



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**ÇİFTÇİ KAYIT VERİLERİ VE AÇIK KAYNAK KODLU
EO-LEARN KÜTÜPHANESİ KULLANILARAK TARIMSAL
ÜRÜN DESEN TESPİTİ VE KONTROLÜ**

Fatih Fehmi ŞİMŞEK

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

Aralık-2022
KONYA
Her Hakkı Saklıdır

ÖZET

DOKTORA TEZİ

ÇİFTÇİ KAYIT VERİLERİ VE AÇIK KAYNAK KODLU EO-LEARN KÜTÜPHANESİ KULLANILARAK TARIMSAL ÜRÜN DESEN TESPİTİ VE KONTROLÜ

Fatih Fehmi ŞİMŞEK

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı**

Danışman Prof. Dr. S. Savaş DURDURAN

2022, 129 Sayfa

Jüri

Prof. Dr. S. Savaş DURDURAN

Prof. Dr. Semih EKERCİN

Doç. Dr. Hüseyin Zahit SELVİ

Doç. Dr. Ash BOZDAĞ

Dr. Öğr. Ü. Gürçay Kıvanç AKYILDIZ

Coğrafi bilgi sistemleri ile uzaktan algılama verilerindeki boyut ve hacim artışı özellikle bölgesel ve ülkesel ölçekteki çalışmalarda, kullanıcıları daha hızlı, entegre ve hazır platform arayışına sokmuştur. Özellikle uydulara ait spektral, zamansal ve mekânsal çözünürlük arttıkça, çok zamanlı görüntülerin de kullanılması ile birçok görüntü ön işleme işlemleri, referans verilerin hazırlanması, eğitim-test verilerinin belirlenmesi ve sınıflandırma çalışmalarının yapılması, hem çok zaman hem de karmaşık bir hal almaktadır. Gelişen teknoloji ile uzaktan algılama çalışmalarında kullanılan bu ve benzeri durumları kolaylaştıracak kütüphaneler ve platformlar oluşturulmaya başlanmış olup bunlardan biri de açık kaynak kodlu EO-Learn kütüphanesidir. EO-Learn kütüphanesi, dünya gözlemi ve uzaktan algılama uygulamalarında, birbirine bağlı entegre iş akışları ve makine öğrenmesi ile derin öğrenme algoritmalarını kullanarak çalışan açık kaynak kodlu bir python kütüphanesidir.

Bu tez çalışmasında ÇKS beyanlı parsellerden yer doğruluk verisi oluşturularak, EO-Learn kütüphanesi ile Denizli Çivril-Baklan Ovası'nda 2017-2021 yılları arasında beş farklı, Eskişehir-Çifteler bölgesinde ise iki farklı olmak üzere toplam yedi farklı sınıflandırma çalışması, hububat (buğday-arpa), haşhaş, meyve ağacı, nadas, şeker pancarı, üzüm, yonca, ayçiçeği, kabak ve mısır ürünleri için yapılmıştır. Çalışmada 15 gün aralıklı Sentinel-2 görüntüleri kullanılmış olup, her Sentinel-2 görüntüsüne ait mavi (bant-2), yeşil (bant-3), kırmızı (bant-4) , yakın kızılötesi (bant-8), kısa dalga kızılötesi-1 (bant-11), kısa dalga kızılötesi-2 (bant-12), bantları ile bantlardan üretilen NDVI, NDWI, SAVI ve üç adet Tasseled cap dönüşümü (TCB-TCG-TCW) olmak üzere toplamda 12 farklı özellik sınıflandırma çalışmasına dâhil edilmiştir.

Geniş alanlarda yapılacak tarımsal ürün desen sınıflandırma çalışmalarında, sınıflandırılacak her ürün için araziden yer doğruluk verisi toplamak çok zamanlı alıcı olmakla beraber maliyetli ve sürdürülebilir değildir. Bu nedenle, tez çalışmasının ana hedeflerinden biri de Çiftçi Kayıt Sistemi'ne (ÇKS) kayıtlı parsellerin sınıflandırma çalışmasında yer doğruluk verisi olarak kullanılmasını sağlamaktır. ÇKS beyanlı parseller üzerinde yapılan incelemede, parsellerde geometrik ve öznel olarak birçok farklılık ve hataların bulunduğu, bunun yanı sıra ekilen ürün ile beyan edilen ürün arasında ise uyumsuzluklar olduğu tespit edilmiştir. Beyan esaslı bu parsellerden yer doğruluk verisi oluşturmak için bir dizi işlem adımı uygulanmış ve parsellerin temizlenmesi için özgün bir uygulama geliştirilmiştir. Parsellerin düzenlenmesi ve temizlenmesi sonucunda Denizli Çivril-Baklan Ovası'nda beş yıl için ortalama 75000'den parselden 13000 adedi, Eskişehir-Çifteler bölgesinde ise iki yıl için ortalama 27000 parselden 6000 adedi yer doğruluk verisi olarak kullanılmıştır.

ÇKS beyanlı parsellerden oluşturulan yer doğruluk verileri ve açık kaynak kodlu EO-Learn kütüphanesi kullanılarak tarımsal ürün desen sınıflandırması yapılmıştır. Sınıflandırma sonucunda K-katmanlı çapraz doğrulama yöntemi ile birinci doğruluk analizi, sınıflandırma çalışmasında test verisi olarak kullanılmayan, dışardan bir veri seti olan Tarım Sigortaları Havuzu (TARSİM) parselleri ile de ikinci doğruluk analizi yapılmıştır. Birinci doğruluk analizi sonucunda Denizli Çivril Baklan Ovası'nda 2017-2018-2019-2020 ve 2021 yılları için sırasıyla %92,8 - %94,7 - %93,5 - %93,5 - %93,9 Eskişehir Çifteler bölgesinde ise 2019 yılı için %92,4 2020 yılı için ise %90,2 genel doğruluk oranına ulaşılmıştır. TARSİM parselleri ile yapılan doğruluk analizinde Denizli Çivril Baklan Ovası'nda 2017-2018-2019-2020 ve 2021 yılları için sırasıyla %94,1 - %88,3 - %92,0 - %90,1 - %90,6 Eskişehir Çifteler bölgesinde ise 2019 yılı için %90,1 2020 yılı için ise %88,4 genel doğruluk oranına ulaşılmıştır. Sınıflandırma sonucunda ürün bazında da doğruluk oranı yüksek olup, yakın fenolojik evrelere sahip ürünlerin birbirleri ile belirli oranda karıştığı tespit edilmiştir.

Geliştirilen uygulama ile ÇKS beyanlı parsellerden oluşturulan yer doğruluk verisi ve açık kaynak kodlu EO-Learn kütüphanesi kullanılarak yapılan sınıflandırma çalışmasında yüksek başarı sağlanmıştır. Eo-Learn kütüphanesi ile yapılan çalışmanın, klasik yöntemlere yapılan çalışmalara kıyasla 10 kat daha az veri boyutu kapsadığı ve işlem süresinin ise 14 kat daha kısa olduğu sonucuna varılmıştır. Farklı alanlarda, farklı ürünlerle, farklı doğruluk analizleri ile birçok kere yapılan ve yüksek başarımlı sağlayan bu çalışma, bölgesel ya da ülkesel ölçekte hızlı, güvenilir ve sürdürülebilir olarak kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Çiftçi Kayıt Sistemi, EO-Learn, Makine Öğrenmesi, Sentinel-2, Sınıflandırma, Tarımsal Ürün Tespiti, Uzaktan Algılama

ABSTRACT

Ph.D THESIS

AGRICULTURAL PRODUCT PATTERN DETECTION AND CONTROL USING FARMER REGISTRATION DATA AND OPEN SOURCE CODE EO-LEARN LIBRARY

Fatih Fehmi ŞİMŞEK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF DOCTOR OF
PHILOSOPHY IN GEOMATIC ENGINEERING**

Advisor: Prof. Dr. S. Savaş DURDURAN

2022,129 Pages

Jury

Prof. Dr. S. Savaş DURDURAN

Prof. Dr. Semih EKERCİN

Assoc. Prof. Dr. Hüseyin Zahit SELVİ

Assoc. Prof. Dr. Aşlı BOZDAĞ

Asst. Prof. Dr. Gürçay Kıvanç AKYILDIZ

The growing size and volume of geographical information systems and remote sensing data have prompted users to seek a more rapid, integrated, and ready platform, particularly in regional and national studies. Many image preprocessing processes, preparation of reference data, determination of training-test data, and classification studies take a long time and become more complex with the use of multi-temporal images, especially as the spectral, temporal, and spatial resolution of satellites increases. With the advancement of technology, libraries and platforms have begun to emerge to aid in these and similar situations encountered in remote sensing studies, one of which is the open source EO-Learn library. The EO-Learn library is a Python open source library that runs earth observation and remote sensing applications by utilizing interconnected integrated workflows as well as machine learning and deep learning algorithms.

In this thesis, a classification study was carried out by creating ground truth data from parcels with ÇKS declaration with the EO-Learn library. In this study between 2017-2021 seven different classification studies were carried out, five in Denizli Çivril-Baklan Plain and two in Eskişehir-Çifteler region for wheat, hash fruit tree, fallaow, sugar beet, vineyard, clover, sunflower, squash , maize. Sentinel-2 images with 15-day intervals were used in the study, and a total of 12 different attributes were included in the classification study including; the blue (bant-2), green (bant-3), red (bant-4) , NIR (bant-8), SWIR-1 (bant-11), SWIR-2 (bant-12) bands and NDVI, NDWI, SAVI, and three Tasseled cap transformation (TCB-TCG-TCW) produced from bands of each Sentinel-2 image.

In large-scale agricultural product pattern classification studies, collecting data from the field for each product to be classified is very time consuming and costly and not sustainable. As a result, one of the primary goals of the thesis research is to ensure that parcels registered in the Farmer Registration System (ÇKS) are used as ground truth data in the classification study. During the examination of the parcels with ÇKS declaration, it was discovered that there are many differences and errors in terms of geometric and attribute as well as significant inconsistencies between the planted product and the declared product. To generate ground truth data from these declaration-based parcels, a series of process steps were used, and a unique application was developed to determine the parcels. As a result of the parcel arrangement and cleaning, 13000 out of 75000 parcels on average for five years in the Denizli Çivril-Baklan Plain and 6000 out of 27000 parcels on average over two years in the Eskişehir-Çifteler region were used as ground truth data.

The agricultural product pattern classification was performed using ground truth data generated from parcels with ÇKS declarations and the open source EO-Learn library. Following the classification, the first accuracy analysis was performed with the K-layer cross-validation method whereas a second accuracy analysis was also carried out with the Tarım Sigortaları Havuzu (TARSİM) parcels, which is an external data set that was not used as test data in the classification study. As a result of the first accuracy analysis; in Denizli Çivril Baklan Plain, the overall accuracy rate of 92.8% - 94.7% - 93.5% - 93.5% - 93.9% was achieved for the years 2017-2018-2019-2020 and 2021, respectively. For Eskişehir Çifteler region, the overall accuracy rate was 92.4% for 2019 and 90.2% for 2020. In the accuracy analysis made with TARSİM parcels, 94.1% - 88.3% - 92.0% - 90.1% - 90.6% for the years 2017-2018-2019-2020 and 2021 in Denizli Çivril Baklan Plain, whereas in Eskişehir Çifteler region, the overall accuracy rate was 90.1% for 2019 and 88.4% for 2020. As a result of the classification, the accuracy rate is also high on the basis of the product, and it has been determined that the products with close phenological stages are mixed with each other at a certain rate.

With the developed application, high success was achieved using the ground truth data generated from the ÇKS declaration based parcels and the classification study conducted using the open source EO-Learn library. In comparison to studies using traditional methods, the Eo-Learn library resulted in 10 times less data size and 14 times shorter processing time. This study, which has been conducted numerous times in various fields, with various products, and with various accuracy analyses and has achieved high success, demonstrates that it can be used quickly, reliably, and sustainably on a regional or national scale.

Keywords: Farmer Register System, EO-Learn, Machine Learning, Sentinel-2, Classification, Agricultural Crop Pattern. Remote Sensing

ÖNSÖZ

Bu çalışma boyunca bilgi ve birikimleriyle yanımda olan başta danışman Hocam Sayın Prof. Dr. S. Savaş DURDURAN'a, uzaktan algılama konusunda bilgi ve tecrübesinden faydalandığım tez jüri üyelerinden Prof. Dr. Semih EKERCİN'e, çalışma alanlarımdan biri olan Denizli-Çivril bölgesi ile ilgili kıymetli bilgiler edindiğim bir diğer tez jüri Dr. Öğr. Ü. Gürçay Kıvanç AKYILDIZ'a teşekkürü borç bilirim.

IACS projesi kapsamında çalışma arkadaşlarım ve şahsıma her türlü desteği veren, devletin imkânları çerçevesinde özellikle yurt dışındaki eğitimlere ve toplantılara katılımımı sağlayan vizyonlu bakış açısıyla şahsıma ve mesai arkadaşlarıma ışık tutan eski Daire Başkanım Dr. Hakan VELİOĞLU'na eski Koordinatörüm Murat ASLAN'a teşekkürlerimi sunarım.

Açık kaynak kodlu EO-Learn kütüphanesinin kullanımı sağlayan başta Sinergise firmasına, firmanın kurucu ortağı Grega MILCINSKI'ye veri bilimci Matic LUBEJ'e, kütüphane üzerinde beraber çok çalıştığımız ve bilgi birikiminde çokça faydalandığım eski mesai arkadaşım Nilhan ÇİFTÇİ SARILAR'a, tezden oluşturduğum makalelerde bana destek veren, yardımcı olan Bükay MURATOĞLU'na teşekkürlerimi sunuyorum.

ÇKS parselleri ile LPIS verini kullanmamı sağlayan Tarım Reformu Genel Müdürlüğü, Entegre İdare ve Kontrol Sistemi eski Daire Başkanı Recep GÜLNAR'a, TARSİM verilerini tarafıma sağlayan Tarım Sigortaları Havuzu İşletmesi A.Ş. teşekkürlerimi sunarım.

ÇKS beyanlı parsellerin temizlenmesi metodolojisinde özgün ara yüzün tasarlanmasında bana çok yardımcı olan, her sorunuma alternatif bir çözüm üreten Mehmet ERDOĞDU ve Batuhan ÇİTOĞLU'na teşekkürü bir borç bilirim.

Son olarak her zaman yanımda olan, her konuda beni destekleyen ve cesaret veren canım aileme sonsuz teşekkür ederim.

Fatih Fehmi ŞİMŞEK
KONYA-2022

Canım ailem ve
yakın zamanda kaybettiğim babaanneme ithafen...

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	x
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Tezin Amacı.....	3
1.2. Literatür Araştırması	3
1.3. Kullanılan Yazılımlar	8
1.4. Tezin Organizasyonu	8
2. MATERYAL VE YÖNTEM.....	10
2.1. Materyal	10
2.1.1. Çalışma alanları	10
2.1.1.1. Çivril-Baklan Ovası (Denizli).....	10
2.1.1.2. Çifteler Ovası (Eskişehir)	11
2.1.2. Sentinel-2 uydu görüntüsü	12
2.1.3. Çiftçi Kayıt Sistemi (ÇKS) ve verileri.....	13
2.1.4. Tarım Sigortaları Havuzu (TARSİM) ve verileri	20
2.1.5. Arazi Parsel Tanımlama Sistemi (LPIS) ve fiziksel blok kavramı	22
2.2. Yöntem.....	25
2.2.1. Makine öğrenmesi kavramı	25
2.2.2. Makine öğrenmesi algoritmaları	26
2.2.2.1. Karar ağacı (Decision tree)	26
2.2.2.2. Destek vektör makineleri (Support vector machine)	27
2.2.2.3. Rastgele orman (Random forest)	28
2.2.2.4. Gradyan artırma (Gradient Boosting)	29
2.2.2.5. Aşırı gradyan artırma (Extreme gradient boosting)	29
2.2.3. Earth Observation (EO-Learn) makine öğrenmesi kütüphanesi.....	30
2.2.3.1. EO-patch	31
2.2.3.2. EO-task	33
2.2.3.2. EO-workflow	33
3. UYGULAMA	34
3.1. Uydu Görüntüsü İşleme ve Özellik Oluşturma.....	34
3.1.1. Çok zamanlı Sentinel-2 görüntülerinin temini.....	34
3.1.2. Atmosferik düzeltme.....	36
3.1.3. Bulutlu alanların belirlenmesi ve maskelenmesi	37
3.1.3.1. Sen2Cloudless.....	38
3.1.4. İndekslerin oluşturulması ve Tasseled Cap dönüşümleri	39
3.1.4.1. Normalize edilmiş fark bitki örtüsü indeksi (NDVI).....	40

3.1.4.2. Normalize edilmiş su farkı indeksi (NDWI).....	41
3.1.4.3. Toprak dengelenmiş bitki örtüsü indeksi (SAVI).....	42
3.1.4.4. Tasseled Cap	42
3.1.5. Oluşturulan katmanların birleştirilmesi	44
3.2. Referans Veri Hazırlama	45
3.2.1. Sınıflandırılacak ürünlerin belirlenmesi	45
3.2.2. Arazi çalışması ve ürünlerin spektral imzalarının çıkarılması.....	46
3.2.3. ÇKS verilerinin temini.....	48
3.2.4. ÇKS verilerinin öznitelik ve geometrik olarak temizlenmesi.....	51
3.2.5. ÇKS verilerinden spektral imza çıkarımı ve parsel tabanlı temizlenmesi	53
3.2.6. ÇKS verilerinin piksel tabanlı temizlenmesi	61
3.2.7. Eğitim ve test verilerinin belirlenmesi.....	72
3.3. Makine Öğrenmesi ve Sınıflandırma	74
3.3.1. Hafif gradyan artırma makineleri (Light gradient boosting machine).....	74
3.3.2. Parametre ve hiper parametre optimizasyonu.....	75
3.3.3. K-katmanlı çapraz doğrulama yöntemi.....	76
3.3.4. Sınıflandırma işlemi.....	77
3.3.5. Sınıflandırma sonuçlarının maskelenmesi	79
3.4. Doğruluk Analizleri	85
3.4.1. Doğruluk Analizi-1	85
3.4.2. Doğruluk Analizi-2	90
4. BULGULAR VE DEĞERLENDİRME	96
5. SONUÇLAR VE ÖNERİLER	106
KAYNAKLAR	110

SİMGELER VE KISALTMALAR

Simgeler

A0:	Ekilebilir arazi
A1:	Dağınık ağaçlı ekilebilir arazi
A3:	Karışık tarımsal alan
S1:	Üzüm bağları
T0:	Sürekli ağaç ürünü
FN:	False negative
FP:	False positive
Ha:	Hektar
Id:	Identification
K:	Kappa katsayısı
m ² :	Metre kare
mtry:	Rastgele özellik seçimi
N:	Toplam eğitim verisi
ntree:	Ağaç sayısı
L:	Toprak düzeltme faktörü
r:	Sınıf sayısı
TN:	True negative
TP:	True positive
X _{+i} :	i satır toplamı
X _{i+} :	i sütun toplamı
X _{ii} :	doğru sınıflandırılmış eğitim verisi toplam

Kısaltmalar

AKS:	Arıcılık Kayıt Sistemi
AWS:	Amazon Web Servisi
BOA:	Bottom of Atmosphere
CBS:	Coğrafi Bilgi Sistemi
ÇKS:	Çiftçi Kayıt Sistemi

CNN:	Convolutional Neural Network
DGD:	Doğrudan Gelir Desteği
DSİ:	Devlet Su İşleri
DTW:	Dynamic Time Warping
EFB:	Exclusive Feature Bundling
EO:	Earth Observation
EPIchlb:	Eucalyptus Pigment Index For Chlorophyll b
ESA:	European Space Agency
GARI:	Green Atmospherically Resistant Vegetation Index
GDAL:	Geospatial Data Abstraction Library
GNDVI:	Green Normalized Difference Vegetation Index
GPU:	Graphics Processing Unit
GOSS:	Gradient Based One Side Sampling
IACS:	Integrated Administration and Control System
IDE:	Integrated Development Environment
IRS-1B:	Indian Remote Sensing Satellite-1B
KNN:	K-Nearest Neighbor
L1C:	Level 1-C
L2A:	Level 2-A
LightGBM:	Light Gradient Boosting Machine
LPIS:	Land Parcel Identification System
MNDVI:	Modified Normalized Difference Vegetation Index
ML:	Machine Learning
NDII:	Normalized Difference Infrared Index
NDRE:	Normalize Difference Red Edge Index
NDVI:	Normalized Difference Vegetation Index
NDWI:	Normalized Different Water Index
NIR:	Near Infrared
OLI:	Operational Land Imager
OTP:	Ortak Tarım Politikası
ÖKS:	Örtü Altı Kayıt Sistemi
PVR:	Photosynthetic Vigour Ratio
RAM:	Random Access Memory
REIP:	Red-Edge Inflection Point

RF:	Random Forest
SAM:	Spektral Angel Mapper
SAVI:	Soil-Adjusted Vegetation Index
SIPI:	Structure Intensive Pigment Index
SKS:	Su Ürünleri Kayıt Sistemi
SMAC:	The Simplified Model for Atmospheric Correction
SVM:	Support Vector Machine
SWIR:	Short Wave Infrared
TARSiM:	Tarım Sigortaları Havuzu
TCB:	Tasseled Cap Brightness
TCG:	Tasseled Cap Greenness
TCW:	Tasseled Cap Wetness
TCT:	Tasseled Cap Transformation
TOA:	Top of the Atmosphere
TÜİK:	Türkiye İstatistik Kurumu
TWDTW:	Time Weighted Dynamic Time Warping
UTM:	Universal Transverse Mercator
VARIGreen:	Visible Atmospherically Resistant Index Green
VH:	Vertical - Horizontal
VV:	Vertical – Vertical
WGS:	World Geodetic System
XGBoost:	Extreme Gradient Boosting

1. GİRİŞ

Son yıllarda etkisini günden güne daha çok hissettiğimiz küresel ısınma ve iklim değişikliğinin, küresel ve bölgesel ölçekte bir takım etkilerinin olması kaçınılmazdır. Nitekim küresel iklim değişikliği, su kaynakları, biyolojik çeşitlilik, orman, bitki örtüsü ve özellikle tarımsal üretim üzerinde olumsuz etkilerini ciddi şekilde göstermektedir. İklim değişikliği nedeniyle toprak ve su rejimleri değişime uğramakta, tarımsal üretim azalmakta ve gıda güvenliği tehlikeye girmektedir. Bu sebeple tarımın ve su tüketiminin profesyonel şekilde yönlendirilmesi ve izlenmesi büyük önem taşımaktadır. Tarımsal üretimin yönetilmesi ve izlenmesi için, ürün çeşidi ve ekimi yapılan araziler hakkında bilgi sahibi olmak gerekmektedir. Bunun yanı sıra tarımsal üretim, verim, rekolte ve tarımsal su tüketimi hakkında elde edilecek veriler de sürdürülebilir tarım açısından önem arz etmektedir.

Uzaktan algılama, yeryüzü ile fiziksel bir bağlantı kurmadan kaydetme ve inceleme tekniğidir. Yeryüzü hakkında bilgi edinimi, elektromanyetik enerji vasıtasıyla yeryüzündeki cisimlerin etkileşimi ile gerçekleşmektedir. Arazi örtüsü/kullanımı ile tarımsal ürün desen çeşidinin belirlenmesi ve tematik olarak haritalanmasını sağlayan önemli teknolojilerden birisi de uzaktan algılamadır. Tarımsal uygulamalar, uzaktan algılama teknolojisinin en yaygın kullanım alanlarından biri olup bu teknoloji ile tarımsal ürün desen tespiti yanı sıra, biokütle, ürün verimi, evapotranspirasyon ve su kullanımı gibi tarımsal ekosistem değişkenlerinin modellenmesi de sağlanmaktadır (Wesseling ve Feddes, 2006).

Tarımsal ürün deseni tespitinde en yaygın kullanılan yöntemlerin başında uzaktan algılama teknolojisi gelmektedir. Uydu görüntüleri ile farklı zamansal ve konumsal çözünürlüklerle dinamik olan tarımsal alanlarının gözlemlenmesi, tanımlanması, haritalanması ve değerlendirilmesi sağlanmaktadır. Uydu görüntüleri ile tarımsal ürün desen tespitinde kullanılan en yaygın yöntem ise görüntü sınıflandırmasıdır. Landsat uydusuna ait görüntülerle başlayan tarımsal ürün desen sınıflandırma çalışmaları belirli bir aşama kaydetse de özellikle zamansal çözünürlük (16 günlük) ve mekânsal çözünürlük (30 m PAN – 15 m RGB) olarak yetersiz kalmıştır. Bunun yanı sıra tek zamanlı uydu görüntüleri ile yapılan ürün desen sınıflandırma çalışmalarının, farklı ürünlerin yakın spektral yansıma değerleri nedeniyle tarımsal ürün desen sınıflandırması için uygun olmadığı tespit edilmiştir. Çok zamanlı görüntülerle yapılan sınıflandırma

çalışmaları ise ürünlerin fenolojik süreçlerini içerdiğinden tek zamanlı görüntülere kıyasla çok daha yüksek doğruluk vermektedir.

Zamansal, konumsal ve spektral çözünürlüğü yüksek IKONOS, QuickBird, Worldview 2-3 ve SPOT 5-6-7 uyduları ve sayıları her geçen gün artan yeni uydulara ait görüntüler de tarımsal ürün desen tespitinde kullanılmaktadır. Yüksek çözünürlüklü uydu görüntüleri, düşük çözünürlüklü uydu görüntülerine kıyasla daha yüksek doğrulukta sonuçlar vermektedir. Ancak yüksek çözünürlüklü uydu görüntülerinin ücretli olması ve çoğu uydunun zamansal çözünürlüğünün sabit olmaması nedeniyle kullanımları sınırlı kalmaktadır.

Avrupa Birliği'nin Avrupa Komisyonu ve Avrupa Uzay Ajansı (ESA) tarafından yönetilen yeryüzü inceleme programı olan Copernicus programı çerçevesinde Sentinel olarak adlandırılan optik ve radar görüntülerini içeren yeni bir uydu serisi uzaya gönderilmiş ve gönderilmeye de devam etmektedir. Amacı küresel, devamlı, otonom, yüksek çözünürlükte ve geniş alanları kapsayan Dünya gözlem kapasitesi yaratmaktır. Program, küresel ısınma, iklim değişikliği, arazi örtüsü ve kullanımı, tarım ve buzul bilimi birçok farklı alanda uydu görüntüleri ile analiz ve çalışma olanağı sağlamaktadır. Uydulara ait görüntülerin tamamının ücretsiz olarak tüm kullanıcılar ve kamu tarafından erişilebilir olması programın sağladığı en önemli faydalardan bir tanesidir. Copernicus programı kapsamında 2015 ve 2016 yıllarında fırlatılan Sentinel-2A ve Sentinel-2B uyduları, 5 günlük çekim periyodu, 13 spektral bandı ve ideal çözünürlüğü ile (10m-20m-60m) dinamik bir yapı gösteren tarımsal ürün desen belirleme çalışmalarında büyük bir avantaj sağlamaktadır.

Uydulara ait mekânsal, spektral, zamansal çözünürlük arttıkça kullanılan veri boyutu da artmaktadır. Sadece Sentinel-2 uydusunun kullanılmaya başlanmasından bu zamana 8 PB'yakın verinin üretildiği tüm Copernicus programına ait verilerin ise yaklaşık 200 PB'ı bulunduğu tahmin edilmektedir. Bilgisayar bilimlerindeki gelişmelere bağlı olarak ortaya çıkan ve her geçen gün daha da popüler olan makine öğrenmesi ve derin öğrenme algoritmaları, özellikle geniş alanları kapsayan ve büyük miktarda veri içeren uzaktan algılama ve dünya gözlemi çalışmalarında kullanılmaya başlanmıştır. Uzaktan algılama çalışmalarında makine öğrenmesi algoritmalarının kullanımı zaman içerisinde daha da yaygınlaşmış olup kullanıcılar için geliştirilen çeşitli hazır iş modelleri, kütüphaneler ve platformlarla desteklenerek zaman alan işlem adımları ve sınıflandırma işlemleri yarı otomatik ya da otomatik bir duruma getirilmeye çalışılmaktadır. Özellikle bu tür kütüphane veya hazır iş modelleri ile büyük alanlar ya da bölgesel çalışmaların

daha az veri boyutu ile, daha kısa sürede ve daha yüksek doğrulukta yapılması ana hedeflerden bir tanesidir.

Bu tez çalışmasında uzaktan algılama uygulamalarında, içerisindeki modüler paketler ve alt paketleri ile birbirine bağlı, entegre iş akışları çalışan, makine öğrenmesi ile derin öğrenme algoritmalarını kullanan açık kaynak kodlu bir python kütüphanesi olan EO-Learn kütüphanesi ile tarımsal ürün desen sınıflandırma çalışması yapılmıştır. Kütüphane ile tarımsal ürün desen sınıflandırma çalışmasının yanı sıra, sınıflandırmada eğitim ve test verisi olarak kullanılmak üzere Çiftçi Kayıt Sistemi (ÇKS) beyanlı parsellerden geliştirilen yöntem ile yer doğruluk verisi üretilmiştir.

1.1. Tezin Amacı

Tarımsal ürün desen tespiti çalışmaları, üç temel ayak üzerine kurulmuştur. Bunlardan birincisi kullanılacak uydu görüntüleri ve ön işleme işlemleri, ikincisi sınıflandırma ve doğruluk analizinde kullanılacak eğitim ile test verisi, üçüncüsü ise çalışmada kullanılacak algoritmadır. Bu tez çalışmasının ilk amacı, özellikle geniş alanlarda yapılacak tarımsal ürün desen sınıflandırma çalışmalarında eğitim ve test verisi olarak kullanılmak üzere, farklı alanlara, zamanlara ve ürünlere ait ÇKS beyanlı parsellerden yer doğruluk verisi oluşturulmasıdır.

Çalışmanın ikinci amacı, uzaktan algılama çalışmalarında, kullanılacak uydu görüntülerinin belirlenip temin edilmesinden, görüntü ön işleme işlemlerine, kullanılmak istenen bantlar, indeksler ve dönüşümlerden sınıflandırma işlemine, çok büyük miktardaki ve çeşitteki veriyi birbirine bağlı hazır modeller ve iş akışları ile makine öğrenme ve derin algoritmanı kullanan açık kaynak kodlu EO-Learn kütüphanesi ile tarımsal ürün desen tespiti çalışması yapmak ve uygulanabilirliği belirlemektir.

Farklı alanlarda, farklı zaman dilimlerinde, farklı ürünlerde ve birden çok yapılacak sınıflandırma çalışması ile iki temel amaç birleştirilerek bölgesel ya da ülkesel ölçekte yapılacak uzaktan algılama teknolojisi ile tarımsal ürün desen tespiti çalışmalarında bir yöntem ve metot oluşturmak bu tez çalışmasının ana hedefidir.

1.2. Literatür Araştırması

Lubej ve ark. (2019), Slovenya sınırlarının tamamını kapsayan arazi örtüsü sınıflandırma çalışmasını açık kaynak kodlu EO-Learn kütüphanesi kullanarak

yapılmışlardır. Yaptıkları bu çalışmada özellikle yıl içerisinde tarım alanları dinamik bir yapı olup değişim gösterdiğinden, tek bir görüntü yerine çok zamanlı Sentinel-2 görüntüleri ile derin öğrenme yöntemini kullanarak sınıflandırmada %84.4 genel doğruluk başarımına ulaşmışlardır.

Račić ve ark. (2020), Slovenya ölçeğinde tarımsal ürün desen sınıflandırması çalışması yapmışlardır. Ülke ölçeğinde 23 farklı tarımsal ürünle başlayan sınıflandırma, bazı sınıfların elemine edilmesi ile 15 sınıfa düşürülmüştür olup çalışmada yer doğruluk verisi olarak Slovenya Tarım Piyasaları ve Kırsal Kalkınma Ajansı'ndan temin edilen poligonlar kullanılmıştır. Açık kaynak kodlu EO-Learn kütüphanesi ve bu kütüphane içerisindeki çok zamanlı Sentinel-2 görüntüleri kullanılarak yapılan bu sınıflandırma çalışmasında hafif gradyan artırma makineleri (LightGBM) ile yapılan sınıflandırma sonucu genel doğruluk %72 iken derin öğrenme algoritması (Temp CNN) kullanılarak başarımlar %87'ye çıkarılmıştır.

Jarray ve ark. (2021), Tunus'un Medenine şehrinde açık kaynak kodlu EO-Learn Kütüphanesini kullanılarak, Sentinel-1 ve Sentinel-2 görüntüleri yardımıyla toprak nem tahmini çalışması yapmış olup, yapılan çalışma sonucunda karar ağacı (RF) algoritması ile % 88, aşırı gradyan artırma algoritması (XGBoost) ile % 79, yapay sinir ağları ile ise % 76 başarımlar sonucuna ulaşmışlardır.

Şimşek ve Durduran (2023), Denizli İli Çivril-Baklan Ovası sınırları içerisinde kalan alanda EO-Learn kütüphanesi kullanarak 8 farklı tarımsal ürün için piksel tabanlı sınıflandırma çalışması yapmışlardır. 21 farklı görüntü ve bu görüntülerden elde edilen 252 farklı özellik ile aşırı gradyan artırma makineleri (XGBoost) kullanılarak yapılan çalışmada %91.1 genel doğrulukta sınıflandırma sonucuna ulaşılmıştır.

Csillik ve Belgiu (2017), tarafından Romanya'da 63.979 hektarlık alanda Sentinel-2 görüntüleri kullanılarak buğday, mısır, pirinç, ayçiçeği ve diğer sınıflar olmak üzere piksel tabanlı sınıflandırma işlemi yapılmıştır. Ağırlıklı dinamik zaman eğrisi (TWDTW- Time Weighted Dynamic Time Warping) metodu ile yapılan çalışmada % 93.43 başarıma ulaşılmıştır.

Csillik ve ark. (2019), Sentinel-2 uydusunun (R-G-B-NIR) ve bu bantlardan üretilen NDVI-GNDVI-NDRE-SAVI-NDWI indekslerini kullanarak Romanya, İtalya ve ABD'de olmak üzere yaklaşık 60.000 hektarlık 3 farklı alanda hem piksel hem de obje tabanlı tarımsal ürün desen sınıflandırma çalışması yapmışlardır. Ağırlıklı dinamik zaman eğrisi (TWDTW- Time Weighted Dynamic Time Warping) metodu ile yapılan çalışma

sonucunda, üç farklı alanda da nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha yüksek doğruluk verdiğini tespit etmişlerdir.

Üstüner ve ark. (2020), Konya İli Sarayönü İlçesinde Sentinel-1 görüntülerini kullanarak yem, mısır, patates, ayçiçeği ve buğday olmak üzere 5 farklı tarımsal ürün için sınıflandırma çalışması yapmışlardır. Hafif gradyan artırma makineleri (Light GBM) kullanılarak yapılan sınıflandırma çalışması sonucunda % 97 doğruluk ile en yüksek skor buğday ürününe ait iken, sınıflandırma işlemi sonucu en düşük skor ise % 69 ile yem bitkisi sınıfına ait olmuştur.

Altun ve Türker (2021), Mardin İli, Artuklu İlçesinde çok zamanlı Sentinel-2 görüntüleri ve ÇKS beyanlı parselleri kullanarak mısır, buğday, pamuk, nohut, mercimek ve diğer sınıfı olmak üzere aşırı gradyan artırma makineleri (XGboost) kullanarak tarımsal ürün desen sınıflandırması yapmışlardır. Yapılan sınıflandırma sonucu başarımlar %96.5 olup, yer doğruluk verisi olarak kullanılan ÇKS beyanlı parsellerin sınıflandırma işleminde kullanılmadan önce bir takım silme ve düzenleme işlemlerinden geçmesi gerektiğinden bahsetmişlerdir.

Kobayashi ve ark. (2020), Japonya'nın Hokkaido bölgesinde karar ağacı algoritmasını kullanarak 6 farklı ürün için tarımsal ürün desen sınıflandırması yapmışlardır. Yapılan bu sınıflandırma çalışmasında Sentinel-2 uydusuna ait tüm bantlar ve bu bantlardan oluşturulan 91 farklı indeks kullanılarak sınıflandırma sonuçları karşılaştırılmıştır. Çalışma sonucunda Sentinel-2 uydusuna ait mavi (b2), kırmızı (b4), yakın kızılötesi (b8), kısa dalga kızılötesi-1 (b11), kısa dalga kızılötesi-2 (b12) bantları ile PVR, VARIGreen, SIPI, GARI, mNDVI, REIP, EPIchlb, ve NDII indeksleri kullanılarak yapılan sınıflandırma sonucunun daha yüksek doğrulukta olduğunu ve tarımsal ürünlerin birbirlerinden daha kolay ayrıldıkları sonucuna varmışlardır.

Serra ve Pons (2008), İspanya'nın Katalunya bölgesinde 17000 hektarlık alanda pirinç, mısır, yonca ve meyve ağacı ürünleri için 2002-2005 yılları arasında 36 adet Landsat görüntüsü kullanarak sınıflandırma çalışması yapmışlardır. Çalışma sonucunda çok zamanlı uydu görüntülerinin ürün desen tespiti ve izlenmesinde gerekli olduğu sonucuna varmışlardır.

Peña-Barragán ve ark. (2011), ABD'de ASTER uydusuna ait görüntüleri kullanarak sınıflandırma çalışması yapmışlardır. Sınıflandırma işleminden önce 12 ürüne ait fenolojik takvim ve NDVI değerleri kullanılarak ürünlere ait spektral ayrılma eğrilerini belirlemişlerdir. Bu işlemin ardından obje tabanlı yapılan sınıflandırma

çalışmasında sınıflandırmaya doku bantları da dahil edilmiş olup karar ağacı modeli ile yapılan sınıflandırmanın genel doğruluk oranı %79 olarak tespit edilmiştir.

Murthy ve ark. (2003) Hindistan'nın Haryana bölgesinde IRS 1-B (Hint Uzaktan Algıma) uydusuyla yaptıkları çalışmada, buğday, ayçiçeği ve nadas ürünlerinin tespitini, yapay sinir ağları ve en yüksek olasılık sınıflandırıcı yöntemleri ile çalışmışlardır. Çalışma sonucunda yapay sinir ağları yöntemi, en yüksek olasılık sınıflandırıcısı yöntemine göre daha iyi sonuçlar vermiştir. Sınıflandırmada buğday ürününün tespitinde %90 doğruluk oranına ulaşılmış olup, diğer ürünlerdeki başarımlar %70-%80 aralığında kalmıştır.

Vuolo ve ark. (2018), Avusturya'nın Marchfeld bölgesinde Sentinel-2 görüntüleri kullanarak 2016-2017 yılları için tarımsal ürün desen sınıflandırması yapmışlardır. Tarımsal ürün desen sınıflandırmasında ne kadar sayıda görüntünün sınıflandırma başarımlarını yukarıya taşıyacağı odak noktalarından biri olup havuç, mısır, soğan, patates, bal kabağı, soya, şeker pancarı, ayçiçeği ürünlerinin sınıflandırmasında 2016 yılı için 8 farklı, 2017 yılı için 10 farklı görüntü kullanmışlardır. Sadece mart ve nisan ayları içerisinde kalan görüntüler kullanıldığında başarımların çok düşük olduğu (%50), Mayıs-Haziran arasında (%70) başarımların bir miktar arttığı tüm tarım takvimini içine alan görüntüler kullanıldığında ise başarımların yüksek skorda olup %90'lara çıktığını tespit etmişlerdir.

Onojeghuo ve ark. (2018), Çin'de yaptıkları çalışmada Sentinel-1 ve Landsat görüntülerini kullanarak pirinç alanlarını rastgele orman modeli (RF) ve destek vektör makineleri (SVM) kullanılarak tespit etmişlerdir. Sınıflandırma çalışmasında çok zamanlı Sentinel-1 uydusunun VH ve VV bantları ile Landsat uydusunun bantlarından oluşturulan NDVI görüntüleri kullanılmıştır. VH, VV radar ve NDVI optik bantlarının farklı kombinasyonları ile yapılan sınıflandırma çalışmasında en yüksek doğruluğu bu 3 bandın bulunduğu rastgele orman modeli vermiş olup (%95.3), destek vektör makineleri ise %90.4 genel doğruluk oranında kalmıştır.

Teke ve Yardımcı (2016), Şanlıurfa'da bulunan Harran Ovası'nda 2015 yılında çekilen 9 adet Göktürk-2 görüntüsü ile buğday, mısır ve pamuk ürünlerinin sınıflandırmasını yapmışlardır. En yakın komşuluk (KNN), spektral açı eşitleyici (SAM), dinamik zaman bükme eğrisi (DTW) algoritmaları kullanılan 3 farklı yöntemde yüksek doğrulukta sınıflandırma başarımına sahip olmuş olup en yüksek başarımlar dinamik zaman bükme algoritması (%99.83) ulaşmıştır.

Yeler ve ark. (2017), Adana İli Aşağı Seyhan Ovası'nda çok zamanlı Landsat görüntüleri kullanarak tarımsal ürün desen (karpuz, mısır, pamuk, narenciye, soya, patates, yer fıstığı, buğday) ile arazi örtüsü sınıflandırması (boş tarım, orman, su, yerleşim) çalışması yapmışlardır. Maksimum olabilirlik metodu ile yapılan çalışma obje tabanlı yapılmış olup genel doğruluk oranı % 91 olarak hesaplanmıştır.

Şimşek ve ark (2016), Harran Ovası'nda 2013 ve 2014 yıllarında Landsat görüntülerine ait NDVI bantlarını kullanarak kural tabanlı sınıflandırma ile ova sınırları içerisindeki ÇKS beyanlı parsellerin (hububat, pamuk, 1.ürün hububat 2. ürün mısır) doğruluğunu kontrol etmişlerdir. Yapılan çalışma sonucunda pamuk beyanlı parsellerin %99 oranında, hububat ve mısır beyan bilgisini içeren parsellerin ise %90 oranında doğru olduğunu tespit etmişlerdir.

Fontanelli ve ark. (2014), İtalya'nın Lombardiya bölgesinde 2013 yılında 13 adet optik Landsat 8-OLI (Operational Land Imager) ve 15 adet radar Cosmo Sky-Med görüntüleri kullanarak MLC (En büyük beklenti sınıflandırıcı), EMD (Öklid en küçük mesafe) ve SAM (Spektral açı eşitleyici) yöntemleri ile pirinç, mısır, buğday alanları sınıflandırılmıştır. MLC yöntemi ile olan sınıflandırma sonucu %94 ile en yüksek başarıyı elde etmiştir.

Pan ve ark. (2015), Çin uydusu olan Huan Jing-1 (HJ-1A/B) uydusuna ait görüntüler ile başta buğday ve mısır ürünleri olmak üzere, çok zamanlı NDVI görüntülerini kullanarak ürünlerin fenolojilerini, ekim tarihi, hasat tarihi, sahada en yeşil (max NDVI) olduğu dönemleri tespit etmişlerdir. Ürünlerin fenolojilerinin tespitinde 16 günlük zamansal çözünürlüğe sahip Landsat görüntülerinin yetersiz kaldığı iddia edilmiş olup, 30 metre mekansal, 4 günlük zamansal çözünürlüğe sahip (HJ-1A/B) uydusu ile çalışmada 2011-2012-2013 yılların için 54-73-57 görüntü kullanarak ürünlerin fenolojilerini tespit etmişlerdir.

Marszalek ve ark. (2020), Google Earth Engine platformunda Almanya'nın Bavyera bölgesinde çok zamanlı Sentinel-2 görüntüleri ile tarla sınırlarının belirlenmesi ve ürün desen sınıflandırması çalışması yapmışlardır. Kolza, buğday, arpa, şeker pancarı, mısır ve patates ürünlerinin tespit edildiği bu çalışmada Sentinel-2 uydusuna ait bütün bantlar ve NDVI indeksleri kullanılmıştır. Çok zamanlı NDVI, NDWI ve NDRE görüntüleri kullanılarak ürünlerin birbirlerinden ayrışmaları kıyaslanmış olup, NDWI ve NDRE indeksleri kullanılarak oluşturulan fenolojik eğriler NDVI ile benzer çıkmış olup, bu sebepten dolayı da sadece sınıflandırmaya NDVI görüntülerini dahil etmişlerdir. Çalışmaya ek olarak 2016 ve 2017 yıllarında toplanmış yer doğruluk verileri ile 2018


yılına ait sınıflandırma çalışması da yapılmıştır. Bir önceki yıllara ait yer doğruluk verisi ile yapılan sınıflandırma çalışmasında başarımın düştüğü görülmüş olup, 2018 yılının daha sıcak ve kurak geçtiği, bu sebeple bazı ürünlerin gelişemediği ve daha az gelişmiş ürünlerin tespit edilememesi nedeniyle bu düşüşün meydana geldiği anlaşılmıştır.

1.3. Kullanılan Yazılımlar

Tez çalışmasında QGIS, ArcGIS Pro, FME WorkBENCH yazılımları ile Python, C# yazılım dilleri kullanılmıştır. Vektör veriler (tarım parselleri, beyan esaslı parseller, fiziksel bloklar) ve raster verilerin (uydu görüntüleri) editlenmesi, düzenlenmesi ile mekânsal analizler vb. işlemlerde açık kaynak kodlu QGIS yazılımı kullanılmıştır. ÇKS beyanlı parsellerin temizlenerek, bu parsellerden yer doğruluk verisi oluşturulması C# yazılım dili kullanılarak oluşturulan özgün ara yüzle yapılmıştır. Uydu görüntülerin temin edilmesi, görüntülerden özellik çıkarımı ve makine öğrenme algoritmaları ile sınıflandırma çalışması açık kaynak kodlu python tabanlı EO-Learn kütüphanesi kullanılarak yapılmıştır. Sınıflandırma çalışması sonrası birinci doğruluk analizi EO-Learn kütüphanesi ile yapılmış olup, ikinci doğruluk analizi ise FME WorkBENCH yazılımı kullanılarak yapılmıştır. Veri görselleştirme ile sınıflandırma sonuçlarının çıktıları ve haritalandırılmasında ArcGIS Pro yazılımı kullanılmıştır.

1.4. Tezin Organizasyonu

Bu tez çalışması beş ana başlık altında toplanmıştır. Birinci bölüm, tezin amacı ve literatür çalışmalarını içermektedir. İkinci bölüm, çalışma alanları, tezde kullanılan veri çeşitleri, makine öğrenme algoritmaları ve açık kaynak kodlu EO-Learn kütüphanesi ile ilgili kısımları içermektedir. Üçüncü bölüm, uygulama kısmını içermekte olup, “Uydu Görüntüsü İşleme ve Özellik Oluşturma, Referans Veri Hazırlama, Makine Öğrenmesi ve Sınıflandırma ile Doğruluk Analizi” olmak üzere 4 alt başlıktan oluşmaktadır. Dördüncü bölümde bulgular ve değerlendirme, beşinci bölümde ise tez çalışması neticesinde varılan sonuçlar açıklanmıştır.



Şekil 1.1 Çalışmada kullanılan işlem adımları diyagramı

2. MATERYAL VE YÖNTEM


2.1. Materyal

2.1.1. Çalışma alanları

2.1.1.1. Çivril-Baklan Ovası (Denizli)

Birinci çalışma alanı Denizli İli Çivril, Baklan ve Çal İlçe sınırlarına giren Çivril-Baklan Ovası sınırları içerisinde yer almaktadır. Çivril-Baklan Ovası ortalama 850 m yükseklikte olup, 90.000 ha'lık genişliği ile bölgenin en yüksek ve en geniş ovası konumundadır (Özsoy, 2011). Ova yer altı suyu potansiyeli bakımından zengin bir havza niteliğinde olup, yıllık ortalama yağış miktarı 409,56 mm'dir. Bölgede yer altı suyu değişimini etkileyen en önemli parametre yağış miktarındaki değişimdir. Yarı kapalı havza niteliğinde olan Çivril-Baklan Ovası kuzeyden güneye uzanan geniş yayılımlı çöküntü alanı ile Çivril-Baklan grabenini oluşturmakta olup, Ege Bölgesi'nin en önemli akarsuyu olan Büyük Menderes Nehri ovayı baştan sona sulayarak geçmektedir (Aksever ve Eroğlu, 2016). Nehrin üzerinde Işıklı Baraj Gölü yer almakta olup, ovadaki tarımsal sulama bu baraj gölü tarafından karşılanmaktadır. Baklan Sağ Sahil, Baklan Sol Sahil, Irgıtlı ve Sütlaç Sulama Birlikleri olmak üzere 50.000 hektar üzerindeki alan bu birlikler vasıtasıyla yüzey suları ile sulanmaktadır. Bu çalışmada Çivril-Baklan Ovası içerisindeki tarım alanlarını kapsayan 60.000 hektarlık alan çalışma alanı olarak belirlenmiştir. Çalışma alanında ortalama 70.000 tarımsal üretim yapan parsel bulunmakta olup, parsel büyüklüğü ortalama 8 dekadır (Şimşek ve Durduran, 2023).

Çok büyük tarımsal alana sahip olan ovada tarımsal ürün çeşitliliği de fazladır. Elma, kiraz, üzüm, ayva, armut, şeftali, kayısı, nar, vişne meyvelerinin yanı sıra ayçiçeği, haşhaş, mısır, buğday, arpa, şeker pancarı, yonca ve üzüm gibi ürünlerde yetiştirilmekte olup sulama imkânının bulunduğu alanlarda sebze tarımı da yapılmaktadır (Özen, 2015). Tarım ve Orman Bakanlığı (2019) tarafından hazırlanan raporda bölgede ekonomik değeri yüksek meyvelerin yetiştirildiği, ülke ihtiyacı olan çekirdek ayçiçeğinin %80'i ile elmanın %25'nin Çivril-Baklan Ovası'ndan karşılandığı belirtilmiştir (Demirci, 2019). Menderes Grabenini çevreleyen dağların etekleri boyunca ise uzun bağları ile zeytin ağaçları yer almaktadır (Atalay, 2018).




Şekil 2.1 Denizli Çivril-Baklan Ovası'na ait çalışma alanı

Çivril-Baklan Ovası'nda 1985'ten 2010 yılına gelindiğinde tarımsal alanlarda önemli bir değişim olduğu görülmektedir. Söz konusu yıllar arasında sulu tarım alanları %100'lük bir artış gösterirken kuru tarım alanlarında ise tam tersi oranda bir azalış görülmektedir. Söz konusu bu durum uydu görüntüleri ile de incelendiğinde kuru tarım alanlarının, sulu tarım alanlarına dönüştüğünü göstermektedir. Bölgede orman alanlarında da azalma olduğu görülmüş olup, mera sahalarının 1985'den 2010 yılına gelindiğinde %10 oranında artması orman alanlarının tahribat sonucu meraya dönüştüğünün bir işaretidir. (Çelik ve Gülersoy, 2013).

2.1.1.2. Çifteler Ovası (Eskişehir)

İkinci çalışma alanı, Eskişehir İl sınırı içerisinde büyük bir kısmını Çifteler ilçesinin oluşturduğu, Mahmudiye ve Sivrihisar ilçelerinin de belirli kısmını içine alan 45.000 hektarlık bir alandır. Çalışma alanının tam ortasında 1968 yılında hizmete açılmış Sakaryabaşı Sulama Birliği bulunmakta olup, 15.000 hektarlık alan birlik tarafından sağlanan pompaj ve cazibe sulama tesisleri vasıtasıyla sulanmaktadır. Bölgede en ayçiçeği, mısır, yonca, şeker pancarı, kabak, buğday ve arpa ürünleri yetiştirilmektedir.

Birlik sınırı dışında, çalışma alanı içinde kalan bölgede ise çoğunluk arpa ve buğday ile nadasa bırakılanlar alanlar oluşturmaktadır.



Şekil 2.2 Eskişehir Çifteler bölgesine ait çalışma alanı

2.1.2. Sentinel-2 uydu görüntüsü

Sentinel-2, Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı dâhilinde geliştirilen optik görüntüler elde eden takım uydulardır. Sentinel 2 serisi Sentinel 2A ve Sentinel 2B olmak üzere iki uydudan oluşmaktadır. Bu uydular yaklaşık 800 km yörünge yüksekliğinde, kutupsal yörüngeli olup birbirlerine 180^0 açıda bulunmaktadır. Sentinel-2 uyduları 5 günde bir çekim periyoduna sahip olup dalga boyuna bağlı olarak 10 m, 20 m ve 60 m mekânsal çözünürlüğü bulunan 13 adet spektral banttandır.

Sentinel-2 uydularının, yüksek tekrar ziyareti, yüksek mekânsal çözünürlüğe sahip olması, geniş şerit genişliği ve 13 spektral bandının bulunması karasal ve kıyisal uygulamalarda çok faydalı olmaktadır (Drusch ve ark, 2012). Özellikle 5 günlük zamansal çözünürlüğe sahip olması bitki örtüsünün izlenmesi ve tarımsal ürün deseninin belirlenmesi ve değişiminin incelenmesinde büyük bir avantaj sağlamaktadır. Sentinel 2 uydularına ait genel özellikler Çizelge 2.1’de, spektral bantlar ve bantlara ait özellikler Çizelge 2.2’de gösterilmiştir.

Çizelge 2.1 Sentinel-2 uydusuna ait özellikleri

Görev özellikleri	Veriler
Uydu sayısı	2
Yörünge	786 km (güneşle eş zamanlı)
Coğrafi çekim alanı	54 ile +84 enlemleri arasında sistematik olarak çalışmaktadır
Zamansal çözünürlük	5 gün
Konumsal çözünürlük	10m/20m/60m
Spektral bantlar	13 (VIS-NIR-SWIR)
Şerit genişliği	290 km

Çizelge 2.2 Sentinel-2 uydusuna ait spektral bantları

Bant Numarası	Spektral Çözünürlük (nm)	Konumsal Çözünürlük(m)
Bant 1 - Kıyı aerosol	433-453	60
Bant 2 - Mavi	458-523	10
Bant 3 - Yeşil	543-578	10
Bant 4 - Kırmızı	650-680	10
Bant 5 - Kırmızı Kenar	698-713	20
Bant 6 - Kırmızı Kenar	733-748	20
Bant 7 - Kırmızı Kenar	773-793	20
Bant 8 - Yakın Kızılötesi	785-900	10
Bant 8A - Kırmızı Kenar	855-875	20
Bant 9 – Su Buharı	930-950	60
Bant 10 - Kısa Dalga Kızılötesi (Cirrus)	1365-1385	60
Bant 11 - Kısa Dalga Kızılötesi	1565-1655	20
Bant 12 - Kısa Dalga Kızılötesi	2100-2280	20

2.1.3. Çiftçi Kayıt Sistemi (ÇKS) ve verileri

ÇKS, Türkiye’de uygulanmakta olan tarımsal desteklemelerin anahtarı konumunda olup, tarıma yönelik planlı, gerçekçi ve sürdürülebilir politikaların hayata geçirilmesinde büyük önem taşımaktadır (Nazlı, 2006). ÇKS, çiftçilere ait kimlik, arazi ve tarımsal üretim bilgilerinin veri tabanında tutulduğu, sürekli güncellenen bu bilgilerin

kontrol edilebildiği, raporlanabildiği, sorgulanabildiği ve içerisinde birçok tarımsal ve hayvansal desteklemeleri içeren bir sistemdir. Tarımsal üretimle uğraşan bütün çiftçilerin desteklerden yararlanması için öncelikle ÇKS'ye kayıt olmaları gerekmekte olup, çiftçilerden tarımsal ve hayvansal varlıkları ile ilgili alınan belgeli bilgiler neticesinde, Türk tarımının envanteri sürekli yaşayan bir veri tabanında tutulmaktadır.

Çiftçi Kayıt Sisteminde:

- Tarımsal üretim yapılan tüm arazilerin kayıt altına alınması,
- Ülke genelinde çiftçilerin özlük ve tarımsal faaliyetlerinin izlenebilmesi,
- Türk tarımının ürün deseninin ortaya çıkarılması,
- Uygulanacak tarımsal politikalarla verimliliğin artması,
- Planlı üretim ile arz fazlası tüketilmeyen ürün stoklarının önüne geçilmesi,
- Destekleme uygulamalarında çapraz ve doğrudan kontrollerin sağlanması,
- Diğer kurum ve kuruluşların bilgi sistemleri ile entegre edilmesi,

hedeflenmiştir. ÇKS'de üreticiler çeşitli desteklerden yararlanabilmekte olup, faydalanabileceği tarımsal destekler ise şunlardır:

- Bitkisel üretim destekleri (fark ödemesi desteği)
- Alan bazlı destekler (mazot, gübre, sertifikalı tohum ve fidan kullanımı, fındık, verim kaybı)
- Telafi edici ödemeler destekleri
- Kırsal kalkınma amaçlı tarımsal destekler
- Hayvancılık destekleri
- Organik ve iyi tarım uygulamaları destekleri
- Diğer tarımsal amaçlı destekler

ÇKS istemi ana hatlarıyla özetlenecek olursa: İşletme sahibi tarafından başvuru dilekçesi ile işletme bilgileri, parsel bilgileri, üretim bilgileri (1. dönem ve 2. dönem) varsa sertifika bilgileri ve çiftçi kayıt formu (Çizelge 2.3) doldurularak il veya ilçe müdürlüklerine teslim edilir. Beyan edilen araziye ait tapu kayıtları ve üretim bilgileri kontrol edilerek ÇKS'ye girişi yapılır. Başvuru evraklarının sisteme girişinden sonra destekleme yılına ait ödeme işlemleri başlamadan önce tarımsal faaliyetler yönetmeliği gereği arazide örnekleme usulü kontrol işlemleri yapılır, bunun yanı sıra bölgeye ait uydu görüntüleri ve uzaktan algılama teknolojileri ile de kontroller sağlanır. Kontrol işlemlerinin tamamlanmasının ardından ödeme icmalleri oluşturulup askıya çıkartılarak

varsa itirazlar değerlendirildikten sonra hak edişler hazırlanıp listeler bankaya gönderilerek çiftçilere ödeme işlemleri yapılmaktadır (Şimşek, 2016).

Çizelge 2.3 Çiftçi kayıt formu örneği

EK-1

ÇİFTÇİ KAYIT FORMU

A- Kişisel Bilgiler

A 1. T.C. Kimlik / Vergi Kimlik No			
A 2. Adı, Soyadı			
A 3. Baba Adı			
A 4. Ana Adı			
A 5. Cinsiyeti			
A 6. Doğum Tarihi (Gün/ay/yıl)			
A 7. Telefon No	Cep : ()	Sabit : ()	
A 8. e-posta	@		
A 9. Başvuru Tarihi			
A 10. Başvuru No			
A 11. Adresi Bilgileri	İkametgah	İşletme	
A 12. İli			
A 13. İlçesi			
A 14. Köy/Mahalle			
A 15. Eğitim Durumu	Okur-yazar ama bir okul bitirmedi ☐	Okuma-yazma bilmiyor ☐	İlkokul ☐
	İlköğretim ☐	Ortaokul veya mesleki ortaokul ☐	Genel lise ☐
	Mesleki veya teknik lise ☐	İki veya üç yıllık yüksekokul ☐	4 yıllık yüksekokul veya fakülte ☐
	5 veya 6 yıllık Fakülte ☐	Yüksek lisans ☐	Doktora ☐

Yukarıda yer alan ve bu form ekinde beyan edilen bilgilerin Bakanlığınız Çiftçi Kayıt Sistemine kayıt talebiyle;
Gereğini arz ederim.


Başvuru Sahibi
İmza

Dosya Kabul Görevlisinin		Veri Giriş Görevlisinin
Adı ve Soyadı		
Unvanı		
Tarih		
İmzası		

Çiftçi kayıt formu ve çiftçi arazi bilgileri formundaki bilgiler ÇKS'ye kaydedildikten sonra veri tabanında tutulan bu sözel verilerdeki her bir parsel için ait özgü Tarımsal No değeri ile sayısal formatta (vektör) bulunan tarım parselleri içerisindeki Tarımsal No (Zemin Id) değerleri eşleştirilerek her bir parsel için beyan ya da beyanlar sayısal formattaki tarım parseli ile ilişkilendirilmektedir.

Çizelge 2.5 Denizli İli Çivril İlçesi 2020 yılı ÇKS belgesi örneği


İl	İlçe	Mahalle	Ada	Parsel	Kul.Alan	Parsel Alan	TarımsalNo	Ürün	Tarım Şekli	Ekilen Alan	Ekim Tarihi	Hasat Tarihi
DENİZLİ	ÇİVRİL	BAYAT	0	1677	30.195	154.857	644258876	ELMA	Sulu	28.000	10.02.2022	15.11.2040
DENİZLİ	ÇİVRİL	BAYAT	0	1679	87.020	142.659	644258851	ELMA	Sulu	87.020	10.02.2022	15.11.2030
DENİZLİ	ÇİVRİL	BAYAT	0	1364	7.420	7.420	232113346	ELMA	Sulu	7.333	10.02.2022	15.11.2040
DENİZLİ	ÇİVRİL	YENİKÖY	169	356	9.386	9.386	232562893	ELMA	Sulu	9.030	15.11.2021	1.01.2026
DENİZLİ	ÇİVRİL	YENİKÖY	172	223	10.257	10.257	99996017	ELMA	Sulu	10.257	15.11.2021	1.01.2026
DENİZLİ	ÇİVRİL	YENİKÖY	172	188	16.335	16.335	99995977	ELMA	Sulu	16.335	15.11.2021	1.01.2026
DENİZLİ	ÇİVRİL	YENİKÖY	172	224	2.162	2.162	99996018	ELMA	Sulu	2.162	15.11.2021	1.01.2026
DENİZLİ	ÇİVRİL	İŞIKLI	229	44	9.712	16.998	637118026	ELMA	Sulu	9.712	15.11.2021	1.01.2026
DENİZLİ	ÇİVRİL	İŞIKLI	263	22	25.652	25.652	232106562	ELMA	Sulu	13.575	15.11.2021	15.11.2030
DENİZLİ	ÇİVRİL	İŞIKLI	263	22	25.652	25.652	232106563	ELMA	Sulu	12.077	15.11.2021	15.11.2030
DENİZLİ	ÇİVRİL	İŞIKLI	226	64	11.578	14.474	232441708	ŞEFTALİ	Sulu	5.149	15.09.2021	1.01.2030
DENİZLİ	ÇİVRİL	İŞIKLI	229	35	2.166	3.793	99896844	ELMA	Sulu	2.166	15.11.2021	15.11.2030
DENİZLİ	ÇİVRİL	YUVAKÖY	152	79	24.637	24.637	100000770	ELMA	Sulu	24.637	15.11.2006	1.01.2026
DENİZLİ	ÇİVRİL	YAHYALI	158	14	14.775	14.775	479370526	ARPA	Sulu	14.775	1.09.2021	1.04.2022
DENİZLİ	ÇİVRİL	YAHYALI	0	732	6.663	6.663	479369878	YONCA	Sulu	6.629	1.04.2019	1.09.2025
DENİZLİ	ÇİVRİL	İMRALI	169	220	20.785	20.785	633188000	CEVİZ	Sulu	18.983	1.11.2013	1.11.2050
DENİZLİ	ÇİVRİL	İMRALI	169	220	20.785	20.785	633188000	ÜZÜM	Sulu	1.802	1.11.2000	1.11.2044
DENİZLİ	ÇİVRİL	İMRALI	182	19	4.021	4.021	633189127	ARPA	Kuru	4.021	1.09.2021	1.04.2022
DENİZLİ	ÇİVRİL	İMRALI	182	28	8.688	8.688	633189115	CEVİZ	Sulu	8.688	1.11.2010	1.11.2040
DENİZLİ	ÇİVRİL	İMRALI	182	5	0.864	0.864	633189086	BUĞDAY	Kuru	0.864	1.10.2021	1.05.2022
DENİZLİ	ÇİVRİL	İMRALI	135	3	25.566	25.566	99904222	ARPA	Kuru	25.566	1.09.2021	1.04.2022
DENİZLİ	ÇİVRİL	İMRALI	113	1	23.357	23.357	99903997	ARPA	Kuru	23.357	1.09.2021	1.06.2022
DENİZLİ	ÇİVRİL	YAHYALI	121	9	13.281	13.281	479370063	MISIR	Sulu	13.281	4.04.2022	1.08.2022
DENİZLİ	ÇİVRİL	YAHYALI	121	9	13.281	13.281	479370063	ARPA	Sulu	13.281	11.11.2021	1.04.2022
DENİZLİ	ÇİVRİL	YAHYALI	0	904	1.350	1.350	479370110	YONCA	Sulu	1.350	1.04.2022	1.04.2026
DENİZLİ	ÇİVRİL	YAHYALI	0	901	0.813	0.813	479369645	YONCA	Sulu	0.813	1.04.2022	1.04.2026
DENİZLİ	ÇİVRİL	YAHYALI	121	15	8.383	8.383	643221404	MISIR	Sulu	8.383	1.04.2022	1.08.2022



Şekil 2.3 ÇKS beyanlı parsellerin gösterimi

2001 yılında Doğrudan Gelir Desteği (DGD) adı altında yaklaşık 12 milyon hektar tarım alanı ve 2.18 milyon çiftçi kayıt altına alınmıştır. 2002 yılında kaydedilen tarım alanı 16.3 milyon hektar, çiftçi sayısı ise 2.56 milyon iken 2003 yıl sonu itibariyle kaydedilen tarım alanı 16.8 milyon hektar, çiftçi sayısı ise 2.77 milyona yükselmiştir. 2001 yılında genel tarım sayımı sonuçlarına göre 3.075.216 adet tarımsal işletmenin %90'ı kayıt altına alınmıştır (Saçlı, 2009).

2005 yılından itibaren daha önce aynı mevzuat kapsamında sürdürülen ÇKS ve DGD uygulamaları ayrıştırılarak farklı mevzuat çerçevesinde yürütülmesine karar verilmiş ve ÇKS'nin muhtelif bitkisel üretim desteklerini kapsayacak şekilde değiştirilerek, bitkisel üretime ilişkin destekleme uygulamalarının dayandığı kapsamlı bir sistem haline dönüştürülmüştür. 2005 yılından itibaren ÇKS'ye kayıtlı çiftçi sayısında düşüş başlamış olup 2022 tarihi itibariyle 2.172.974 çiftçi ile 15.3 milyon hektar tarım arazisi ise kayıtlı durumdadır.



Şekil 2.4 Yıllara göre ÇKS'ye kayıtlı çiftçi sayısı değişimi



Şekil 2.5 Yıllara göre ÇKS'ye kayıtlı tarımsal alan (hektar) değişimi

ÇKS’de 81 Tarım İl Müdürlüğü ile 911 Tarım İlçe Müdürlüğü olmak üzere toplam 992 veri giriş noktası bulunmaktadır. ÇKS’ye başvuruların alınması, başvuruların kontrolü, veri girişi, tespit komisyonları dâhil Bakanlık bünyesinde yaklaşık 15.000 personel bu sistem içerisinde çalışmaktadır. Destekleme ödemelerinin ÇKS üzerinden yapılması neticesinde sistemde kayıtlı yaklaşık 300 farklı tarımsal ürünün kaydı bulunmaktadır. Kaydı bulunan bu ürünler Türkiye İstatistik Kurumu (TÜİK) ile birlikte yapılan bir çalışma ile Avrupa Birliği standartlarına göre sınıflandırması yapılarak kodlanmıştır.

ÇKS’deki kayıtlar birinci ve ikinci ürün bilgisi olarak alınmakta olup arazilerin hissedarlarına ait kimlik bilgileri de veri tabanına eklenmektedir. ÇKS veri tabanında T.C. kimlik numaraları esas kabul edilip kayıtlar yapılmaktadır. Çiftçi Kayıt Sistemi ile T.C. kimlik numaraları kullanılarak çapraz kontroller yapılmakta ve usulsüz kiralamalar ile farklı illerden başvurular var ise söz konusu bu durumlar da önlenmektedir. ÇKS sayesinde destekleme programlarına ilişkin ödeme icmalleri oluşturulmakta olup, nihai ödeme icmalleri ödemelerin yapıldığı T.C. Ziraat Bankası’na on-line olarak aktarılmaktadır (Keser, 2007).

23 Eylül 2022 tarihli ve 32962 sayılı Resmi Gazete’ de yayınlanarak 1 Ekim 2022 tarihinden geçerli olmak üzere “*Tarım ve Orman Bakanlığınca hazırlanan Çiftçi Kayıt Sistemi Yönetmeliğinde Değişiklik Yapılmasına Dair Yönetmelik*” yürürlüğüne girmiş olup ÇKS başvurularında ve yönetmeliğinde önemli değişiklikler olmuştur (URL-1) :

- Yeni bir arazi eklemesi yapmayan (ÇKS dosyasında sadece ürün güncellemesi yapacak olan) çiftçiler ÇKS’ye başvurularını e-Devlet üzerinden yapacak olup, ÇKS’ye ilk defa kayıt olacak veya arazi bilgilerinde değişiklik yapacak çiftçiler İl/İlçe Müdürlüklerine başvuru yapacaktır.
- 1 Eylül – 30 Haziran olan başvuru süresi 1 Eylül – 31 Aralık olarak değişmiştir. Çiftçiler bu tarihten sonra edindikleri veya kiraladıkları tarım arazileri hariç ÇKS’ye yeni bir kayıt yapamayacaklardır.
- ÇKS’ye ilk defa kayıt olacak çiftçilerden ziraat odası çiftçi belgesi istenecek olup, ilk başvuru hariç bu belge zorunlu olmayacaktır.
- Hazine adına tespit ve tescil edilmiş ve/veya Devletin hüküm ve tasarrufu altında olan tarım arazilerini işleyen şahsın bu yeri defterdarlıktan veya mal müdürlüğünden kiraladığına dair kira sözleşme istenecektir.

2.1.4. Tarım Sigortaları Havuzu (TARSİM) ve verileri

TARSİM, sigorta yaptıran çiftçilere, prim desteği sağlanan ve teminat kapsamındaki bir risk nedeniyle, hasar olması durumunda, sigorta prensipleri ve teknikleri çerçevesinde, hasar tazminatı ödemesi yapılan bir sistemdir. Kısacası TARSİM, belirli teknikler ve prensiplere göre çalışan bir sigorta sistemidir. TARSİM'in açılımı "Tarım Sigortaları Havuzu"dur. 14/06/2005 tarihli 5363 sayılı "Tarım Sigortaları Kanunu" kapsamında kurulan Tarım Sigortaları Havuz İşletmesi A.Ş. çiftçilerin ürünlerini oluşabilecek hasarlara karşı güvence alınmasını amaçlamaktadır (URL-2).

TARSİM ile tarım ürünleri, hayvanlar, seralar, arı kovanları, tarımsal yapılar, tarım aletleri ve makineleri sigorta ile güvence altına alınır. Dolu, fırtına, don, hortum, sel, heyelan, taban altı baskını ve deprem, kar ağırlığı (ağaç ve fidanlarda) gibi doğal afetlerin yanı sıra yangın gibi doğal yoldan veya kaza ile oluşan durumlar, zararlılar ve hayvanlarda meydana gelebilen salgın hastalık ve zehirlenmeler sonucu oluşan zararlar TARSİM kapsamındadır. Bunun yanı sıra kuru tarım ürünlerinde (arpa, buğday, çavdar ve bakliyat) ilçe bazlı kuraklık verim sigortası da yapılır (Tarsim, 2018)

Devlet destekli tarım sigortaları sistemi, bitkisel ürün sigortası, sera sigortası, köy bazlı kuraklık verim sigortası, su ürünleri hayat sigortası, arıcılık sigortası, büyükbaş hayvan hayat sigortası, küçükbaş hayvan hayat sigortası ve kümes hayvanları hayat sigortası branşlarında TARSİM hizmet vermektedir. Üreticilerin sigorta yaptırabilmeleri ve devletin prim desteğinden yararlanabilmeleri için :

- Büyükbaş, küçükbaş ve kümes hayvanları için Tarım ve Orman Bakanlığı kayıt sistemine,
- Sera için, Örtü Altı Kayıt Sistemi'ne (ÖKS'ye), su ürünleri çiftlikler için, Su Ürünleri Kayıt Sistemi'ne (SKS'ye)
- Arıcılık için, Arıcılık Kayıt Sistemi'ne (AKS'ye),
- Bitkisel ürünler için ise Çiftçi Kayıt Sistemi'ne

kayıt yaptırmaları ve bu kayıtlarını güncellemeleri gerekmektedir.



Şekil 2.6 TARSİM bitkisel ürün sigortası iş akışı

Bitkisel ürün sigortası yaptırılmış parseller, kayıt altına alınmadan ilgili acenteye ait uzmanlar tarafından arazide ve yerinde kontrol edildiğinden bu parsellere ait bilgiler arazi gerçeğini yansıtmaktadır. Böylelikle hem Denizli hem de Eskişehir bölgesinde bulunan sigortalı parseller arazi gerçeği verisi olarak sınıflandırma çalışmasının doğruluk analizinde test verisi olarak kullanılmıştır. TARSİM’den iki farklı çalışma alanına ait sigortalı parseller resmi yazı yoluyla temin edilmiş olup sözel veriler tarım parselleri ile ilişkilendirilerek sayısal test verisi üretilmiştir.

Çizelge 2.6 Denizli Çivril-Baklan Ovası 2021 yılına ait sigortalı parsel listesi örneği




YIL	İL ADI	İLÇE ADI	KÖY ADI	ADA	PARSEL	ÜRÜN ADI
2021	Denizli	Çivril	Irgıllı	221	339	Haşhaş
2021	Denizli	Çivril	Irgıllı	213	606	Haşhaş
2021	Denizli	Çivril	Irgıllı	213	110	Haşhaş
2021	Denizli	Çivril	Irgıllı	193	35	Haşhaş
2021	Denizli	Çivril	Irgıllı	180	112	Mısır (Silajlık)
2021	Denizli	Çivril	Irgıllı	206	18	Mısır (Silajlık)
2021	Denizli	Çivril	Irgıllı	205	388	Mısır (Silajlık)
2021	Denizli	Çivril	Irgıllı	221	586	Tritikale
2021	Denizli	Çivril	Irgıllı	203	50	Yonca
2021	Denizli	Çivril	Irgıllı	205	148	Yonca
2021	Denizli	Çivril	Irgıllı	220	32	Yonca
2021	Denizli	Çivril	Irgıllı	213	541	Yonca
2021	Denizli	Çivril	İğdir	1148	16	Arpa
2021	Denizli	Çivril	İğdir	132	56	Buğday
2021	Denizli	Çivril	İğdir	1201	63	Buğday
2021	Denizli	Çivril	İğdir	132	72	Buğday
2021	Denizli	Çivril	İğdir	1148	6	Buğday

2.1.5. Arazi Parsel Tanımlama Sistemi (LPIS) ve fiziksel blok kavramı

Entegre İdare ve Kontrol Sistemi (IACS), Avrupa birliği ülkelerinde Ortak Tarım Politikası (OTP) kapsamında verilen desteklemeleri yönetmek amacıyla kullanılmakta olan bir sistemdir. Söz konusu bu sistem; tarımsal desteklemelerin doğru ödenmesini, bilimsel metotlarla izlenmesini, tarım arazilerinin varlığının belirlenerek sınıflandırılmasını, kesin ve değişmez sınırların tanımlanmasını, değişikliklerin takibini, oluşturulacak tek bir veri tabanı ve çapraz kontrollerin yanı sıra saha kontrollerinin de uygulanmasını sağlayan bir sistemdir. Bu sistem teknolojik ilerlemeler, coğrafi bilgi sistemleri ve uzaktan algılama teknolojileri ile daha önemli bir hale gelmiştir. (Keser, 2007). IACS sistemi bilgisayarlı ve birbirine bağlı bir veri tabanından oluşmakta olup, bu veri tabanları destek başvurularını ve ilgili veriyi almada ve işlemede kullanılmaktadır. Böylece;

- Çiftçilere özgü bir tanımlama sistemi,
- Arazi Parsel Tanımlama Sistemi (LPIS) olarak adlandırılan tüm tarımsal alanları kapsayan bir tanımlama sistemi,
- Ödeme hakları için bir tanımlama sistemi,
- Hayvanların kaydı ve kimliklendirilmesi için bir sistem (üye ülkelerde hayvan odaklı önlemlerin uygulandığı yerlerde) sağlamaktadır.

Arazi Parsel Tanımlama Sistemi (LPIS) IACS'ın alt bileşenlerinden biri olup çiftçilerin alan bazlı destek için tarım parsellerini beyan ettikleri, referans parselleri içeren bir coğrafi veri tabanıdır (Erden, 2008). Referans parseller, 1/5000 ölçeğe 30 cm mekânsal çözünürlüğe sahip ortofoto görüntülerden oluşturulmuştur. LPIS kurulumunda ilk olarak referans parsel türünün belirlenmesi gerekmektedir. Avrupa çapında, tarımsal parseli, çiftçi bloğunu, kadastral parseli veya fiziksel bloğu temel alan bir dizi farklı yaklaşımdan yararlanılmıştır. Türkiye'de, ülkenin büyüklüğü ve tarımsal peyzajın doğal yapısı nedeniyle, referans parsel olarak kullanılmak üzere fiziksel blok seçilmiştir. Mülga Gıda Tarım ve Hayvancılık Bakanlığı tarafından IACS projesi kapsamında 1/5000 ölçekli 30 cm çözünürlüklü oluşturulan ortofoto görüntüler üzerinden belirlenen kurallar çerçevesinde fiziksel bloklar çizilip, arazi örtüsü sınıfları belirlenerek ülkesel ölçeğe Arazi Parsel Tanımlama Sistemi (LPIS) oluşturulmuştur.

	Tarımsal Parsel: Bir çiftçinin tek bir bitki ektiği arazi parçasıdır
	Çiftçi Bloğu: Bir çiftçinin birbirinden farklı bitkileri ektiği arazi parçasıdır
	Fiziksel Blok: Birden fazla çiftçi tarafından birden fazla bitki yetiştirmek için kullanılan parselleri içeren, kalıcı sınırlara sahip arazi parçasıdır.
	Kadastral Parsel: Gerçek veya tüzel kişiye ait belli bir geometriye sahip toprak parçasıdır.


Şekil 2.7 Fiziksel blok tanımları

LPIS uyarınca bir fiziksel bloğun kilit özellikleri şunlardır:


- Tüm alan fiziksel bloklarla kaplı olmalıdır, komşu poligonlar arasında boşluk olmamalıdır ve tarımsal peyzaj içerisinde yer alan tüm tarım dışı araziler fiziksel bloklar halinde sayısallaştırılmalıdır.
- Her bir fiziksel blok, önceden tanımlı bir arazi örtüsü sınıfına sahiptir ve bir kimlik numarası bulunmaktadır.
- Her fiziksel bloğa ortalama 15 tarım parselinin düşmesi ve her bir bloğun ortalama olarak 20 ha (200 da) büyüklüğünde olması gerekmektedir.
- Fiziksel bloklar genellikle homojen olmalı ve tek bir arazi sınıfına sahip olmalıdır. Bununla birlikte nadiren de olsa bir fiziksel blok kendi sınırları içerisinde farklı tarımsal sınıfa ait arazileri de içerebilir ancak bu arazilerin alanları tüm fiziksel bloğun alanının %10'undan fazla olmamalıdır.
- Fiziksel bloklar mutlaka tarıma elverişli alanların dâhil edileceği şekilde oluşturulmalıdır.
- Tarımsal fiziksel blokların boyutu en az 0.05 ha olmalıdır.
- Tarıma elverişli olmayan bloklar, çok büyük boyutlu poligonlardan kaçınmak amacıyla isteğe bağlı olarak bölünebilmelidir.

Mülga Gıda Tarım ve Hayvancılık Bakanlığı tarafından IACS projesi kapsamında 1/5000 ölçekli 30 cm çözünürlüklü oluşturulan ortofoto görüntüler üzerinden belirlenen


kurallar çerçevesinde fiziksel bloklar çizilip, arazi örtüsü sınıfları belirlenerek ülkesel ölçekte Arazi Parsel Tanımla Sistemi (LPIS) oluşturulmuştur.



Şekil 2.8 LPIS kapsamında oluşturulan arazi örtüsü sınıfları (LPIS Guideline, 2015)



Şekil 2.9 Fiziksel bloklar ile tarım parsel ilişkisi-1 (LPIS Guideline, 2015)



Şekil 2.10 Fiziksel bloklar ile tarım parsel ilişkisi-2 (LPIS Guideline, 2015)

LPIS projesi kapsamında üretilen fiziksel bloklardan çalışma alanına giren ilgili sınıflar, piksel tabanlı sınıflandırma sonucunun maskelenmesi işleminde kullanılmıştır.

2.2. Yöntem


2.2.1. Makine öğrenmesi kavramı

Makine öğrenmesi, matematiksel ve istatistiksel işlemler yardımıyla veriler üzerinden çıkarım yaparak tahminlerde bulunan sistemlerin bilgisayarlar ile modellenmesidir. Makine öğrenmesi yapay zekânın bir alt kümesi olup tespitler ve tahmin yoluyla otomatik olarak gerçekleştirilebilen bilgisayar programlarının geliştirilmesi üzerine çalışan bu teknoloji; bilgisayar sistemlerinin deneyimlerine, öğrenmesine ve geliştirilmesine odaklanmaktadır (URL-3).

Makine öğrenmesi uygulamalarının genel olarak çalışıldığı konu, bilgisayarlar karmaşık örüntü ve veriye dayalı çıkarım yapabilme becerisi kazandırmaktadır (Bilgiöglü, 2018). Makine öğrenmesi çeşitli algoritmalarından oluşmaktadır. Tahminler ve karar vermek için öğrenme verileri olarak bilinen test verilere dayalı bir matematik model oluşturur. Makine öğrenme algoritmaları, görevleri yerine getirmek üzere geleneksel algoritmalar geliştirmenin zor veya mümkün olmadığı filtreleme, katsayılar ve değişken fonksiyonların çok çeşitli uygulamalarında kullanılmaktadır (Mitchell, 1997).

Makine öğrenmesi için kullanılabilecek çok sayıda model ve algoritma bulunmakta olup, yapılacak çalışmanın başarısı için tercih edilecek olan algoritmanın

doğru seçilmesi çok önemlidir. Makine öğrenme modelleri işlevlerine göre üç ana başlıkta toplanmakta olup bunlar; sınıflandırma, kümeleme ve birliktelik kurallarıdır.




Şekil 2.11 Makine öğrenmesi modelleri

2.2.2. Makine öğrenmesi algoritmaları

2.2.2.1. Karar ağacı (Decision tree)

Karar ağacı algoritması tümevarımsal algoritmalarından biri olup, hem regresyon hem de sınıflandırma problemlerinde kullanılır. Bu model, her yaprak düğümünün bir sınıf etiketine karşılık geldiği ve özniteliklerin ağacın iç düğümünde temsil edildiği sorunu çözmek için ağaç odaklı çalışmaktadır.

Karar ağacının çalışma prensibi böl ve yönet stratejisine dayanmakta olup, uygulamada kolay ve az bir ön bilgiye ihtiyaç duymaktadır. Karar ağacı ile çok fazla öz nitelik değerine sahip her boyutta veri seti oluşturulabilir. Eğitim örnek setinin başarılı bir şekilde bölünmesi alt örnek setlerinde tek bir sınıf örneği kalan kadar devam etmektedir (Farid ve ark. 2013).




Şekil 2.12 Karar ağacı örneği

2.2.2.2. Destek vektör makineleri (Support vector machine)

Destek vektör makineleri, farklı sınıfları ayırmak ve sınır marjını en üst düzeye çıkarmak için kullanılan denetimli bir öğrenme algoritmasıdır (Carrizosa vd. 2017). Destek vektör makineleri sınıflandırma ve regresyon için kullanılan ilgili denetimi öğrenme yöntem kümesidir. Her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneği verildiğinde, algoritma yeni bir örneğin bir kategoriye mi yoksa diğerine mi düştüğünü tahmin eden bir model oluşturur. Destek vektör makineleri, ikili sınıflandırıcıları birleştirme ve çok sınıflı öğrenmeyi dâhil etmek için ikili programı değiştirme şeklinde iki farklı sınıflandırma yöntemini kullanılır.

Destek vektör makineleri geleneksel yöntemlerden daha yüksek sınıflandırma doğruluğu üretmektedir (Mantero ve ark. 2005). Bu model verilerin olasılık dağılımı üzerine önceden yapılmış varsayımlar olmaksızın, görünmeyen veriler üzerinde sınıflandırma hatasını en aza indirmektedir.




Şekil 2.13 Destek vektör makineleri örneği

2.2.2.3. Rastgele orman (Random forest)

Birden çok karar ağacı üzerinden her bir karar ağacını farklı bir gözlem örneği üzerinde eğiterek oluşturan modeldir. Rastgele orman algoritması tek karar ağacı algoritmasına göre çoğunlukla daha doğru sonuç vermektedir. Rastgele orman ağacı; topluluk çeşitliliğini kazanmak, temel klasörü oluşturmak ve temel sınıfları birleştirmek olmak üzere üç ana aşamadan oluşmaktadır. Hata oranı karar ağacı sınıflarının gücüne ve ağaçlar arasındaki korelasyona bağlı olup, tek tek ağaçların gücünü artırmak ormanın doğruluğunu yukarı çıkarırken, korelasyon arttıkça hata oranı da artmaktadır (Breiman, 2001)

Rastgele orman algoritmasında ağaç sayısı (ntree) ve rastgele özellik seçimi (mtry) olmak üzere iki parametre kullanılmakta olup bu parametreler kullanıcı tarafından belirlenebilmektedir. Ağaç sayısı (ntree) arttıkça karar ormanı büyümekte iken “mtry” parametresi değişken sayısının karekökü alınarak artmaktadır. Rastgele ormanın oluşturulma sürecinde eğitim veri setinin 2/3’ü karar ağacını oluşturmak kullanılmakta olup 1/3’ü ise dışarda bırakılarak ağacın yapımında kullanılmaz. Dışarda bırakılan bu veri setine Out of Bag (OBB) adı verilir ve doğruluğu belirlemek için bu veri seti kullanılmaktadır.



Şekil 2.14 Rastgele orman örneği

2.2.2.4. Gradyan artırma (Gradient Boosting)

Gradyan artırma, regresyon ve sınıflandırma problemleri için bir makine öğrenme modelidir. Model özellikle büyük ve karmaşık veri kümelerinde tahmin hızı ve doğruluğunu ile öne çıkmaktadır. Algoritma modelleri sırayla oluşturarak, sonraki oluşturulacak modeller önceki modelin hatalarını azaltmaya çalışacak şekilde tasarlanmıştır. Her yanlış sınıflandırma hatasını kullanarak tek bir güçlü sınıflandırma aracı üretmek için birçok sınıflandırma aracını birleştirir. Veri seti her tekrar serisinde oluşturulan temel sınıflandırma araçlarının ağırlıklı tahminlerinin oylaması sonucu sınıflandırılır (Farid,2013).

Gradyan artırma algoritmasında doğru sınıfların eğitim örneklerinin ağırlıkları düşerken sınıflandırılan örneklerin ağırlıkları güçlenir. Söz konusu bu durum sınıflandırma aracının devamlı iterasyonla sınıflandırması zor olan örneklerle odaklanmasına zorlar (Farid,2013).

2.2.2.5. Aşırı gradyan artırma (Extreme gradient boosting)


Aşırı gradyan artırma algoritması, gradyan artırma algoritmasının çeşitli düzenlemeler ile optimize edilmiş daha yüksek performans gösteren halidir. Algoritma karar ağaç tabanlı bir algoritma olup, yüksek tahmin gücü elde edebilmesi, aşırı öğrenmenin (overfitting) önüne geçebilmesi, boş verileri yönetebilmesi, paralel çalışabilmesi ve tüm bunları hızlı yapabilmesi algoritmanın en önemli özelliklerindendir. İşlenmesi zor verilerle bilinen en iyi sonuçları elde etmek için birçok alanda kullanılmaktadır. Algoritma düşük doğruluğa sahip zayıf sınıflandırıcı serileri birleştirerek daha iyi bir sınıflandırma performansı ile güçlü bir sınıflandırıcı oluşturmaktadır (Chen ve Guestrin, 2016).

Ağaç tabanlı öğrenme algoritmalarını kullanan bir başka algoritma hafif gradyan artırma makineleri (Light GBM) modelidir. Diğer boosting algoritmaları ile karşılaştırıldığında, büyük verileri işleyebilmesi, yüksek tahmin oranı, paralel öğrenme, daha az kaynak (RAM) kullanımı, yüksek işlem hızı ve GPU öğrenimi desteklemesi gibi avantajları bulunmaktadır. Light GBM algoritması bölüm 3.3.1’de detaylı olarak anlatılmaktadır.

2.2.3. Earth Observation (EO-Learn) makine öğrenmesi kütüphanesi

EO-Learn, veri bilimi, coğrafi bilgisi sistemleri, dünya gözlem ve uzaktan algılama çalışmalarında makine öğrenmesini ve derin öğrenme algoritmalarını kullanan açık kaynak kodlu bir python kütüphanesidir. Kütüphane üzerinden amazon web servislerine erişilerek (AWS) başta Sentinel-2 uydusuna ait görüntüler olmak üzere birçok uzaktan algılama uydusuna ait ticari olan (Spot-Pleadies-WorldView-2-3) ve ticari olmayan (Landsat-Modis-Envisat) uydu görüntülerine erişim sağlanmaktadır (URL-4). Kütüphane içerisindeki modüler python paketleri ve alt paketleri ile birbirine bağlı ve entegre iş akışları sayesinde, büyük ölçekteki alanlarda, görüntü işleme ve uzaktan algılama uygulamaları kolay hızlı ve otomatik olarak yapılabilmektedir (Jarray ve ark, 2021). EO-Learn kütüphanesinin ana amacı, büyük miktardaki ve çeşitteki verinin otomatik ve hazır iş modelleri ile çalışmasıdır. Açık kaynak kodlu bir kütüphaneye sahip olan bu kütüphaneye kullanıcılar tarafından yeni görevler ve iş akışları da eklenebilmektedir (URL-5).


EO-Learn kütüphanesi istenilen tarih aralığında uydu görüntülerinin indirilmesi, indirilen görüntüleri üzerindeki bulutlu alanların otomatik olarak tespiti ve maskelenmesi, görüntülere ait bantlarla istenilen indekslerin oluşturulması (NDVI, NDWI, SAVI), farklı çözünürlükteki bantların yeniden örneklendirilmesi ve birleştirilmesi gibi görüntü işleme adımlarını özellikle büyük alanlarda dahi yeterli donanıma sahip bilgisayarla kolaylıkla yapılabilmektedir (URL-6). Arazi örtüsü sınıflandırması, tarımsal ürün desen sınıflandırması, obje tabanlı sınıflandırma, parsel sınırlarının otomatik tespiti, detay çıkarma, çözünürlük artırma gibi karmaşık uzaktan algılama çalışmaları, yine kütüphane içerisinde var olan ve kullanıcılar tarafından geliştirile bilinen hazır iş modelleri ile makine öğrenmesi ve derin öğrenme algoritmaları yardımıyla 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-7). Bunun yanı sıra kullandığı başlıca kütüphaneler; gdal, rasterio, shapely, fiona, cartopy ve pyproj kütüphaneleridir (URL-8). EO-Learn kütüphanesi EO-Patch, EO-Task ve EO-Workflow olmak üzere 3 ana paketten oluşmaktadır. Bu ana paketlerin içerisinde bulunan farklı işlevler gören alt paketler bulunmakta olup, kullanıcılara tüm kütüphaneyi kurmak yerine ihtiyaç duyduğu işleme göre alt paketlerden bir ve birkaçını kurma imkânı da sağlamaktadır (URL-4).



Şekil 2.15 Eo-Learn kütüphanesi ile küresel ölçekte su rezervlerini tespiti için oluşturulmuş örnek iş akışı (URL-7)


2.2.3.1. EO-patch

Uydu görüntüleri ve türevleri gibi çok zamanlı raster veriler için temel veri nesnesi olup görüntülere ait bütün bilgiler (bantlar, bantlardan oluşturulan indeks ve dönüşümler, bulut maske özellikleri vb.) numpy formatında dizi nesnesi olarak her bir EO-Patch’ de depolanmaktadır (URL-9). EO-Patch’lerde raster verinin yanı sıra vektör veriler de depolanabilmekte olup her bir EO-Patch raster (data, mask, scalar, label, data_timeless, mask_timeless, scalar_timeless, label_timeless), vektör (vector, vector_timeless), meta data, tarih bilgisi ve koordinat bilgisi özelliklerini de içinde barındırmakta olup, bu veriler makine öğrenmesiyle sınıflandırma işlemlerinde modeli oluşturmak için de gereklidir (URL-10).



Şekil 2.16 EO-Patch’de raster ve vektör formatında tutulan veri örneği (URL-10)

Özellikle orta ölçekli ve büyük ölçekli yapılacak sınıflandırma çalışmalarında hem alanın büyüklüğü hem de tarımsal ürün desen sınıflandırması gibi çok zamanlı birçok görüntünün kullanılacağı durumlarda, sınıflandırma öncesi görüntü işleme işlemleri ile sınıflandırma işlemini çalışma alanının tamamını kapsayacak şekilde bir bütün olarak yapmak, hem görüntü işleme adımlarında hem de karmaşık makine öğrenme algoritmalarıyla çok zaman almasının yanı sıra yüksek donanıma da ihtiyaç duyulmasına sebep olmaktadır. Bu sebeple çalışma yapılacak alan bölümlenmelere ayrılarak (EO-Patch), görüntülerin temin edilmesi de dâhil olmak üzere bütün görüntü işleme adımları (atmosferik düzeltme, bulutlu alanların belirlenmesi ile maskelenmesi çeşitli indeks ve özellik çıkarımları, bantların ve özelliklerin birleştirilmesi) ve makine öğrenmesi ile sınıflandırma çalışması her bir EO-Patch’de bağımsız olarak yapılır ve son aşamada birleştirilir. Bölümlenmelere ayrılarak içerisindeki alt kütüphaneler ile belirli bir iş akışında yapılan bu çalışma klasik yöntemlere göre çok daha hızlı ve yüksek donanım kapasitesi gerekmeksizin çalışma yapılmasına olanak sağlamaktadır. Çalışması yapılacak alanın büyüklüğü, sınıflandırılacak ürün çeşidi ve fenolojisi, temin edilecek görüntülerin tarih aralığı ve işlem yapılacak bilgisayarın donanımı gibi değişkenler göz önüne alınarak, kullanıcı tarafından optimum EO-Patch boyutu belirlenebilmektedir (5*5km – 10*10 km).



Şekil 2.17 Bir çalışma alanına ait Eo-Patch'lerin görünümü (URL-11)

2.2.3.2. EO-task

EO-Patch örnekleri üzerindeki herhangi bir işlem EO-Task'lar tarafından gerçekleştirilmekte olup kapsamlarına göre gruplandırılmış aşağıdaki python alt paketleri kullanılmaktadır (URL-12).

- **eo-learn-core:** Temel yapı taşlarını (EO-Patch, EO-Task, EO-Workflow) ve yaygın olarak kullanılan işlevleri uygulayan alt pakettir.
- **eo-learn-io:** Sentinel-hub hizmetlerinden ve Geopedia'dan veri almakla ilgilenen alt paket olup aynı zamanda GeoTIFF dosyasında Eo-Patch'e veri aktarımını sağlamaktadır.
- **eo-learn-mask:** Sen2cloudless paketi ile bulutlu görüntülerin tespit edilmesi ve maskelenmesinden kullanılan pakettir.
- **eo-learn-feature:** Görüntülere ait bantları kullanarak NDVI, NDWI, MSAVI vb. indeksleri oluşturan ve bunları işleyen alt pakettir.
- **eo-learn-geometry:** Super piksel segmentasyonu, vektör ile raster veri arasından dönüşüm yapan alt pakettir.
- **eo-learn-ml-tools:** Makine öğrenmesi için eğitim ve test verilerini seçmek, makine öğrenme modeli kurmak veya doğrulamak için kullanılan alt pakettir.

2.2.3.2. EO-workflow

Eo-Patch'ler ve EO-Patch'ler üzerinde kapsamına göre işlem yapacak EO-Task'lar seçilerek yapılacak çalışmaya göre iş akışı oluşturmayı sağlayan python paketidir. EO-Workflow'da oluşturulan iş akışı, çalışmanın raporları ve log dosyaları da içerisinde oluşturup saklamaktadır.

3. UYGULAMA

3.1. Uydu Görüntüsü İşleme ve Özellik Oluşturma

3.1.1. Çok zamanlı Sentinel-2 görüntülerinin temini

Tarım alanları dinamik bir arazi örtüsüne sahip olup ürünlerin yıl içerisindeki gelişimleri farklılık göstermektedir. Ürün desen sınıflandırmasında ürünlerin ekim, çimlenme, kardeşlenme, olgunlaşma, gelişim ve hasat tarihlerinde görüntü alımı yapılması ürünler arasındaki fenolojik değişimin ortaya çıkartılmasında çok önemli bir rol oynamaktadır.


Fenolojik süreçleri farklı ürünler tek bir görüntüde yakın spektral yansıma değeri verebilecek olup, tarımsal ürün desen tespitinde tek görüntü ile yapılan sınıflandırma çalışmalarında yüksek başarı oranı sağlanamamaktadır. (Siachalou ve ark 2015).

Tarımsal ürün deseni sınıflandırmasında farklı zamanlarda alınan birden çok uydu görüntüsü ile yapılan sınıflandırma sonucunun tek bir uydu görüntüsü ile yapılan sınıflandırma sonucuna kıyasla daha yüksek doğruluk verdiği bilinmektedir (Gómez ve ark, 2016 ; Long ve ark. 2013). Çok zamanlı görüntülerle yapılan tarımsal ürün desen sınıflandırmasının başarı oranı, tek zamanlı görüntü ile yapılan sınıflandırma sonucuna kıyasla daha yüksek doğruluk vermektedir. Özellikle zaman serisi olarak NDVI gibi bitki indekslerinin kullanılması, tarımsal ürünlerin sınıflandırmasında benzer fenolojik süreçleri olan sınıfların birbirinden ayrılmasını da sağlamaktadır (Viana ve ark, 2019).

Çalışmada kullanılan Sentinel-2 görüntüleri, açık kaynak kodlu EO-Learn kütüphanesinin alt paketlerinden biri olan ‘Sentinelhub-py’ paketi kullanılarak indirilmiştir (URL-13). Sentinelhub-py paketi ile Amazon S3 bulutta depolanan Sentinel-L1C ve Sentinel-L2A görüntüleri ile farklı uydulara ait farklı formattaki görüntülere erişim sağlanabilmektedir (URL-14).

Sentinelhub-py paketi ile çalışmada kullanılacak Sentinel-2 görüntülerine ait başlangıç tarihi, bitiş tarihi, çekim aralığı, formatı ve ilgili bantlar gibi özellikler belirlenerek, görüntüler zaman serisi halinde bütünleşik ve görüntü katmanı olarak bölümlenmelere (EO-Patch) ayrılmış bir şekilde temin edilmiştir.

Çalışmada Denizli Çivril-Baklan Ovası'nda 2017-2018-2019-2020 ve 2021 yılları için, Eskişehir Çifteler Bölgesinde Sakaryabaşı Sulama Birliği'ni kapsayan alanda ise 2019 ve 2020 yılları için 1 Ocak -31 Aralık tarihleri arasında kalan Sentinel-2 L1C seviyesinde 15 gün aralıklı 10*10 km boyutlu, bölümlemelere (EO-Patch) ayrılmış 24 farklı görüntü her yıl için temin edilmiştir (Şekil 3.1).



Şekil 3.1 Çalışma alanına giren EO-Patch'lerin görünüm

Çizelge 3.1. Sınıflandırmada kullanılacak EO-Patch' in özellikleri


Year	: 2020
Time period	: 15 days
Start date	: 01.01.2019
End date	: 31.12.2020
Level	: L1C
Band feature	: BANDS-S2-L1C
Band resolution	: 10
Cloud mask feature	: CLM
Multi temporal cloud feature	: CLM
Area field name	: civril.geojson
Area buffer	: 0.1
Patch size x	: 10000
Patch size y	: 10000

3.1.2. Atmosferik düzeltme


Sentinel-2 L1C görüntüleri sayısal yükseklik modeli kullanılarak ortorektifiye edilmiş ve geometrik düzeltme işlemi yapılmış görüntüler olup, bu görüntüler için ön işleme işlemi olarak sadece atmosferik düzeltme işlemi gereklidir (Feng ve ark. 2019).

Çalışma alanına ait uydu görüntüleri temin edildikten sonra, algılayıcı tarafından kaydedilen görüntülerin atmosferik etkilerinin azaltılması ve görüntüdeki piksel parlaklık değerlerinin (dijital değerler) yüzey yansıtım değerlerine dönüştürülmesi gerekmektedir (Kim ve Lee, 2005). Bu işlem atmosferik düzeltme işlemi olarak adlandırılıp, algılayıcı tarafından kaydedilen piksel değerleri yersel spektral yansıtma değerleri ile spektral olarak karşılaştırılabilir birime dönüştürülmektedir (Arslanoğlu, 2019).

Atmosferik düzeltme işlemi için Simplified Method for the Atmospheric Correction (SMAC), Radiative Transfer Code (S6) ve Sen2core başlıca bilinen atmosferik düzeltme metotlarına dayanan uygulamalar olup, Avrupa Uzay Ajansı tarafından geliştirilen Sen2core uygulamasının diğer uygulamalarla kıyaslandığında daha yüksek doğruluğu verdiği tespit edilmiştir (Feng ve ark. 2019). Tez çalışmasında ise EO-Learn kütüphanesinin kendi atmosferik düzeltme uygulaması kullanılarak TOA Top of Atmosfer (TOA) L1C atmosfer üstü yansıtım değerleri Bottom Of Atmosfer (BOA) L2A yüzey yansıtım değerlerine dönüştürülmüştür.



Şekil 3.2 Atmosferik düzeltme işlemi (Denizli Çivril-Baklan Ovası)



Şekil 3.3 Atmosferik düzeltme işlemi (Eskişehir-Çifteler)

3.1.3. Bulutlu alanların belirlenmesi ve maskelenmesi

Sentinelhub-py paketi ile çalışma alanını kapsayan Sentinel-2 görüntüleri, başlangıç tarihi, bitiş tarihi ve görüntü alım sıklığı belirlenerek zaman serisi halinde bütünleşik olarak indirilmiş olup, çalışma alanına ait bir görüntünün bulutluluk oranı %30'dan fazla ise otomatik olarak çalışma dışında tutulmakta ve bu oran kullanıcı tarafından değiştirilebilmektedir. Bu eşik değerinin üstündeki görüntüler otomatik olarak elemine edilse de bulut içeren diğer görüntülerdeki alanların tespit edilip maskelenmesi sınıflandırma öncesi gereklidir.


Optik uzaktan algılamanın önemli sınırlandırmalarından biri, görüntü çekimi sırasında atmosferik koşullardan kaynaklanan problemlerdir. Uydu görüntülerinde atmosferik koşullardan ortaya çıkan bulutlar, yoğun sis grupları ve bunlardan oluşan gölgeler, görüntülerin analiz edilmesinde problem oluşturan ana gürültü kaynaklarından biridir (Kalkan ve Maktav 2016b). Bulutlardan kaynaklı parlaklıklar ve bulutların oluşturduğu gölgeler veri analizini olumsuz etkilemektedir. Bu etkiler NDVI (Normalize Difference Vegetation Index), NDWI (Normalize Difference Water Index) vb. indekslerde değerlerin değişmesine, sınıflandırma işlemleri ve çeşitli analizlerde başarımın düşmesine sebep olmaktadır (Zhu ve Woodcock 2012). Bu hataların elemine edilmesi için bulutlu alanlar otomatik olarak tespit edilerek maskelenmektedir.

Görüntülerin çekilme anına bir daha dönülemeyeceğinden, bulutsuz bir görüntü temin etmek önemli bir süreç haline gelmektedir (Kalkan ve Maktav, 2016a). Çalışmada EO-Learn kütüphanesi içerisindeki 'Sen2Cloudless' python paketi kullanılarak uydu


görüntüsü üzerindeki bulutlar tespit edilmiş ve maskelenmiştir. Zaman serisi olarak alınan görüntülerin uzun süre zarfında bulutlu olması ürün desen sınıflandırmasında özellikle belirli fenolojik aralıkta olan ürünlerin tespit edilememesi ya da yanlış tespit edilmesine sebep olabilmektedir. Bu durumu ortadan kaldırmak için çalışmada bulutlu alanların tespit edilip maskelenmesi işleminden sonra anomali olan piksel değerleri, kendisinden önceki ve sonraki görüntülere ait piksel değerleri referans alınıp enterpole edilerek düzeltilmiştir. Aynı işlem indeksler için de uygulanmıştır.

3.1.3.1. Sen2Cloudless

Sen2Cloudless, hafif gradyan makine öğrenme algoritmasını (LightGBM) kullanarak çalışan bir bulut belirleme modelidir (URL-15). Sinergise firması tarafından oluşturulan bu model küresel ölçekte büyük bir veri seti kullanılarak eğitilmiş olup, diğer birçok algorithmadan farklı olarak kullanıcı tarafından belirlenen değişkenler ve geometrilerle Sentinel-2 reflektans değerleri üzerinden çalışarak doğru sonuçlar vermektedir. Algoritmada bulut olasılık haritası bir eşik değeri belirlenerek (threshold) bulut maskesine dönüştürülür (Skakun ve ark. 2022). Piksel tabanlı çalışmakta olan model B01, B02, B04, B05, B08, B8A, B09, B10, B11, B12 bantlarını kullanarak çalışmaktadır (URL-15).



Şekil 3.4 Sen2Cloudless modeli ile bulutlu alanların belirlenmesi ve maskelenmesi



Şekil 3.5 Parseldeki NDVI değerinin, bulut maskesiz, bulut maskeli ve enterpole edilmiş değerlerinin zaman serisi olarak değişimi

3.1.4. İndekslerin oluşturulması ve Tasseled Cap dönüşümleri

Bulutlu alanların belirlenip maskelenmesinden ve spektral değerlerin enterpole edilmesi işlemlerinden sonra sınıflandırmada kullanılacak girdi verilerin belirlenmesi gerekmektedir. Özellikle tarımsal alanların tespiti ve izlenmesinde, kırmızı bant kırmızı bant ile klorofile duyarlı olmaları sebebiyle yakın kızıl ötesi veya kırmızı kenar spektral bantları ve bu bantlardan oluşturulan bitki indeksleri başarılı sonuçlar vermektedir (Eitel ve ark, 2011). 10 metre mekânsal çözünürlüklü; mavi (B02), yeşil (B03), kırmızı (B04) , yakın kızılötesi (B08), spektral 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) spektral bantları girdi bantları olarak kullanılmıştır.

Makine öğrenmesi algoritmaları kullanılarak ürün desen sınıflandırmasında sınıfların birbirinden ayırt edilebilirliğini arttırmak bir başka deyişle sınıflandırma doğruluğunun istenilen yüksek doğrulukta olmasını sağlamak amacıyla, uydu görüntülerine ait spektral bantlar dışında girdi olarak ek veriler de kullanılmaktadır (Üstüner ve ark, 2015). Ürün desen sınıflandırması gibi çok zamanlı uydu görüntüleri kullanılarak yapılan çalışmalarda, sınıflandırmanın doğruluğu belirlenen algoritma, kullanılan uydu görüntülerine ait spektral bantlar ve bu bantlardan oluşturulan indekslere de bağlıdır (Lu ve Weng, 2007). NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi), NDWI (Normalize Edilmiş Su Farkı İndeksi), SAVI (Normalize Edilmiş Toprak Ayarlı Bitki İndeksi) işlemi için girdi veri olarak kullanılmıştır.

3.1.4.1. Normalize edilmiş fark bitki örtüsü indeksi (NDVI)

Uzaktan algılamada bitki örtüsünün izlenmesinde en çok kullanılan yöntemlerden biri NDVI analizi olarak adlandırılan, normalize edilmiş fark bitki örtüsü indeksidir. NDVI analizi yardımıyla özellikle geniş alanlardaki bitki örtüsünün gelişiminin ve değişiminin gözlemlenmesi, bitki örtüsünün tahribatı, kuraklığın belirlenmesi vb. çalışmalarda kullanılmaktadır.

NDVI indeksi için kırmızı ve yakın kızılötesi spektral bantları kullanılmaktadır. Her piksel için piksele ait yakın kızılötesi bant sayısal değerinden aynı piksele ait kırmızı bant sayısal değeri çıkartılır. Bu fark, bitki örtüsü yoğun alanlar için bitki örtüsü seyrek alanlara göre daha fazla olacaktır. Farkları alınan bu iki sayının toplanması ve farkın toplama bölünmesi ile $[-1,+1]$ aralığında bir değer elde edilir. Bitki örtüsünün yoğun olduğu alanlarda NDVI değeri +1 değere yaklaşırken, bitki örtüsünün zayıf olduğu, çıplak ve toprak alanlarda 0 değerine, kar bulut ve su yüzeyi ile kaplı alanlarda ise -1 değerine doğru bir yönelim olmaktadır (Hatfield ve ark, 1985).

$$NDVI = (NIR-RED) / (NIR+RED) \quad (\text{Rouse ve ark, 1974})$$




Şekil 3.6 NDVI görüntüsü, 25.01.2020 tarihli Denizli Çivril-Baklan Ovası örneği

3.1.4.2. Normalized Difference Water Index (NDWI)

Normalized Difference Water Index, su alanlarının tespiti, değişiminin incelenmesi, kayıp su alanlarının hesaplanması ve kuraklık izlenmesi için kullanılan bir analizdir (Çağlayan ve ark. 2020). Yeşil spektral bant ile yakın kızıl ötesi bant kullanılarak su kütlesini tespit eden bu indeks, yakın kızıl ötesi spektral bant ve kısa dalga kızılötesi (SWIR) spektral bantlarını kullanarak bitkilerin yapraklarında bulunan su içeriğindeki değişiklikleri izlemek için de kullanılır (Gao, 1996).

Her piksel için o piksele ait yakın kızılötesi bant sayısal değerinden aynı piksele ait kısa dalga kızılötesi sayısal değeri çıkartılır. Farkları alınan bu iki sayının toplanması ve farkın toplama bölünmesi ile $[-1,+1]$ aralığında bir değer elde edilir. Su içeriği ve kütlesi bulunan alanlar +1 değere yaklaşırken 0 ile -1 aralığındaki değerler su içeriği olmayan alanları temsil etmektedir.

$$NDVI = (NIR-SWIR) / (NIR+SWIR) \text{ (Gao, 1996)}$$




Şekil 3.7 NDWI görüntüsü, 25.01.2020 tarihli Denizli Çivril-Baklan Ovası örneği

3.1.4.3. Toprak dengelenmiş bitki örtüsü indeksi (SAVI)

Toprak düzeltilmiş bitki örtüsü indeksi, toprağın uzaktan algılanan bitki örtüsü üzerindeki etkisini sınırlayan bitki örtüsü indeksidir (Huete, 1988) . Bu indeks vejetatif örtü düşük olduğunda toprak parlaklığının etkisini düzeltmek için NDVI indeksinin modifikasyonu olarak geliştirilmiştir.

SAVI indeksi için kırmızı ve yakın kızılötesi spektral bantları kullanılmaktadır. SAVI indeksinde toprak düzeltme faktörü olarak L değeri kullanılmaktadır. L değeri Çok yoğun bitki örtüsüne sahip alanlarda L=0, yeşil bitkisi örtüsü olmayan alanlarda ise L=1 değerini almakta olup, çalışmalarda çoğunlukla L=0.5 değeri kullanılmaktadır.

$SAVI = ((1 + L) * (NIR - RED) / (NIR + RED + L))$ (Huete, 1988)



Şekil 3.8 SAVI görüntüsü, 25.01.2020 tarihli Denizli Çivril-Baklan Ovası örneği

3.1.4.4. Tasseled Cap

Uydu verilerinin spektral bilgilerini spektral göstergelere dönüştürmek için bir yöntem olup özellikle vejetasyon analizinde kullanılmaktadır (URL-16). Bu dönüşüm yöntemi ilk defa Landsat MSS görüntüleri üzerinden tarım arazilerinin izlenmesi


çalışmasında kullanılmıştır (Kauth ve Thomas 1976). Tasseled Cap dönüşümü, görüntüdeki atmosferik etkileri ve gürültü bileşenlerini azaltarak daha doğru analiz sağlanmasının yanı sıra bitki örtüsü, toprak ve suni yapılardaki değişiklikleri tespit etmek için farklı sensörlerden alınan uydu görüntülerini kullanarak arazi örtüsü özelliklerini doğrudan karşılaştırmak için analitik bir yol da sağlamaktadır (URL-17).

Uydu görüntülerinin ilgili bantlarını kullanarak vejetasyon indekslerini zenginleştiren dönüşümünde kullanılan katsayılar belli algılayıcılar için sabit ve değişmezdir (Schowengerdt, 2006). Tasseled Cap dönüşümünde multispektral battan gelen veri üç ana bileşene indirgenir bunlar; parlaklık, yeşillik ve ıslaklık. Sentinel-2 görüntüsünün B02, B03, B04, B08, B11ve B12 spektral bantları kullanılarak parlaklık (TCB), yeşillik (TCG) ve ıslaklık (TCW) indislerinin üç eksen boyunca dönüşümü sağlanarak, Tasseled Cap dönüşümleri yapılmıştır (Chen ve ark, 2020).

$$TCB = 0.3037*B2 + 0.2793*B3 + 0.4743*B4 + 0.5585*B5 + 0.5082*B6 + 0.1863*B7 \text{ (Ros ve ark, 2021)}$$

$$TCG = -0.2941*B2 - 0.243*B3 - 0.5424*B4 + 0.7276*B5 + 0.0713*B6 - 0.1608*B7 \text{ (Tane ve ark 2018)}$$

$$TCW = 0.1511*B2 + 0.1973*B3 + 0.3283*B4 + 0.3407*B5 - 0.7117*B6 - 0.4559*B7 \text{ (Tane ve ark, 2018)}$$



Şekil 3.9 Sentinel-2 görüntüsünden üretilmiş Tasseled Cap dönüşümleri (Cleckner ve ark, 2011)


3.1.5. Oluşturulan katmanların birleştirilmesi

Raster veri seti olarak 15 gün aralıklı görüntüler her yıl için temin edilmiş olup, çalışma alanının % 20'sinden fazlasını kapsayan bulut ve bulut kaynaklı gölgeli alanlar sınıflandırma işlemine dâhil edilmemiştir. Böylelikle Denizli Çivril Ovası'nda 2017 ve 2018 yılları için 21, 2019 ve 2020 yılları için 22, 2021 yılı için ise 23 farklı görüntü kullanılmıştır. Eskişehir Çifteler bölgesinde ise 2019 yılı için 21, 2020 yılı için ise 22 farklı görüntü kullanılmıştır.

Farklı tarihlerde çekilen her bir Sentinel-2 görüntüsüne ait; mavi (bant-2), yeşil (bant-3), kırmızı (bant-4), yakın kızılötesi (bant-8), kısa dalga kızılötesi-1 (bant-11), kısa dalga kızılötesi-2 (bant-12), bantları ile görüntülerden üretilen NDVI, NDWI, SAVI ve 3 adet Tasseled cap dönüşümü (TCB-TCG-TCW) olmak üzere her bir görüntü için toplamda 12 farklı özellikten (banttan) oluşan görüntü yığını kullanılmıştır. Zaman serisi olarak alının bu görüntü yığını numpy formatında çok boyutlu dizin olarak her bir EO-Patch'de depolanmış ve sınıflandırma işleminde girdi raster veri seti olarak kullanılmıştır.

Çizelge 3.2 Sınıflandırmada kullanılacak görüntü ve özellik sayısı

	Yıllar	Görüntü Sayısı	Özellik (R-G-B-NIR-SWIR1-SWIR2-NDVI-NDWI-SAVI-3 TASSELED CAP)	Toplam bant sayısı
Denizli Çivril	2017	21	12	252
	2018	21	12	252
	2019	22	12	264
	2020	22	12	264
	2021	23	12	276
Eskişehir Çifteler	2019	21	12	252
	2020	22	12	264



Şekil 3.10 Sınıflandırmada kullanılan görüntü yığınının temsil eden görsel

3.2. Referans Veri Hazırlama

3.2.1. Sınıflandırılacak ürünlerin belirlenmesi

Denizli Çivril-Baklan Ovası ve Eskişehir Çifteler bölgesi tarımsal ürün çeşitliliği bakımından zengin olup her iki bölgede aynı tarımsal ürünlerin ekilmesinin yanı sıra farklı tarımsal ürünler de bulunmaktadır.

Çivril Ovası'nda arpa, ayçiçeği, buğday, fiğ, haşhaş, korunga, mısır, şekerpancarı ve yonca en çok yetişen tarla bitkileridir. Meyve üretiminin de yoğun olarak yapıldığı ovada üzüm ve elma geniş alanlarda üretilmekte olup bu ürünleri şeftali, kiraz ve kayısı izlemektedir. Sınıflandıracak ürünlerde; buğday ve arpa ürünleri hububat sınıfı altında, yem bitkisi olan yonca, fiğ, korunga ürünleri yonca sınıfı altında, kiraz, şeftali, kayısı, vişne ve elma ağaçları ise meyve ağacı sınıfı altında toplanarak sınıflandırma işlemine dâhil edilmiştir. Sınıflandırma işlemine girecek olan bu ürünler Çivril Ovası'ndaki tarımsal üretimin %95'lik bir kısmına karşılık gelmektedir.

Eskişehir Çifteler Sakaryabaşı Sulama Birliği sınırları ve çevresine kapsayan alanda ise buğday, arpa, çavdar, tritikale mısır, ayçiçeği, şekerpancarı, yonca, kabak en çok yetiştirilen tarımsal ürünler olmasının yanı sıra bölgede farklı yıllarda rotasyonlu olarak nadasa bırakma işleminin de olduğu görülmektedir. Sınıflandıracak ürünlerde; buğday, arpa, çavdar ve tritikale ürünleri hububat sınıfı altında toplanmış olup diğer ürünler aynı kalmıştır. Sınıflandırma işlemine girecek olan bu ürünler Çifteler bölgesindeki tarımsal üretimin %96.2'lik bir kısmına karşılık gelmektedir.

Sınıflandırma işlemine girecek ürünler hakkında bilgi sahibi olmak için Denizli-Çivril ve Eskişehir-Çifteler Tarım İlçe Müdürlükleri ile görüşülmüştür. Belirlenen her bir ürüne ait ekim tarihi, hasat tarihi ve farklı vejetatif gelişim süreçlerini içeren tarihler istenerek ürünlerin yıl içerisindeki fenolojileri hakkında saha çalışması yapılmadan önce bilgi sahibi olunmuştur.

Çok zamanlı uydu görüntüleri ile yapılan sınıflandırma çalışmaları farklı fenolojik evreleri yakalayabilmekte olup, ürünlere ait fenolojik takvim, ürünlerin birbirleri ile olan zamansal olarak ilişkileri hakkında bilgi edinimini sağlamakta ve sınıflandırma işleminde hangi bantların ve indekslerin kullanılabileceği hakkında da fikri sahibi olmamızı sağlamaktadır (Şimşek ve Durduran 2023).

Çizelge 3.3 Çalışma alanlarındaki ürünlerin zamansal gelişim ve değişimi

DENİZLİ-ÇİVRİL OVASI TARIM TAKVİMİ														
	Ekim	Kasım	Aralık	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım
Hububat														
Ayçiçeği														
Haşhaş														
Mısır														
Şekerpancarı														
Bağ	Seyrek ekildiği ve toprak örtüsünü de içine aldığından dolayı üzümün anlamlı değişim gösterdiği dönem bulunmamaktadır.													
Yonca	Yonca bir tarım sezonu boyunca 15-20 günde bir hasat edildiğinden tabloda gösterilmemiştir													
Meyve Ağacı														

Ekim
 Vejetatif Gelişim-Değişim
 Yüksek vejetasyon
 Hasat


ESKİŞEHİR-ÇİFTELER TARIM TAKVİMİ														
	Ekim	Kasım	Aralık	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım
Hububat														
Ayçiçeği														
Kabak														
Mısır														
Şekerpancarı														
Nadas	Nadasa bırakılan alanlarda herhangi bir ürün ekimi yapılmadığından vejetatif gelişim de yoktur													
Yonca	Yonca bir tarım sezonu boyunca 15-20 günde bir hasat edildiğinden tabloda gösterilmemiştir													

3.2.2. Arazi çalışması ve ürünlerin spektral imzalarının çıkarılması


Tarım İlçe Müdürlüklerinden alınan veriler doğrultusunda çalışma alanlarına ait ürünlerin fenolojik takvimleri oluşturulmuştur. Oluşturulan bu takvim de referans alınarak Denizli-Çivril Ovası ile Eskişehir-Çifteler bölgesinde 2020 ve 2021 yıllarında arazi çalışması yapılmış sınıflandırılacak tarımsal ürünler yerinde tespit edilmiştir. Tez çalışmasının ana hedeflerinden biri de beyan esaslı parsellerden yer doğruluk verisi üretilmesi ve bu verinin sınıflandırma çalışmasındaki başarımının testi olduğundan, araziden az sayıda yer doğruluk verisi toplanmış olup hem Çivril hem de Çifteler bölgesinde her bir tarımsal sınıf için yaklaşık 10-15 parselde yerinde tespit işlemi yapılmıştır. Yerinde tespiti yapılan parseller referans olarak kullanılacağından büyük alanları kapsayan (minumum 15 dekar), herhangi bir tarımsal anomali olmayan, tarım sezonuna uygun zamanda ekimi işlemi gerçekleştirilmiş parseller tercih edilmiştir.

Araziden toplanan referans parseller ve çok zamanlı Sentinel-2 görüntülerinden üretilen NDVI bantları kullanılarak çalışma alanlarındaki her bir sınıf için spektral


ayrılma eğrileri oluşturulmuştur. Oluşturulan spektral ayrılma eğrileri ÇKS beyanlı parsellerin temizlenmesinde referans olarak kullanılmıştır.



Şekil 3.11 Arazi çalışması yapılan ürünlere ait fotoğraflar



Şekil 3.12 Denizli Çivril-Baklan Ovası'ndaki ürünlere ait spektral ayrılma eğrileri



Şekil 3.13 Eskişehir Çifteler bölgesindeki ürünlere ait spektral ayrılma eğrileri

3.2.3. ÇKS verilerinin temini

Çiftçi Kayıt Sistemi (ÇKS) çiftçilere ait tarımsal faaliyetlerin kayıt altına alındığı, Tarım ve Orman Bakanlığı tarafından oluşturulan bir sistemdir. Bu sistemde her bir çiftçinin tarımsal faaliyet gösterdiği ürüne ait beyan bilgisi, il, ilçe, ada, parsel, parsel alanı, ekim alanı, ekim tarihi, hasat tarihi, tarım şekli (kuru-sulu), üretim çeşidi (1.üretim-2.üretim) ve zeminId bilgileri bulunmaktadır. Veri tabanında tutulan sözel verilerdeki her bir özgün zeminId değeri ile sayısal formatta bulunan tarım parsellerindeki zeminId değerleri spatial join işlemi ile ilişkilendirilerek bir ya da birden fazla beyana esas ürün bilgisi her bir tarım parseline aktarılmıştır. Bu işlem ürün desen sınıflandırması yapılacak her yıl için tekrarlanmıştır.


Coğrafi WGS 84 projeksiyon sistemindeki parseller UTM WGS84 ZONE 35 (Denizli-Çivril) ve UTM WGS84 ZONE 36 (Eskişehir-Çifteler) projeksiyon sistemine çevrilmiş, birleştirilmiş ve çalışma alanına göre kesilmiştir.

Çizelge 3.4 Denizli İli Çivril İlçesi 2020 yılı ÇKS belgesi örneği



T.C. TARIM VE ORMAN BAKANLIĞI
ÇKS Köy Genelinde Parsel Üretim Belgesi

İl	İlçe	Köy	Ada No	Parsel No	Kullanılan Alan(da)	Tarım Alanı No	Parsel Alanı(da)	Ürün	Tarım Şekli	Ekim Tarihi	Hasat Tarihi	Ekili Alan (da)	Üretim Çeşidi
DENİZLİ	ÇİVRİL	İNCEKÖY	101	366	1,935	99904627	1,935	ŞEKER PANCARI (MUHTELİF)	Sulu	01/04/2020	01/10/2020	1,935	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	368	1,798	230564640	10,791	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	1,798	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	309	1,875	99904564	9,381	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	1,875	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	110	30	10,526	99905038	10,527	MISIR (DANE)	Kuru	01/04/2020	01/08/2020	10,526	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	110	99	4,878	99905113	4,879	MISIR (DANE)	Kuru	01/04/2020	01/08/2020	4,878	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	383	5,659	99904646	5,66	ARPA (muhtelif)	Kuru	01/09/2019	01/04/2020	5,659	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	374	4,758	99904636	4,759	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	4,758	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	111	85	16,742	99905197	16,743	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	16,742	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	111	86	1,284	99905198	1,285	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	1,284	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	111	71	9,655	99905182	9,656	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	9,655	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	177	9,22	99904417	9,22	YONCA (MUHTELİF)	Sulu	01/04/2018	01/04/2022	9,22	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	245	4,729	99904493	4,729	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	4,729	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	275	2,219	99904526	2,219	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	2,219	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	101	426	5,09	230566314	5,09	MISIR (DANE)	Sulu	01/04/2020	01/08/2020	4,765	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	111	73	2,344	99905184	2,344	AYÇİÇEĞİ (ÇEREZ)	Sulu	01/04/2020	01/08/2020	2,344	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	111	79	2,528	99905190	2,528	AYÇİÇEĞİ (ÇEREZ)	Sulu	01/04/2020	01/08/2020	2,528	1.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	113	30	2,233	99905291	2,233	MISIR (SILAHLIK)	Sulu	15/06/2020	30/11/2020	2,233	2.Üretim
DENİZLİ	ÇİVRİL	İNCEKÖY	113	31	2,663	99905292	2,663	MISIR	Sulu	15/06/2020	30/11/2020	2,663	2.Üretim




Şekil 3.14 Denizli Çivril-Baklan Ovası ÇKS beyanlı parsel dağılımı

Çizelge 3.5 Eskişehir İli Çifteler İlçesi 2019 yılı ÇKS belgesi örneği



T.C. TARIM VE ORMAN BAKANLIĞI
ÇKS Köy Genelinde Parsel Üretim Belgesi

İl	İlçe	Köy	Ada	Parsel	Kullanılan Alan(da)	Parsel Alanı	Tarım Alanı	Ürün	Tarım Şekli	Ekili Alan (da)	Ekim Tarihi	Hasat Tarihi	Üretim Çeşidi
ESKİŞEHİR	ÇİFTELER	DOĞANAY	0	228	3,812	3,812	220953322	NADAS (MUHTELİF)	Sulu	3,812	01/10/2018	01/08/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	DOĞANAY	0	184	68,5	68,5	220952497	ARPA (muhtelif)	Kuru	68,278	01/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	DOĞANAY	0	225	9	9	220953692	ŞEKER PANCARI	Sulu	8,933	01/03/2019	01/09/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1271	12,65	12,65	221182838	AYÇİÇEĞİ (YAĞLIK)	Sulu	12,606	01/03/2019	01/09/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1492	5,5	5,5	221182001	ARPA (muhtelif)	Sulu	5,5	02/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1509	21,8	21,8	221182305	ARPA (muhtelif)	Sulu	21,8	02/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1329	4,9	4,9	221186795	ARPA (muhtelif)	Kuru	4,9	01/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1511	15,35	15,35	221182295	ARPA (muhtelif)	Sulu	15,246	10/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	294	20,873	41,75	221168555	ŞEKER PANCARI	Sulu	20,644	01/03/2019	01/09/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1496	6,05	6,05	222920420	ARPA (muhtelif)	Sulu	5,92	10/10/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1335	20,9	20,9	221185269	ARPA (muhtelif)	Kuru	20,9	10/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	702	41	41	221185890	ARPA (muhtelif)	Sulu	40,757	01/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	716	14	14	222921971	ARPA (muhtelif)	Sulu	13,785	01/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	387	6,5	6,5	221176394	ŞEKER PANCARI	Sulu	6,341	01/03/2019	01/09/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1512	12,5	12,5	221173988	ARPA (muhtelif)	Sulu	12,327	02/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1246	46,15	46,15	221184301	AYÇİÇEĞİ (YAĞLIK)	Sulu	46,15	01/03/2019	01/09/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	ORTAKÖY	0	1328	14,1	14,1	221171690	ARPA (muhtelif)	Kuru	14,1	01/09/2018	01/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	SARIKAVAK	0	265	19,249	19,25	61701129	BUĞDAY (EKMEKLİK)	Kuru	19,012	20/09/2018	20/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	KADIKUYUSU	0	2308	16,299	16,3	221055312	BUĞDAY (EKMEKLİK)	Kuru	16,091	20/09/2018	20/06/2019	1.Üretim
ESKİŞEHİR	ÇİFTELER	OSMANIYE	0	397	6,999	7	221125327	NADAS (MUHTELİF)	Kuru	6,999	01/10/2018	01/08/2019	1.Üretim



Şekil 3.15 Eskişehir-Çifteler ÇKS beyanlı parsel dağılımı

ÇKS beyanlı parsellerde yapılan incelemelerde, parsellerde geometrik ve öznitelik olarak sistematik ve sistematik olmayan hatalar olduğu görülmüş, bunun yanı sıra ekilen ürün ile beyan edilen ürün arasında da farklılıklar olduğu tespit edilmiştir. Bu sebeplerden dolayı ÇKS beyanlı parseller sınıflandırma işlemi için doğrudan referans veri (yer doğruluk verisi) olarak kullanılamayıp, bu verinin temizlenmesi gerekmektedir. Verinin temizlenme işlemi üç adımda gerçekleşmekte olup bunlardan birincisi verinin öznitelik ve geometrik olarak temizlenme işlemi, ikincisi verinin NDVI görüntüleri kullanarak parsel tabanlı temizlenmesi üçüncüsü ise temizlenmiş parsel tabanlı verinin raster veriye dönüştürülerek ve yine NDVI görüntüleri kullanarak piksel tabanlı temizlenmesidir.

3.2.4. ÇKS verilerinin öznitelik ve geometrik olarak temizlenmesi

Ülkemizde çoğu parsel birden fazla hissedara sahip olup, bir başka deyişle hisseli mülkiyet durumundadır. Aynı parsele ait her bir hissedar ÇKS’ne kayıt olduğunda, parsel tek bir geometride tutulmak yerine başvuran hissedar sayısı kadar geometride tekrarlı olarak tutulmaktadır. Sistemden kaynaklı bu durum sonucunda bölgeye ait ÇKS kayıtlı parsel sayısı tekrarlamakta ve gerçek sayının 10 katına kadar dahi çıkabilmektedir. Söz konusu bu durum geometrileri, ZeminId’leri ve UrunAd özellikleri birebir aynı olan tekrarlı parsellerin otomatik olarak silinmesi ile giderilmiştir.

civril_ova_2020 [12]	
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
Id	228540291
(Derived)	
(Actions)	
Id	228540291
IlceAd	BAKLAN
UrunAd	HAŞHAŞ
EkimTarihi	2019-10-15
HasatTarih	2020-05-15
EkilenAlan	26.0790000000
Id	228540291
(Derived)	
(Actions)	
Id	228540291
IlceAd	BAKLAN
UrunAd	HAŞHAŞ
EkimTarihi	2019-10-15
HasatTarih	2020-05-15
EkilenAlan	14.4870000000

Şekil 3.16 ÇKS beyanlı parsele ait tekrarlı öznitelik bilgileri

Çiftçinin beyan değişikliği başvurusundan kaynaklı aynı tarımsal döneme ait birden fazla farklı ürün girişi yapılması ve önceki beyanın veri tabanında aktif olarak tutulmasından dolayı, aynı ekim ve hasat tarihlerinde aynı ekim alanına sahip farklı ürün girişi olması beyan esaslı parsellerde karşılaşılan problemlerden bir diğeridir. Beyan edilen hangi ürünün arazide gerçeği yansıttığı bilinmediğinden bu parseller tespit edilip sınıflandırma işlemi için kullanım dışı bırakılmıştır.

▶ (Actions)	
Id	479091135
IlceAd	ÇAL
UrunAd	MISIR
EkimTarihi	2019-06-02
HasatTarih	2019-10-02
EkiliAlan	20000.000
▶ Id	479091135
▼ Id	479091135
▶ (Derived)	
▶ (Actions)	
Id	479091135
IlceAd	ÇAL
UrunAd	AYÇİÇEĞİ
EkimTarihi	2019-06-01
HasatTarih	2019-10-02
EkiliAlan	20000.000
▼ Id	479091135
▶ (Derived)	
▶ (Actions)	
Id	479091135
IlceAd	ÇAL
UrunAd	AYÇİÇEĞİ
EkimTarihi	2019-06-01
HasatTarih	2019-10-02
EkiliAlan	20000.000

Şekil 3.17 ÇKS beyanlı parsele ait aynı tarihleri içeren birden fazla farklı ürün giriş

Beyan esaslı parsellerde aynı sezonda, parselin bir kısmına ürün ekilirken bir diğer kısmına bir ya da birden çok farklı çeşitte ürün ekilebilir. Bu gibi durumlarda hangi ürün çeşidinin parselin geometrik olarak neresine ekildiği bilinmediğinden bu tür parsellerin yer doğruluk verisi olarak kullanılması sorun teşkil etmektedir. Bu tür birden fazla ürün bilgisi içeren parsellerde, ikinci ya da daha fazla ürün çeşidi için parsel alanı ile beyan edilen alan arasındaki oran %10'dan büyükse parsel sınıflandırma işlemi için elemine edilmiştir.

Özellikle Güneydoğu Anadolu bölgesinde verimli toprak ve iklim koşullarından kaynaklı olarak yıl içerisinde 2 farklı ürün almak mümkündür. Bu gibi durumlarda ÇKS kayıtlarında farklı tarihlere sahip birden fazla ürün beyanı olabileceğini göstermektedir. Çalışma alanları olan hem Denizli – Çivril hem de Eskişehir–Çifteler bölgelerinde ise bu durum gibi rotasyonlu ürün ekimi neredeyse yapılmamaktadır.

▶ (Actions)	
Id	479332195
IlceAd	ÇAL
UrunAd	YONCA
EkimTarihi	2019-03-15
HasatTarih	2023-03-15
EkilenAlan	30.36500000000
▼ Id	479332195
▶ (Derived)	
▶ (Actions)	
Id	479332195
IlceAd	ÇAL
UrunAd	ŞEKER PANCARI
EkimTarihi	2020-03-15
HasatTarih	2020-10-15
EkilenAlan	24.63700000000
▶ Id	479332195

Şekil 3.18 ÇKS beyanlı parsele ait farklı tarihleri içeren birden fazla ürün giriş

Beyan bilgisini içeren tarım parselleri çizilirken ya da düzeltilirken bazı parsellerde topolojik hataların olduğu (sarkan çizgiler, alanın kapatılmaması, üst üste binen parseller) bazı parsellerin ise tarım dışı alanlarda çizildiği tespit edilmiştir. Geometrik hatalar, ilgili yazılımlarda topoloji kurularak giderilmiş olup, LPIS (Arazi Parsel Tanımlama Sistemi) projesi kapsamında üretilen tarım alanları ile ÇKS beyanlı parseller karşılaştırılarak, tarımsal alanlar dışında bulunan beyanlı parseller ise tespit edilerek silinmiştir.



(a)



(b)

Şekil 3.19 Topolojik hata içeren (a) ve tarım dışında bulunan ÇKS parselleri

3.2.5. ÇKS verilerinden spektral imza çıkarımı ve parsel tabanlı temizlenmesi

ÇKS verisinin sınıflandırma işleminde test verisi olarak kullanılmasından önce yarı otomatik ve otomatik olarak öznetelik ve geometrik düzenleme ile silme işlemleri gerçekleştirilmiştir. ÇKS'ye kayıtlı parsellerin bir kısmında ürün beyanı verilmesine rağmen herhangi bir tarımsal aktivite yapılmadığı, birçok parselde ise ÇKS'de beyan


edilen ürün ile arazide ekilen ürün arasında farklılık olduğu tespit edilmiştir. Bu durumun ÇKS'deki en büyük problemlerden biri olduğu bilgisine ulaşılmış olup, yanlış beyanların tespit edilerek elemine edilmesi gerekmektedir. (Şimşek ve Durduran 2023). Yanlış beyanların temizlemeden sınıflandırma işleminde eğitim verisi olarak kullanılması sınıflandırma başarısını oldukça düşüreceği de aşikârdır.

NDVI indeksi bitki örtüsü fenolojisini izlemek için kullanılan popüler indekslerden biri olup, NDVI zaman serisi ile bitki örtüsünün yıl içerisindeki büyüme, gelişme ve hasadı ile ilgili bilgilere ulaşılabilir (Mishra ve ark, 2017). NDVI görüntüsü ile ÇKS beyanlı parseller karşılaştırılmış ve her bir parselin içine median NDVI değerleri yazdırılmıştır. Yıl boyunca alınan tüm görüntülerde zaman serisi şeklinde bu işlem tekrarlanarak, çalışma alanına giren her bir ÇKS beyanlı parselin NDVI değerleri ile spektral ayrılma eğrileri oluşturulmuştur. Böylelikle tarımsal ürün beyan bilgisi içeren her bir parsel için vejetatif gelişim ve değişim değeri ile her bir ürün çeşidine ait NDVI paterni belirlenmiştir.

Her bir parsel için oluşturulan spektral ayrılma eğrileri, arazi çalışması sonucu her ürün sınıfı için oluşturulan spektral yansıma değerleri referans alınarak kontrol edilmiştir. Beyan bilgisi içeren bir parsel spektral olarak arazide bulunduğu tarih aralığında kendi türünün spesifik yansıma değerini vermemiş ise silinmiş, referans yansıma eğrisi ile aynı ve benzer ise tutulmuştur.


Parsel tabanlı bu işlemi yarı otomatik olarak yapmak için tez kapsamında özgün bir uygulama yazılmıştır. Bu uygulama basit, modern, genel amaçlı, nesneye yönelik olan Microsoft tarafından geliştirilen bir programlama türü olan C# dilinde yazılmıştır. C# Microsoft'un geliştirmiş olduğu .NET Framework platformu için geliştirilmiş yeni nesil bir programlama dili olup, özellikle nesne yönelimli programlama kavramının gelişmesine katkıda bulunan en aktif programlama dillerinden biridir. C# dili kullanılarak oluşturulan uygulama yine Microsoft tarafından geliştirilen bir IDE (Integrated Development Environment) programı olan Visual Studio kullanılarak oluşturulmuştur. Uygulama oluşturulurken GDAL, GeoAPI, GeoJSON, OGR-C#, OSR C# , Projnet ve DevExpress Tool kütüphaneleri kullanılmıştır.

ÇKS beyanlı parsellere ait, çok zamanlı görüntülerin NDVI bantlarından her bir sınıf için oluşturulan spektral ayrılma eğrileri geliştirilen uygulama ile grafik şeklinde gösterilmektedir. Şekil 3.20’de gösterilen siyah eğriler her bir sınıfa ait spektral yansıma değerlerini temsil etmektedir.




Şekil 3.20 Denizli Çivril-Baklan Ovası ÇKS beyanlı parsellere ait spektral yansıma değerleri (parsel tabanlı temizlenmemiş)


Her bir sınıf için spektral yansımaya eğrileri, ilgili sınıfa ait arazi çalışması sonucu oluşturulan referans spektral yansımaya eğrileri ile karşılaştırılmıştır. Uygulama ile kullanıcı tarafından referans spektral yansımaya eğrisinin paternine benzeyen ÇKS beyanlı parseller tutulurken, spektral olarak benzemeyen, farklı ürünü temsil eden veya anomali olan parseller ise elemine edilmiştir.




Şekil 3.21 Denizli Çivril-Baklan Ovası ÇKS beyanlı tutulan ve silinen parsellere ait spektral yansımaya değerleri (parsel tabanlı)




Şekil 3.22 Denizli Çivril-Baklan Ovası ÇKS beyanlı temizlenen parsellere ait spektral yansıma değerleri (parsel tabanlı temizlenmiş)



Şekil 3.23 Eskişehir-Çifteler ÇKS beyanlı parsellere ait spektral yansımaya değerleri (parsel tabanlı temizlenmemiş)



Şekil 3.24 Eskişehir-Çifteler ÇKS beyanlı tutulan ve silinen parsellere ait spektral yansıma değerleri (parsel tabanlı)



Şekil 3.25 Eskişehir-Çifteler Ovası ÇKS beyanlı temizlenmiş parsellere ait spektral yansıma değerleri (parsel tabanlı temizlenmiş)

Yukarıdaki spektral yansıma değerleri Denizli Çivril Ovasında 2020 yılı, Eskişehir Çifteler bölgesinde ise 2019 yılına ait olup, parsel tabanlı temizleme işlemi Denizli Çivril-Baklan Ovası'nda sınıflandırması yapılan 2017, 2018, 2019 ve 2021 yılları için, Eskişehir Çifteler bölgesinde ise 2020 yılı için tekrarlanmıştır.


Spektral ayrılma eğrilerini temizleme işleminden sonra her bir sınıf için kalan parseller referans veri haline gelmiş olup bu parseller yer doğruluk verisi, bir başka deyişle arazi gerçeği verisi olarak sınıflandırma işleminde kullanılmak üzere oluşturulmuştur.

Oluşturulan uygulama ile çalışma alanına giren ÇKS beyanlı parsellerin zaman serisi olarak NDVI median değerleri belirlenmiş, bu değerler ile parsellere ait spektral ayrılma eğrileri oluşturulmuştur. Bu eğriler ile sahadan ölçülen ürünlere ait referans spektral ayrılma eğrilerinin karşılaştırılması ve referans alınmasıyla, gerçeği yansıtmayan ve/veya uyumsuz beyan içeren parseller kullanıcı tarafından kolay ve kontrollü bir şekilde silinmiş olup geriye kalan parsellerin arazi gerçeği verisi haline gelmesi sağlanmıştır.


3.2.6. ÇKS verilerinin piksel tabanlı temizlenmesi

Parsel tabanlı temizleme yöntemi ile yer doğruluk verisi sınıflandırma işlemi için hazır olmasına rağmen, açık kaynak kodlu EO-Learn kütüphanesi yer doğruluk verisini piksel tabanlı olarak kullanmaktadır. Bu sebeple vektör formatta tutulan ve temizlenen ÇKS beyanlı parseller raster veriye dönüştürülmüştür ve tıpkı parsel tabanlı temizle işleminde olduğu gibi zaman serisi NDVI değerleri kullanılarak spektral ayrılma eğrileri tekrar oluşturulmuştur.


ÇKS beyanlı parsellerin parsel tabanlı temizlemesi sonrası yer doğruluk verisi olarak hazır hale gelmesine rağmen, vektörden piksele dönüşümden kaynaklı aykırı değerler (outlier) ve anomaliler ortaya çıkmıştır. Ortaya çıkan bu değerler az sayıda olmasına rağmen piksel tabanlı temizle işlemi ile ikinci kez temizlenerek sınıflandırma işlemi için hazır hale getirilmiştir.




Şekil 3.26 Denizli Çivril Baklan Ovası ÇKS beyanlı parsellere ait spektral yansım değerleri (piksel tabanlı temizlenmemiş)




Şekil 3.27 Denizli Çivril Baklan Ovası ÇKS beyanlı tutulan ve silinen parsellere ait spektral yansımalar (piksel tabanlı)




Şekil 3.28 Denizli Çivril Baklan Ovası ÇKS beyanlı tutulan parsellere ait spektral yansıma değerleri (piksel tabanlı temizlenmiş)



Şekil 3.29 Eskişehir-Çifteler ÇKS beyanlı parsellere ait spektral yansımalar (piksel tabanlı temizlenmemiş)



Şekil 3.30 Eskişehir-Çifteler ÇKS beyanlı tutulan ve silinen parsellere ait spektral yansıma değerleri (piksel tabanlı)



Şekil 3.31 Eskişehir-Çifteler ÇKS beyanlı tutulan parsellere ait spektral yansımalar (piksel tabanlı temizlenmiş)

Yukarıdaki spektral yansıma değerleri Denizli Çivril-Baklan Ovasında 2020 yılı, Eskişehir Çifteler bölgesinde ise 2019 yılına ait olup, piksel tabanlı temizleme işlemi Denizli Çivril-Baklan Ovası'nda sınıflandırması yapılan 2017, 2018, 2019 ve 2021 yılları için, Eskişehir Çifteler bölgesinde ise 2020 yılı için tekrarlanmıştır.

Özellikle büyük alanlarda yapılacak sınıflandırma çalışmalarında, hangi algoritma kullanılırsa kullanılsın yapay zekânın doğru bir sonuç vermesi için çok sayıda ve farklı özelliklerde eğitim setine ihtiyaç duyulmaktadır. Geliştirilen bu yöntemle ve uygulama ile birçok farklı hata içeren ÇKS beyanlı parseller temizlenerek sınıflandırma çalışmasında kullanılmak üzere yer doğruluk verisi haline getirilmiştir.

Öznitelik - geometrik, parsel tabanlı ve piksel tabanlı temizleme işlemleri sonrası her bir sınıf için temizlenmiş parsel sayıları Çizelge 3.6 ve 3.7'de gösterilmektedir.

Çizelge 3.6 Temizlenme öncesi ve sonrası ÇKS beyanlı parsel sayısı (Eskişehir-Çifteler)

Yıllar	Ürünler	ÇKS	Öznitelik-Geometrik Temizleme	Parsel Tabanlı Temizleme	Piksel Tabanlı Temizleme
2019	Ayçiçeği	1802	717	150	122
	Hububat	18364	8537	3740	3512
	Kabak	1652	812	131	102
	Mısır	1421	707	286	258
	Nadas	6960	3123	2454	2132
	Şeker pancarı	2122	956	358	333
	Yonca	1561	504	480	414
	Toplam	33882	15356	7599	6873
2020	Ayçiçeği	1314	599	352	322
	Hububat	10038	5389	3243	3027
	Kabak	1296	701	341	315
	Mısır	1314	662	262	221
	Nadas	4066	1984	1320	1120
	Şeker pancarı	1554	728	395	345
	Yonca	1336	522	364	287
	Toplam	20918	10585	6277	5637

Çizelge 3.7 Temizlenme öncesi ve sonrası ÇKS beyanlı parsel sayısı (Denizli Çivril-Baklan Ovası)

Yıllar	Ürünler	ÇKS	Öznitelik-Geometrik Temizleme	Parsel Tabanlı Temizleme	Piksel Tabanlı Temizleme
2017	Ayçiçeği	17658	2258	1220	1017
	Bağ	2508	1202	682	514
	Haşhaş	16232	3173	1181	1061
	Hububat	13049	6903	2814	2513
	Meyve Ağacı	15094	6138	2195	2097
	Mısır	1461	11420	3301	3125
	Şeker pancarı	4160	510	314	297
	Yonca	4627	2269	1830	1750
	Toplam	74789	33873	13537	12374
2018	Ayçiçeği	12204	9215	2865	2801
	Bağ	5056	1207	805	777
	Haşhaş	19679	1968	570	534
	Hububat	11753	10055	3718	3648
	Meyve Ağacı	15062	5846	3193	3003
	Mısır	1225	5038	1241	1041
	Şeker pancarı	3684	729	401	387
	Yonca	5901	2073	1570	1538
	Toplam	74564	36131	14363	13729
2019	Ayçiçeği	3743	1560	1585	1365
	Bağ	8996	1184	882	848
	Haşhaş	17997	4343	1301	1255
	Hububat	12721	7992	1623	1521
	Meyve Ağacı	19856	5918	2648	2447
	Mısır	1290	11415	5991	5777
	Şeker pancarı	4004	509	289	267
	Yonca	5381	2259	1447	1407
	Toplam	73988	35180	15766	14887

Yıllar	Ürünler	ÇKS	Öznitelik-Geometrik Temizleme	Parsel Tabanlı Temizleme	Piksel Tabanlı Temizleme
2020	Ayçiçeği	9403	3485	1745	1599
	Bağ	7212	1144	960	917
	Haşhaş	17838	4593	1081	988
	Hububat	11970	10467	3595	3445
	Meyve Ağacı	18534	5961	2787	2645
	Mısır	1491	7919	3606	3512
	Şeker pancarı	3599	881	403	366
	Yonca	4786	2595	1844	1564
	Toplam	74833	37045	16021	15036
2021	Ayçiçeği	8488	1477	1302	1156
	Bağ	8820	229	361	315
	Haşhaş	27243	5889	1256	1056
	Hububat	13817	9704	2178	2048
	Meyve Ağacı	8430	2331	2136	2056
	Mısır	705	1849	1597	1414
	Şeker pancarı	3736	339	311	288
	Yonca	5733	1524	1481	1355
	Toplam	76972	23342	10622	9688

Her iki çalışma alanına giren ÇKS beyanlı parsellerin yaklaşık %80'i öznitelik, geometrik, parsel tabanlı ve piksel tabanlı temizleme işlemleri sonrası silinmiş ve elemine edilmiştir. Bu uygulama ile sistematik ve sistematik olmayan hatalar giderilmiş, aynı zamanda çok büyük miktarda ve ihtiyaç duyulmayacak boyutta veriyle çalışmanın da önüne geçilmesi sağlanarak makine öğrenim sürecinde kolaylık sağlanmıştır. Sonuç olarak yarı otomatik ve otomatik olarak yapılan bu işlemler silsilesi ile ÇKS beyanlı parsellerden sınıflandırma çalışmasında kullanılmak üzere arazi gerçeği verisi oluşturulmuştur.

3.2.7. Eğitim ve test verilerinin belirlenmesi

Sınıflandırma çalışmalarında kullanılacak veri seti eğitim ve test verisi olarak ikiye ayrılmaktadır. Eğitim veri seti üzerinden kullanılacak algoritma ile model oluşturularak sınıflandırma işlemi yapılır, sınıflandırma sonucu ise test verisi kullanılarak oluşturulan hata matrisleri ile kontrol edilir.

Beyan esaslı parsellerin arazi gerçeği verisine dönüştürülmesinden sonra parseller eğitim ve test verisi olarak ikiye ayrılmıştır. Sınıflandırma işlemlerinde klasik olarak uygulanan, eğitim ve test verilerinin kullanıcı tarafından manuel olarak ayrılmasının yerine, veri kendi içinde K-katmanlı çapraz doğrulama (k-fold cross validation) işlemine tabi tutularak otomatik bir şekilde eğitim ve test verisine tekrarlı olarak ayrılmıştır. K-katmanlı çapraz doğrulama yöntemi ile ayrılan test ve eğitim veri sayısı 3.3.3. bölümünde detaylı olarak anlatılmıştır.


Temizlenen parsellerden eğitim ve test verilerinin oluşturulmasının yanı sıra, sınıflandırma sonucunun farklı verilerle ikinci kere test edilmesi amaçlanmıştır. Bu nedenle sınıflandırma işleminde eğitim verisi olarak kullanılmayan TARSİM parselleri test verisi olarak kullanılmış olup sınıflandırma sonucu üzerinde ikinci bir doğruluk analizi yapılmıştır. Test verisi olarak kullanılan her bir sınıfa ait TARSİM parselleri Çizelge 3.8 ve 3.9’da gösterilmiştir.

Çizelge 3.8 Test verisi olarak kullanılan TARSİM parselleri (Denizli Çivril-Baklan Ovası)


TARSİM parselleri	Ürünler/Yıllar	2017	2018	2019	2020	2021
	Ayçiçeği	690	426	120	271	374
	Bağ	14	7	12	20	20
	Haşhaş	88	286	451	640	646
	Hububat	158	219	120	223	475
	Meyve Ağacı	454	374	242	278	278
	Mısır	352	313	1043	468	355
	Şeker pancarı	33	23	13	48	32
	Yonca	63	58	66	124	137
	Toplam	1852	1706	2067	2072	2317

Çizelge 3.9 Test verisi olarak kullanılan TARSİM parselleri (Eskişehir-Çifteler)

TARSİM parselleri	Ürünler/Yıllar	2020	2021
	Ayçiçeği	104	182
	Hububat	91	150
	Kabak	120	128
	Mısır	199	179
	Nadas	59	111
	Şeker pancarı	315	260
	Yonca	152	148
	Toplam	1040	1158



Şekil 3.34 Denizli Çivril-Baklan Ovası'nda test verisi olarak kullanılan 2020 yılını ait TARSİM parselleri



Şekil 3.35 Eskişehir Çifteler bölgesinde test verisi olarak kullanılan 2019 yılını ait TARSİM parselleri

3.3. Makine Öğrenmesi ve Sınıflandırma

3.3.1. Hafif gradyan artırma makineleri (Light gradient boosting machine)

Çok zamanlı (multi-temporal) görüntüler kullanılarak yapılan sınıflandırma çalışmalarında, kullanılacak bantlar, indeksler, veri boyutu, çalışma alanının kapsamı, doğruluk hassasiyeti ve kullanılacak donanımın özellikleri göz önüne alındığında optimum bir model belirlenmelidir.

Son yıllarda veri boyutu ve çeşitliliğin hızla artması ile makine öğrenmesi ve veri bilimi alanındaki araştırmacılar yeni algoritmalar geliştirmeye başlamışlardır. Yeni nesil algoritmalarından olan, aşırı gradyan artırma (XGBoost) ve hafif gradyan artırma makineleri (LightGBM) sık kullanılan makine öğrenme algoritmalarına kıyasla daha hızlı eğitim, daha yüksek doğruluk ve daha yüksek performans göstermeleri sebebi ile araştırmacıların ve kullanıcıların ilgisini çekmiştir (Üstüner ve ark, 2020).

Bu tez çalışmasında Açık kaynak kodlu EO-Learn Kütüphanesinin alt paketlerinden biri olan “eo-learn-ml-tools” paketi içerisindeki Light GBM makine öğrenme algoritması kullanılmıştır.

LightGBM, “Microsoft dağıtık makine öğrenmesi yazılımı (Distributed machine learning toolkit)” projesi kapsamında 2017 yılında geliştirilmiş bir boosting algoritması olup Kaggle platformu yarışmalarında en çok tercih edilen algoritmalarından biridir (URL-18). Birçok model gibi ağaç tabanlı öğrenme algoritmalarını kullanan Light GBM ile histogram tabanlı algoritmalar kullanır. Histogramı biriken değerler sıralanır ve sıralanan histogram en iyi bölünmeyi seçerek eğitim hızlanır ve bellek kullanımı azalır (URL-19). Yapılan çalışmalarda Light GBM algoritmasının diğer algoritmalarla göre 20 kat daha hızlı olduğu sonucuna ulaşılmıştır (Guolin ve ark, 2017).

LightGBM algoritmasını diğer algoritmalarından ayıran özellik karar ağaçlarının eğitilmesi aşamasında yaprak odaklı büyümesidir (Liu ve ark, 2017). LightGBM düşey yönde büyüme stratejisini (yapraksal büyüme) kullanırken, diğer gradyan artırma yöntemleri ise yatay seviyesel (level-wise) büyüme stratejisini kullanmaktadır (Guolin ve ark, 2017 ; Li ve ark, 2019) Yaprak odaklı büyüme ile daha az hata oranına sahip, daha hızlı öğrenme gerçekleşmektedir (Li ve ark, 2019).

Light GBM algoritması karar ağaçlarının eğitiminde iki yöntem kullanmaktadır. Bu iki yöntem gradyan tabanlı tek yönlü örnekleme (Gradient-based one-side sampling, GOSS) ve ayrıcalıklı özellik desteleme (Exclusive feature bundling, EFB) yöntemidir. Gradyan tabanlı tek yönlü örnekleme karar ağaçlarının doğruluk oranını korurken veri sayısının azaltılması amaçlar böylelikle tüm veri yerine alt örneklem ve önemli veri setinin kullanılması amaçlanmaktadır (Üstüner ve Şanlı, 2019). Ayrıcalıklı özellik destekleme doğruluk oranını koruyarak değişken sayısını azaltmayı ve buna bağlı olarak model eğitiminin verimliliği artırmayı amaçlamıştır. Diğer algoritmalarda olduğu gibi Light GBM algoritmasında da parametreler bulunmakta olup hangi parametrelerin seçildiği ve kullanıldığı 3.3.2 Hiper parametre optimizasyon bölümünde anlatılmaktadır.

3.3.2. Parametre ve hiper parametre optimizasyonu

Makine öğrenme algoritmalarını büyük boyutlu probleme doğrudan uygulamadan önce problemi daha küçük parçacıklara ayırma işlemine parametre optimizasyonu denilmektedir. Parametre optimizasyonunda amaç farklı kombinasyonlar uygulayarak algoritma için en iyi sonucu veren parametreyi elde etmektedir. Parametre optimizasyonu genelde hiper-parametre optimizasyonu olarak karşımıza çıkar (Kuş ve ark, 2021).

Bir makine öğrenmesi algoritmasına ait, kullanılacak veri seti göz önünde bulundurularak veri setinin özelliklerine göre değişkenlik gösteren parametreler hiper

parametre olarak tanımlanır. Hiper parametre optimizasyonu ise, bir makine öğrenmesi algoritması için belirlenen başarı metriğine göre en uygun parametre kombinasyonunu bulma işlemidir. Hiperparameter optimizasyonu ile modelin yüksek başarıya ulaşması ve model karmaşıklığı dengelenerek aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) durumlarının önüne geçilir. En yüksek model doğruluğunu veren parametre çifti, en uygun parametre değeri olarak kabul edilir (Maxwell ve ark, 2018). Hiper parametre optimizasyonun küçük boyutlu verilerde iyi sonuçlar vermesinin nedeni doğru kümenin bulunması için geçen sürenin ve tekrarlama sayısının az olmasıdır (URL-20).

Makine algoritmalarında en iyi sonucu veren hiper parametreleri bulan çeşitli yöntemler kullanılmaktadır. Izgara araması, bayes optimizasyonu, rastgele arama, evrimsel optimizasyon ve gradyan tabanlı optimizasyon bu yöntemlerden bazıları olup bu çalışmada ızgara algoritması yöntemi kullanılmıştır.

Çizelge 3.10 Light GBM hiper parametreleri

Parametre	Değer
Hızlandırma Türü	GOSS
Yapraktaki Minumum Veri Sayısı	377
Güçlendirilmiş Ağaç Sayısı	20
Maksimum Derinlik	7
Maksimum Yaprak Sayısı	81
Max bin	255
Bölütleme sayısı	42

3.3.3. K-katmanlı çapraz doğrulama yöntemi

Sınıflandırma problemlerinde öncelikle veri seti eğitim ve test setleri olarak ayrılır daha sonra eğitim veri seti üzerinden model oluşturur ve test veri seti üzerinde yapılan tahminler test edilir (URL-21). Sınıflandırma işleminde kullanılacak eğitim ve test verilerinin ayrımında bazı problemler yaşanabilmektedir bunlar;

- Eğitim ve test veri setinin ayrımı rastgele yapılmamış olup belirli bir özellik, sınıf, değer fazla ya da az seçilip model kurulmuş olabilir.
- Eğitim veri seti tek düze hazırlanmış veya model veri setimiz üzerinden gereğinden fazla çalışıp ezberlemeye başlamış ise aşırı öğrenme (overfitting) olma riski olabilir (URL-22).

- Aşırı öğrenmenin aksine (overfitting) sınıflandırma için kullanılacak veri seti; eksik, yetersiz, gürültülü ve basit bir model yapısına sahip ise eksik öğrenme (underfitting) olma ihtimali yüksektir (URL-23).

Bu ve benzeri hatalar K-katmanlı çapraz doğrulama yöntemleri ile elemine edilerek modelin yüksek performansının rastgele olup olmadığının anlaşılmasını sağlamaktadır. K-katmanlı çapraz doğrulama yöntemi, makine öğrenmesi modeline dâhil olmayan veriler üzerindeki performansının doğru bir şekilde değerlendirmek için kullanılan istatistiksel bir yeniden örnekleme yöntemidir (URL-24). K-katlamalı çapraz doğrulama tekniğinde orijinal veri seti k sayıda parçaya bölünür, k-1 sayıdaki parça sınıflandırıcı modeli eğitmek için kullanılırken, geriye kalan parça ise modelin doğruluğunu hesaplamak için kullanılır. Her seferinde farklı eğitim ve test verisi kullanarak işlem k defa tekrarlanır (Kohavi, 1995). Her k değeri için elde edilen doğruluk değerlerinin ortalaması alınır, modelin doğruluğu ise bu ortalamaya eşit olmaktadır (Toosi ve ark, 2019).

Bu çalışmada k değeri 5 alınmış olup aşağıdaki sınıflandırma çalışması yapılan her yıla ait referans parsellerin %80'i eğitim %20'si test verisi olarak kullanılmış olup her k (k1, ..., k5) değeri için eğitim ve test verileri belirlenen yüzdelerde rastgele otomatik olarak seçilmiştir.

Çizelge 3.11 Eğitim ve test parsellerinin dağılımı


	Yıllar	Eğitim Verisi	Test Verisi	Toplam
Denizli	2017	9899	2475	12374
	2018	10983	2746	13729
	2019	11910	2977	14887
	2020	12029	3007	15036
	2021	7750	1938	9688
	2019	5498	1375	6873
Eskişehir	2020	4510	1127	5637

3.3.4. Sınıflandırma işlemi


Sınıflandırma çalışması açık kaynak kodlu python tabanlı EO-Learn kütüphanesi kullanılarak piksel tabanlı olarak yapılmıştır. Çalışmada makine öğrenmesi modeli olarak eo-learn-ml-tools alt paketi içerisinde bulunan Light GBM algoritması kullanılmıştır. Denizli Çivril-Baklan Ovası olan birinci çalışma alanında 2017 ve 2018 yılları için 21,

2019 ve 2020 yılları için 22, 2021 yılı için 23, Eskişehir Çifteler bölgesi olan ikinci çalışma alanında ise 2019 yılı için 21, 2020 yılı için ise 22 farklı zamanda çekilmiş Sentinel-2 görüntüleri ve bu görüntülerden üretilmiş NDVI, NDWI, SAVI indeksleri ile Tasseled Cap dönüşümleri sınıflandırma işleminde kullanılmıştır.

ÇKS beyanlı parsellerin temizlenmesi ile Denizli Çivril-Baklan Ovası'nda 2017 yılı için 12374, 2018 yılı için 13729, 2019 yılı için 14887, 2020 yılı için 15036, 2021 yılı 9688 parsel, Eskişehir Çifteler bölgesinde 2019 yılı için 6873, 2020 yılı için 5673 parsel, k-fold cross validation metoduyla otomatik olarak belirlenen eğitim ve test oranları ile sınıflandırma işleminde yer doğruluk verisi olarak kullanılmıştır.



Şekil 3.36 Denizli Çivril-Baklan Ovası 2020 yılı tarımsal ürün desen sınıflandırması (maskelenmemiş)




Şekil 3.37 Eskişehir Çifteler 2020 yılı tarımsal ürün desen sınıflandırması (maskelenmemiş)


3.3.5. Sınıflandırma sonuçlarının maskelenmesi

Temizlenmiş ÇKS beyanlı parseller, uydu görüntüleri ve bu görüntülerden oluşturulan indeksler ile EO-Learn kütüphanesi içerisindeki Light GBM algoritması kullanılarak piksel tabanlı sınıflandırma çalışması yapılmıştır. Sınıflandırma işlemi piksel tabanlı olduğundan çalışma alanı içerisinde kalan her bir piksel ilişki ve yakın olduğu sınıfa otomatik olarak atanmış olup tarımsal alanlar dışında kalan (yollar, nehirler, göller, kayalık ve çıplak alanlar, ormanlar, yerleşim yerleri) alanlar da sınıflandırmaya giren herhangi bir tarımsal ürün desenini temsil etmiştir. Söz konusu bu durum aynı zamanda sınıflandırma sonuçlarının istatistiki olarak değerlendirilmesinde de hataların oluşmasına sebep olacaktır.


Piksel tabanlı sınıflandırma sonucu Arazi Parsel Tanımlama Sistemi Projesi (LPIS) kapsamında üretilen fiziksel bloklardan A0 (ekilebilir arazi), A1 (dağınık ağaçlı ekilebilir arazi), A3(karışık tarımsal alan), S1(üzüm bağları) ve T0 (sürekli ağaç ürünü) sınıflarına ait poligonlar kullanılarak sınıflandırma sonucu maskelenmiştir. Bu işlem sonucunda hem Denizli Çivril-Baklan Ovası'nda hem de Eskişehir Çifteler bölgesinde bulunan çalışma alanları içerisinde sadece tarımsal alanlara ait sınıflandırma verisi kalmıştır.




Şekil 3.38 Denizli Çivril-Baklan Ovası'nı kapsayan fiziksel blokların görünümü




Şekil 3.39 Eskişehir Çifteler bölgesini kapsayan fiziksel blokların görünümü




Şekil 3.40 Denizli Çivril-Baklan Ovası 2017 yılına ait tarımsal ürün desen sınıflandırması




Şekil 3.41 Denizli Çivril-Baklan Ovası 2018 yılına ait tarımsal ürün desen sınıflandırması




Şekil 3.42 Denizli Çivril-Baklan Ovası 2019 yılına ait tarımsal ürün desen sınıflandırması



Şekil 3.43 Denizli Çivril-Baklan Ovası 2020 yılına ait tarımsal ürün desen sınıflandırması



Şekil 3.45 Eskişehir Çifteler 2019 yılına ait tarımsal ürün desen sınıflandırması



Şekil 3.46 Eskişehir Çifteler 2020 yılına ait tarımsal ürün desen sınıflandırması

3.4. Doğruluk Analizleri

3.4.1. Doğruluk Analizi-1

Piksel tabanlı sınıflandırma işlemi sonrasında, EO-Learn kütüphanesi içinde bulunan doğruluk analiz işlemlerini içeren jupyter notebook yardımıyla, tüm sınıflandırma işlemleri için her bir ürüne ait hata matrisi, F1 Score, duyarlılık (recall), kesinlik (precision) ve genel doğruluk (accuracy) değerleri hesaplanmıştır.

		Var olan Durum	
		Pozitif Durumlar	Negatif Durumlar
Tahmin	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3.47 Hata matrisine ait örnek

TP&TN: Sınıfların doğru tahmin edildiği rakamı verir

FP&FN: Sınıfların birbirleri ile olan yanlış tahmin adetlerini verir

Genel Doğruluk (Accuracy): Oluşturulan bir modelde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır. Bir modelin başarısını ölçmek için kullanılan ancak tek başına yeterli olamayan bir metriktir.

$$\text{Genel Doğruluk} = (TP + TN) / (TP + FP + TN + FN)$$

Recall: Pozitif durumların ne kadar başarılı tahmin edildiğini gösterir.

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

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

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

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

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

Çizelge 3.12 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2017-2019 yılı)

Denizli Çivril 2017								
Mısır	0,90	0,00	0,10	0,00	0,00	0,00	0,00	0,00
Hububat	0,00	0,99	0,00	0,00	0,00	0,00	0,01	0,00
Ayçiçeği	0,10	0,00	0,88	0,00	0,00	0,00	0,01	0,01
Yonca	0,01	0,00	0,02	0,93	0,04	0,00	0,00	0,00
M.Ağacı	0,00	0,00	0,00	0,01	0,97	0,01	0,00	0,00
Haşhaş	0,02	0,19	0,02	0,00	0,00	0,77	0,00	0,00
Şpancarı	0,04	0,00	0,00	0,00	0,01	0,01	0,93	0,00
Bağ	0,05	0,01	0,09	0,00	0,06	0,01	0,08	0,79
Denizli Çivril 2018								
Mısır	0,99	0,00	0,00	0,00	0,00	0,00	0,00	0,01
Hububat	0,00	0,99	0,00	0,00	0,00	0,00	0,02	0,01
Ayçiçeği	0,00	0,00	0,99	0,00	0,00	0,00	0,01	0,00
Yonca	0,01	0,00	0,02	0,96	0,01	0,00	0,00	0,00
M.Ağacı	0,05	0,00	0,01	0,01	0,89	0,01	0,00	0,03
Haşhaş	0,03	0,20	0,01	0,00	0,00	0,74	0,00	0,00
Şpancarı	0,06	0,01	0,01	0,00	0,01	0,00	0,90	0,01
Bağ	0,01	0,01	0,13	0,00	0,01	0,01	0,00	0,83
Denizli Çivril 2019								
Mısır	0,98	0,00	0,10	0,00	0,00	0,01	0,01	0,01
Hububat	0,00	0,98	0,00	0,00	0,00	0,00	0,02	0,00
Ayçiçeği	0,06	0,00	0,93	0,00	0,00	0,00	0,01	0,00
Yonca	0,01	0,00	0,02	0,96	0,01	0,00	0,00	0,00
M.Ağacı	0,04	0,00	0,01	0,01	0,94	0,01	0,00	0,00
Haşhaş	0,02	0,07	0,01	0,00	0,00	0,90	0,00	0,00
Şpancarı	0,32	0,00	0,00	0,00	0,00	0,00	0,68	0,00
Bağ	0,02	0,01	0,00	0,00	0,06	0,01	0,00	0,90
	Mısır	Hububat	Ayçiçeği	Yonca	M.Ağacı	Haşhaş	Şpancarı	Bağ

Çizelge 3.13 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2020-2021 yılı)

Denizli Çivril 2020								
Mısır	0,93	0,00	0,00	0,00	0,00	0,00	0,00	0,01
Hububat	0,00	0,99	0,00	0,00	0,00	0,00	0,02	0,01
Ayçiçeği	0,07	0,00	0,93	0,00	0,00	0,00	0,01	0,00
Yonca	0,01	0,00	0,02	0,96	0,01	0,00	0,00	0,00
M.Ağacı	0,01	0,00	0,01	0,01	0,97	0,00	0,00	0,00
Haşhaş	0,01	0,21	0,01	0,00	0,00	0,77	0,00	0,00
Şpancarı	0,05	0,00	0,00	0,00	0,00	0,00	0,94	0,01
Bağ	0,02	0,03	0,05	0,00	0,00	0,00	0,00	0,90
Denizli Çivril 2021								
Mısır	0,90	0,00	0,10	0,00	0,00	0,00	0,00	0,00
Hububat	0,00	0,99	0,00	0,00	0,00	0,00	0,01	0,00
Ayçiçeği	0,11	0,00	0,88	0,00	0,00	0,00	0,01	0,00
Yonca	0,01	0,00	0,02	0,93	0,01	0,01	0,00	0,02
M.Ağacı	0,00	0,00	0,01	0,01	0,97	0,01	0,00	0,00
Haşhaş	0,02	0,17	0,01	0,00	0,00	0,79	0,00	0,01
Şpancarı	0,04	0,00	0,00	0,00	0,00	0,02	0,93	0,01
Bağ	0,02	0,00	0,12	0,00	0,00	0,01	0,08	0,77
Mısır	Hububat	Ayçiçeği	Yonca	M.Ağacı	Haşhaş	Şpancarı	Bağ	

Çizelge 3.14 Denizli Çivril-Baklan Ovası sınıflandırmalarına ait F1, recall, precision ve doğruluk değerleri (2017-2021 yılı)

Sınıflandırma (2017)	Sınıflar	F1	Recall	Precision
	Mısır	92.5	91.4	93.2
	Hububat	97.4	98.6	96.3
	Ayçiçeği	90.3	91.7	89.0
	Yonca	96.2	94.8	97.8
	Meyve Ağacı	96.3	96.6	96.1
	Şeker pancarı	86.8	89.2	84.6
	Haşhaş	85.7	87.6	83.9
	Bağ	85.6	81.3	90.3
	Genel Doğruluk: %92.8			

Sınıflandırma (2018)	Sınıflar	F1	Recall	Precision
	Mısır	96.9	97.8	96.1
	Hububat	95.3	91.8	99.2
	Ayçiçeği	88.7	89.2	88.3
	Yonca	96.7	94.9	98.6
	Meyve Ağacı	91.7	89.2	94.5
	Şeker pancarı	85.2	83.2	87.3
	Haşhaş	79.6	78.3	81.1
	Bağ	84.6	82.3	87.1
	Genel Doğruluk: %94.7			

Sınıflandırma (2019)	Sınıflar	F1	Recall	Precision
	Mısır	97.3	98.0	96.8
	Hububat	94.6	94.8	94.5
	Yonca	96.3	94.7	98.0
	Meyve Ağacı	94.9	93.5	96.4
	Haşhaş	78.1	78.6	77.7
	Ayçiçeği	88.0	90.4	85.8
	Şeker pancarı	90.2	88.7	91.4
	Bağ	90.4	89.7	91.2
	Genel Doğruluk: %94.9			

Sınıflandırma (2020)	Sınıflar	F1	Recall	Precision
	Mısır	92.9	91.3	94.7
	Hububat	97.4	99.3	95.6
	Ayçiçeği	85.8	91.3	81.1
	Yonca	97.5	96.5	98.6
	Meyve Ağacı	96.3	96.0	96.6
	Haşhaş	82.8	74.8	93.3
	Şeker pancarı	91.3	91.3	91.4
	Bağ	91.2	88.9	93.7
	Genel Doğruluk: %93.5			

Sınıflandırma (2021)	Sınıflar	F1	Recall	Precision
	Mısır	92.3	92.4	92.2
	Hububat	98.2	99.2	97.3
	Ayçiçeği	90.9	92.3	89.6
	Yonca	95.8	94.1	97.7
	Meyve Ağacı	95.5	96.5	94.6
	Haşhaş	77.6	73.0	83.9
	Şeker pancarı	85.9	88.1	83.9
	Bağ	84.7	80.8	89.3
	Genel Doğruluk: %93.9			

Çizelge 3.15 Eskişehir Çifteler sınıflandırmasına ait hata matrisi (2019-2020 yılı)

Eskişehir Çifteler 2019							
Hububat	0,99	0,01	0,00	0,00	0,00	0,00	0,00
Nadas	0,04	0,91	0,02	0,00	0,00	0,01	0,01
Şpancarı	0,01	0,07	0,91	0,00	0,00	0,00	0,00
Mısır	0,01	0,03	0,00	0,95	0,01	0,01	0,00
Yonca	0,06	0,10	0,07	0,02	0,73	0,01	0,01
Ayçiçeği	0,00	0,01	0,01	0,01	0,00	0,84	0,13
Kabak	0,06	0,18	0,00	0,00	0,01	0,00	0,75
Eskişehir Çifteler 2020							
Hububat	0,97	0,02	0,10	0,00	0,00	0,00	0,01
Nadas	0,07	0,88	0,02	0,02	0,01	0,00	0,00
Şpancarı	0,06	0,00	0,92	0,00	0,01	0,00	0,01
Mısır	0,03	0,00	0,02	0,90	0,01	0,02	0,02
Yonca	0,06	0,00	0,03	0,01	0,87	0,01	0,02
Ayçiçeği	0,0	0,00	0,01	0,00	0,00	0,85	0,14
Kabak	0,02	0,16	0,02	0,01	0,01	0,01	0,76
	Hububat	Nadas	Şpancarı	Mısır	Yonca	Ayçiçeği	Kabak

Çizelge 3.16 Eskişehir Çifteler sınıflandırmalarına ait F1, recall, precision ve doğruluk değerleri (2019-2020 yılı)


Sınıflandırma (2019)	Sınıflar	F1	Recall	Precision
	Hububat	96.6	98.7	94.6
	Nadas	89.7	87.4	92.3
	Şeker pancarı	88.5	94.9	83.2
	Mısır	93.0	93.8	92.2
	Yonca	83.1	74.4	94.2
	Ayçiçeği	86.3	85.7	87.1
	Kabak	75.2	73.9	83.9
Genel Doğruluk: %92.4				

Sınıflandırma (2020)	Sınıflar	F1	Recall	Precision
	Hububat	96.6	98.1	95.3
	Nadas	88.8	86.6	91.1
	Şeker pancarı	92.7	97.4	88.5
	Mısır	87.2	84.1	90.9
	Yonca	84.9	77.8	93.8
	Ayçiçeği	87.0	82.7	92.0
	Kabak	79.3	84.8	74.5
Genel Doğruluk: %90.2				


3.4.2. Doğruluk Analizi-2

Piksel tabanlı sınıflandırma sonucu, sınıflandırma çalışmasında makine öğrenmesinde eğitim verisi olarak kullanılmayan TARSİM parselleri ile ikinci kere doğruluk analizi yapılmıştır. Makine öğrenmesinde eğitim verisi olarak kullanılmayan bu veriler ile sınıflandırma sonucunun kontrol edilmesi sınıflandırma sonucunun güvenilirliği ve doğruluğu bakımından da önem arz etmektedir.

Çalışma alanı ve yıllarına ait piksel tabanlı sınıflandırılmış raster veri ile TARSİM parselleri karşılaştırılmıştır. Eşik değeri (threshold) %85 olarak belirlenerek referans parseller içerisine raster verideki ürün bilgisi yazdırılmıştır. Hem referans parsellerin (TARSİM) çok sayıda olmasından hem de farklı yıllarda yapılan sınıflandırma sonuçları için bu işlem tekrarlanacağından FME WorkBENCH yazılımında bir iş akışı oluşturulmuştur. Oluşturulan iş akışları ile referans parsellerin içine belirlenen eşik değerinde ürün bilgisi yazdırılıp, arazi de var olan gerçek ürün deseni ile karşılaştırılması yapılmıştır.



Şekil 3.48 Sınıflandırma sonucu ile TARSİM parsellerinin üst üste görünümü



Şekil 3.49 FME WorkBENCH’ de oluşturulan iş akışı

Sınıflandırma sonuçlarının ikinci doğruluk analizinde hata matrisleri yöntemi kullanılmıştır. Hata matrisleri yine FME WorkBENCH kullanılarak programı kullanılarak oluşturulmuştur. Bir hata matrisi sınıf sayısı kadar satır ve sütundan oluşmakta olup satır ve sütunlarda sınıflandırma sonuç verileri ile referans veriler yer almaktadır. Hata matrisinde doğru sonuçlar satır ve sütun kesişimde bulunan diyagonal değerlerde olup, diğer değerler ise yanlış sınıfları temsil etmektedir.

Hata matrisi ile üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kappa değeri hesaplanmıştır. Test verilerinin sonuçlarının doğruluğu üretici doğruluğunu, eğitim verilerinin sonuçlarının doğruluğu kullanıcı doğruluğunu, doğru sınıflandırma sonucundaki verilerin eğitim verilerine bölünmesiyle genel doğruluk bulunur, Kappa değeri ise aşağıdaki formül ile hesaplanır.

$$\text{Üretici doğruluğu} = \frac{\text{Köşegen elemanı}}{\text{Sütun toplamı}} \quad \text{Kullanıcı doğruluğu} = \frac{\text{Köşegen elemanı}}{\text{Satır toplamı}}$$

$$\text{Genel doğruluk} = \frac{\text{Köşegen elemanlar toplamı}}{\text{Toplam veri}}$$

$$Kappa(\hat{\kappa}) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

N değeri toplam eğitim verisini, r sınıf sayısını, x_{ii} doğru sınıflandırılmış eğitim verisi toplamını, x_{+i} i satır toplamını, x_{i+} i sütun toplamını temsil etmektedir.

Çizelge 3.17 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2017 yılı)

Sınıflandırma (2017)	Referans Veri										
	Sınıflar	Ayçiçeği	Haşhaş	Hububat	Meyve A.	Mısır	Şeker P.	Bağ	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	657	1	0	5	14	0	0	1	678	96,90
	Haşhaş	0	74	4	0	1	0	0	0	79	93,67
	Hububat	0	3	143	0	1	0	0	0	147	97,28
	Meyve A.	3	0	2	442	6	2	1	2	458	96,51
	Mısır	17	0	6	4	328	0	1	1	357	91,88
	Şeker P.	5	0	0	0	0	29	0	0	34	85,29
	Bağ	3	9	3	3	2	1	12	1	34	35,29
	Yonca	5	1	0	0	0	1	0	58	65	89,23
	Toplam	690	88	158	454	352	33	14	63	1852	
	Üretici Doğruluğu (%)	95,22	84,09	90,51	97,36	93,18	87,88	90,00	91,24	Genel Doğruluk (%) 94,11 Kappa Katsayısı 0,92	

Çizelge 3.18 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2018 yılı)

Sınıflandırma (2018)	Referans Veri										
	Sınıflar	Ayçiçeği	Haşhaş	Hububat	Meyve A.	Mısır	Şeker P.	Bağ	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	379	2	2	0	8	1	0	0	392	96,68
	Haşhaş	9	230	22	3	5	0	0	1	270	85,19
	Hububat	4	42	184	8	6	0	0	3	247	74,49
	Meyve A.	0	0	1	355	3	0	0	3	362	98,07
	Mısır	27	0	0	0	283	2	0	2	314	90,13
	Şeker P.	4	1	1	1	1	20	0	0	28	71,43
	Bağ	1	3	8	4	7	0	6	0	29	20,69
	Yonca	2	8	1	3	0	0	1	49	64	76,56
	Toplam	426	286	219	374	313	23	7	58	1706	
	Üretici Doğruluğu (%)	88,97	80,42	84,02	94,92	90,42	86,96	85,71	84,48	Genel Doğruluk (%) 88,28 Kappa Katsayısı 0,86	

Çizelge 3.19 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2019 yılı)

Sınıflandırma (2019)	Referans Veri										
	Sınıflar	Ayçiçeği	Haşhaş	Hububat	Meyve A.	Mısır	Şeker P.	Bağ	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	100	2	2	0	34	1	0	0	139	71,94
	Haşhaş	0	407	3	0	8	0	1	1	420	96,90
	Hububat	3	29	106	6	4	0	1	0	149	71,14
	Meyve A.	1	1	1	230	9	0	0	1	243	94,65
	Mısır	10	3	0	0	977	1	0	2	993	98,39
	Şeker P.	3	2	1	0	2	11	0	1	20	55,00
	Bağ	1	0	6	6	6	0	10	0	29	34,48
	Yonca	2	7	1	0	3	0	0	61	74	82,43
	Toplam	120	451	120	242	1043	13	12	66	2067	
	Üretici Doğruluğu (%)	83,33	90,24	88,33	95,04	93,67	84,62	83,33	92,42	Genel Doğruluk (%) 92,02 Kappa Katsayısı 0,89	

Çizelge 3.20 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2020 yılı)

Sınıflandırma (2020)	Referans Veri										
	Sınıflar	Ayçiçeği	Haşhaş	Hububat	Meyve A.	Mısır	Şeker P.	Bağ	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	233	7	3	0	22	2	0	2	269	86,62
	Haşhaş	0	585	12	6	1	1	0	2	607	96,38
	Hububat	0	27	194	4	0	1	1	3	230	84,35
	Meyve A.	2	2	1	260	3	0	1	0	269	96,65
	Mısır	15	8	4	0	425	2	0	3	457	93,00
	Şeker P.	7	3	6	0	10	41	0	2	69	59,42
	Bağ	8	8	3	3	0	1	18	1	42	42,86
	Yonca	6	0	0	5	7	0	0	111	129	86,05
	Toplam	271	640	223	278	468	48	20	124	2072	
	Üretici Doğruluğu (%)	85,98	91,41	87,00	93,53	90,81	85,42	90,00	89,52	Genel Doğruluk (%) 90,11 Kappa Katsayısı 0,89	

Çizelge 3.21 Denizli Çivril-Baklan Ovası sınıflandırmasına ait hata matrisi (2021 yılı)

Sınıflandırma (2021)	Referans Veri										
	Sınıflar	Ayçiçeği	Haşhaş	Hububat	Meyve A.	Mısır	Şeker P.	Bağ	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	344	5	9	1	19	1	0	4	383	89,82
	Haşhaş	4	577	25	0	4	0	0	3	613	94,13
	Hububat	3	30	422	0	5	0	0	3	463	91,14
	Meyve A.	2	7	3	265	4	0	2	1	284	93,31
	Mısır	12	7	6	9	320	2	0	0	356	89,89
	Şeker P.	1	0	1	0	3	29	0	1	35	82,86
	Bağ	3	11	4	1	0	0	18	0	37	48,65
	Yonca	5	9	5	2	0	0	0	125	146	85,62
	Toplam	374	646	475	278	355	32	20	137	2317	
	Üretici Doğruluğu (%)	91,98	89,32	88,84	95,32	90,14	90,63	90,00	91,24	Genel Doğruluk (%) 90,63 Kappa Katsayısı 0,88	

Çizelge 3.22 Eskişehir Çifteler sınıflandırmasına ait hata matrisi (2019 yılı)

Sınıflandırma (2019)	Referans Veri									
	Sınıflar	Ayçiçeği	Kabak	Hububat	Nadas	Mısır	Şeker P.	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	154	11	3	0	8	2	2	180	85,56
	Kabak	10	108	3	6	4	1	2	134	80,60
	Hububat	0	2	138	2	0	1	3	146	94,52
	Nadas	2	2	1	98	3	0	0	106	92,45
	Mısır	5	2	2	0	154	2	3	168	91,67
	Şeker pancarı	4	3	3	0	6	254	0	270	94,07
	Yonca	7	0	0	5	4	0	138	154	89,61
	Toplam	182	128	150	111	179	260	148	1158	
	Üretici Doğruluğu (%)	84,62	84,38	92,00	88,29	86,03	97,69	93,24	Genel Doğruluk (%) 90,15 Kappa Katsayısı 0,87	

Çizelge 3.23 Eskişehir Çifteler sınıflandırmasına ait hata matrisi (2020 yılı)

Sınıflandırma (2019)	Referans Veri									
	Sınıflar	Ayçiçeği	Kabak	Hububat	Nadas	Mısır	Şeker P.	Yonca	Toplam	Kullanıcı Doğruluğu (%)
	Ayçiçeği	76	11	3	1	6	1	4	102	74,51
	Kabak	12	92	3	0	4	0	3	114	80,70
	Hububat	1	2	75	2	0	1	1	82	91,46
	Nadas	1	3	2	50	2	0	0	58	86,21
	Mısır	6	1	2	4	178	2	0	193	92,23
	Şeker pancarı	8	5	3	0	9	311	1	337	92,28
	Yonca	0	6	3	2	0	0	143	154	92,86
	Toplam	104	120	91	59	199	315	152	1040	
	Üretici Doğruluğu (%)	73,08	76,67	82,42	84,75	89,45	98,73	94,08	Genel Doğruluk (%) 88,94 Kappa Katsayısı 0,86	

4. BULGULAR VE DEĞERLENDİRME

Bu çalışmada, sınıflandırma çalışmalarında Sentinel-2 görüntüleri 15 günlük aralıklarla temin edilmiş olup, birinci çalışma alanı olan Denizli Çivril-Baklan Ovası'nda 2017 ve 2018 yılları için 21 farklı görüntü ile bu görüntülerden oluşturulan indeksler ve dönüşümlerle (21×12) 252 farklı özellik kullanılmıştır. 2019 ve 2020 yılları için 22 farklı görüntü 264 özellik, 2021 yılı için 23 farklı görüntü 276 özellik kullanılmıştır. İkinci çalışma alanı olan Eskişehir Çifteler bölgesinde ise 2019 yılı için 21 farklı görüntü 252 özellik, 2020 yılı için ise de 22 farklı görüntü 264 özellik sınıflandırma işleminde raster veri olarak kullanılmıştır.

Beyan esaslı bu parsellerin arazi gerçeği verisi olarak kullanılmasından önce çeşitli CBS programları yardımıyla öncelikle öznitelik temizleme ve geometrik düzenleme işlemleri gerçekleştirilmiştir. Bu işlemlerden sonra geliştirilen yöntem ve yazılım yardımıyla parsel tabanlı ve piksel tabanlı temizleme işlemi yapıp sınıflandırma çalışması için arazi gerçeği verisi haline getirilmiştir. Denizli Çifteler bölgesinde 2017 yılı için 74789 parselden 12374 adedi, 2018 yılı için 74564 parselden 13729 adedi, 2019 yılı için 73988 parselden 14887 adedi, 2020 yılı için 74833 parselden 15036 adedi, 2021 yılı için 76972 parselden 9688 adedi, ikinci çalışma alanı olan Eskişehir Çifteler bölgesinde ise 2019 yılı 33882 parselden 6873 adedi 2020 yılı için 20918 parselden 5637 adedi uygulanan düzeltme ve silme işlemleri sonrasında referans veri olarak sınıflandırma çalışmasında kullanılmıştır.

Sınıflandırma çalışması EO-Learn kütüphanesi içerisindeki Light GBM algoritması kullanılarak yapılmıştır. Hiperparametre optimizasyon işlemi yapılarak sınıflandırma için en uygun parametreler belirlenmiş olup, eğitim ve test verilerinin ayrılmasında K-katmanlı çapraz doğrulama yöntemi kullanılmıştır.

Çalışmada sınıflandırma sonucunun analizinde ise iki farklı veri ile iki farklı doğruluk analizi yapılmıştır. K katmanlı çapraz doğrulama yöntemi ile %80 eğitim ve %20 test verisi şeklinde tekrarlı olarak (k=5) ayrılan veri ile yapılan analiz birinci doğruluk analizidir.

Birinci doğruluk analizinde her bir sınıflandırma sonucu için Recall, Precision, F1 ve genel doğruluk değerleri hesaplanmıştır. Birinci çalışma alanı olan Denizli Çivril-Baklan Ovası'nda, sınıflandırma sonuçları incelendiğinde 2017,2018,2019, 2020 ve 2021 yıllarına ait sınıflandırma sonuçlarında genel doğruluğun ortalama %94 (Çizelge 3.14) olduğu görülmektedir. Eskişehir Çifteler bölgesindeki çalışma alanında ise 2019 yılı

sınıflandırma sonucuna ait genel doğruluk %92.4 iken 2020 yılına ait genel doğruluk %90.2'dir. (Çizelge 3.16).

Denizli Çivril Ovasında sınıf bazında doğruluklar incelendiğinde (Çizelge 3.14) yonca ve hububat sınıfları ortalama %96 ile en yüksek doğruluk değerlerini verdiği, yonca ve hububat sınıflarını, % 92-95 doğruluk değer aralığı ile mısır sınıfının izlediği görülmektedir. Meyve ağacı sınıfı o % 92-96 aralığında olup, ayçiçeği, şeker pancarı ve bağ sınıfları için doğruluk oranı o %85-90 seviyesi aralığındadır. Sınıflandırma işleminde en düşük doğruluk oranını ise %77-84 aralığı ile haşhaş sınıfı oluşturmaktadır. Haşhaş sınıfı belirli bir oranda hububat sınıfına geçmiş olup hata matrisinde de gözükmemektedir. Eskişehir Çifteler bölgesinde sınıf bazında doğruluklar incelendiğinde (Çizelge 3.16) ise en yüksek doğruluk %96 ile hububat sınıfı olup, hububat sınıfını % 87-92 doğruluk oranı ile mısır, nadas ve şeker pancarı sınıfları izlemektedir. Yonca sınıfı 2019 yılında %82.5 doğrulukta iken 2020 yılında %84.5 doğrulukta olup, şeker pancarı sınıfı ise 2019 yılında %88.5 doğrulukta iken 2020 yılında %92.7 seviyesine çıkmıştır.

Sınıflandırma çalışmasında eğitim verisi olarak kullanılmayan, dışardan bir veri olarak sadece test verisi olarak kullanılan TARSİM parselleri ile ikinci bir doğruluk analizi çalışması yapılmıştır. İkinci doğruluk analizinde sınıflandırma yapılan her yıl için ürün seviyesinde üretici doğruluğu ve kullanıcı doğruluğu değerleri hesaplanmış olup, her yıla ait genel doğruluk ile kappa değerleri de hesaplanmıştır.

Denizli Çivril Ovasındaki sınıflandırma sonuçları incelendiğinde; 2017 yılına ait genel doğruluk değeri %94.11, 2019 yılına ait genel doğruluk değeri %92.02, 2020 yılına ait genel doğruluk değeri %90.11, 2021 yılına ait genel doğruluk değeri %90.63 olup (Çizelge 3.17-3.19-3.20-3.21) bu değerler EO-Learn kütüphanesi ve içindeki Light GBM algoritması ile tarımsal ürünlerin yüksek doğrulukta tespit edildiğini göstermektedir. 2018 yılında ise haşhaş ve hububat sınıflarında karşılıklı geçiş olup bu ürünlerin karışmasından kaynaklı olarak genel doğruluk değeri %88.28 seviyesindedir (Çizelge 3.18). Sınıflandırma işlemi sonrası hata matrisinden hesaplanan kappa katsayısı değeri 0.9'dur, bu değer istatistiki olarak yorumlandığında, çalışma alanına ait fiziksel yeryüzü 1 kabul edildiğinde, çalışma alanındaki tarımsal üretim yapılan alanlar, sınıflandırma sonucu tematik harita ile oluşturulan ürün desenine % 90 oranında yaklaştığını göstermektedir. Eskişehir Çifteler bölgesinde 2019 yılına ait genel doğruluk değeri %90.15, 2020 yılına ait genel doğruluk değeri ise %88.94'dür. Hata matrisinden hesaplanan kappa katsayısı değerleri 2019 yılı için 0.87, 2020 yılı için ise 0.86 olarak hesaplanmıştır (Çizelge 3.22-3.23).


Denizli Çivril Ovasındaki her yıla ait sınıflandırma sonuçları hata matrisi yardımıyla ürün bazında incelendiğinde, ayçiçeği sınıfından mısır sınıfına, mısır sınıfından ayçiçeği sınıfına, hububat sınıfından haşhaş sınıfına, haşhaş sınıfından ise hububat sınıfına geçiş olduğu görülmüş olup, ayçiçeği ile mısır sınıfının, hububat ile de haşhaş sınıfının bir miktar karıştığı tespit edilmiştir. Eskişehir Çifteler bölgesindeki hata matrisi incelendiğinde ise ayçiçeği ile kabak sınıfları arasında karşılıklı geçiş olmuş olup sınıfların bir miktar karıştığı sonucuna ulaşılmıştır. Diğer ürünlerin birbirleri ile arasında belirgin bir karışımı olmadığı tespit edilmiştir.

Tarımsal ürünlerin uydu görüntüleri ile çeşitli algoritmalar yardımıyla sınıflandırılmasında ürünlerin ekim, gelişim ve hasat tarihlerinin bilinmesi ve bu tarihlerde çok zamanlı görüntü alınması, ürünler arasındaki zamansal değişimleri ortaya koyduğundan çok önemlidir. Çalışmada 15 gün aralıklı çok zamanlı görüntüler alınmasına rağmen Denizli Çivril Ovasında ayçiçeği ve mısır sınıflarının, haşhaş ile de hububat sınıflarının ekim gelişim ve hasat dönemlerinin birbirine yakın olduğu, Eskişehir Çifteler bölgesinde ise kabak ayçiçeği sınıflarının fenolojik gelişimlerinin neredeyse bire bir aynı olduğu görülmektedir (Şekil 3.12 - 3.13). Bu sınıfların birbirlerine yakın yansıma değerleri vermesi sebebiyle, algoritma sınıflandırma çalışmasında bu sınıfları yüksek doğrulukta birbirinden ayıramadığı ve sınıfların belirli bir miktar olsa da karıştığı tespit edilmiş olup hem birinci hem de ikinci doğruluk analizine ait hata matrisinde görülmektedir. Sınıflandırma çalışması sonucunda her iki çalışma alanı için ürünlere ait alansal dağılım Çizelge 4.1 - 4.2 - 4.3 ve 4.4'de gösterilmektedir.

Çizelge 4.1 Denizli Çivril-Baklan Ovası sınıflandırılan ürünlerin alansal dağılımı

		2017	2018	2019	2020	2021
Denizli Çivril (hektar)	Ayçiçeği	12227.69	8521.60	3574.13	9956.60	6558.08
	Haşhaş	1271.34	3676.10	7801.92	3129.90	8420.77
	Hububat	11807.90	14722.40	12707.35	11560.52	20346.72
	Meyve Ağacı	9870.90	10200.73	9007.29	8967.62	9242.02
	Mısır	14530.50	13013.28	18128.52	17069.37	5421.43
	Şekerpancarı	977.50	1247.36	1205.37	1218.78	547.50
	Bağ	3388.25	3718.08	3196.33	3953.51	1951.95
	Yonca	5894.96	4869.49	4347.73	4138.01	7022.27

Çizelge 4.2 Denizli Çivril-Baklan Ovası'nda sınıflandırılan ürünlerin alansal dağılımı




Çivril Ovasındaki sınıflandırma sonucu ürünlerin alansal dağılımı incelendiğinde, 2017-2020 yılları arasında ovada %50-%60 oranında sulu tarım (ayçiçeği, mısır, şekerpancarı, yonca) yapıldığı, 2021 yılında ise bu oranın %30 seviyelerine kadar gerilediği görülmektedir. Özellikle ovayı besleyen Çivril Gölünün 2020 yılında kuraklıktan aşırı etkilenecek su seviyesinin çok gerilediği bu sebeple de 2021 yılında ovanın yalnızca % 50'sine su verileceği bilgisinden dolayı çiftçilerde kuru tarıma yönelim

olduğu yapılan sınıflandırma sonucu da tespit edilmiştir. Söz konusu bu durum ÇKS beyanlı parsel dağılımı ile de paralel olup çizelge 4.5 ile şekil 4.1’de görülmektedir.

Çizelge 4.3 Eskişehir-Çifteler sınıflandırılan ürünlerin alansal dağılımı


		2019	2020
Eskişehir Çifteler (Hektar)	Ayçiçeği	3522.69	2949.09
	Mısır	2884.32	3348.91
	Yonca	1009.78	1058.78
	Şekerpancarı	4112.85	4558.41
	Kabak	2632.65	2959.24
	Nadas	7448.52	7874.56
	Hububat	23771.77	22633.59

Çizelge 4.4 Eskişehir-Çifteler bölgesinde sınıflandırılan ürünlerin alansal dağılımı




Eskişehir Çifteler bölgesindeki sınıflandırma sonucu incelendiğinde ise, bölgenin % 50’sinde kuru tarım alanlarının hâkim olduğu, % 17’lik kısmının nadas geriye kalan %23’lük kısmını ise sulu tarım alanlarının oluşturduğu görülmektedir.

Çizelge 4.5 Denizli Çivril Baklan Ovası ÇKS beyanlı parsel dağılımı




	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Ayçiçeği	5965	7389	5685	4645	3211	2908	3740	5981	12112	12531	11856	17305	16455	17127	17658	12204	3743	9403	8488
Haşhaş	3048	1394	1559	2147	3981	3376	4552	4893	4601	4420	4926	3561	7069	3129	2508	5056	8996	7212	8820
Hububat	41654	43345	42521	36475	35614	35453	33931	30677	29695	28262	27960	25396	22453	20782	16232	19679	17997	17838	27243
Meyve Ağacı	6467	5985	6411	6947	7787	7988	8378	8744	10255	10193	10008	12242	12795	13236	13049	11753	12721	11970	13817
Mısır	948	1926	3434	2537	3172	2476	4006	4519	6015	6201	7608	6121	6788	10535	15094	15062	19856	18534	8430
Şekerpancarı	1623	1325	2172	1641	1027	723	557	706	1209	977	1016	936	957	1086	1461	1225	1290	1491	705
Üzüm	7357	6786	6455	11200	11386	11371	11681	15716	5995	6117	5700	5613	5101	4550	4160	3684	4004	3599	3736
Yonca	1315	1393	1730	1819	1949	1955	1834	1708	2058	2266	2435	2348	2350	4445	4627	5901	5381	4786	5733
Toplam	68377	69543	69966	67411	68129	66250	68678	72944	71940	70967	71509	73522	73968	74890	74789	74564	73988	74833	76972


Çizelge 4.6 Eskişehir Çifteler bölgesi ÇKS beyanlı parsel dağılımı



	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Ayçiçeği	1215	975	1011	816	753	941	920	763	824	848	754	647	801	713	802	747	717	599	750
Hububat	8148	7645	7173	6848	8250	7754	7123	7002	6879	6758	7250	7400	7312	6945	7347	7542	8537	5389	5820
Kabak	645	945	715	648	750	680	770	823	721	654	732	751	721	845	675	802	812	701	715
Mısır	818	754	815	745	1020	886	802	1051	904	811	803	816	675	678	725	714	707	662	811
Nadas	2345	2879	2645	2244	2679	2515	2845	1746	3004	2007	2864	1423	2715	1546	3014	1875	3123	1984	3430
Şekerpancarı	741	804	777	769	803	757	911	692	790	763	699	812	859	751	877	845	956	728	1002
Yonca	808	741	622	602	744	796	804	645	632	546	537	601	502	587	555	673	504	522	613
Toplam	14720	14743	13758	12672	14999	14329	14175	12722	13754	12387	13639	12450	13585	12065	13995	13198	15356	10585	13141



Şekil 4.1 Denizli Çivril Baklan Ovası'nda ÇKS beyanlı parsellerin değişimi




Şekil 4.2 Eskişehir Çifteler bölgesinde ÇKS beyanlı parsellerin değişimi

Denizli Çivril-Baklan Ovası sınırları içerisinde kalan ve yaklaşık 20 yıllık süreci kapsayan ÇKS beyanlı parsel dağılımı incelendiğinde, su tüketimine az miktarda ihtiyaç duyan hububat ve haşhaş ürünlerinin (kışlık ürünler) yıllar içerisinde ekiminin azaldığı,

fazla su tüketimine ihtiyaç duyan ayçiçeği, mısır, şekerpancarı ve yonca (yazlık ürünler) ürünlerinin ise yıllar içerisinde ekimin arttığı görülmektedir. Meyve ağacı ve üzüm gibi çok yıllık ürünlerde ise 2005 ile 2010 yılları arasında %10'luk bir artış olduğu sonrasında ise sabit kaldığı sonucuna ulaşılmıştır. 2003 yılında ÇKS beyanlı parsel dağılımı incelendiğinde ovanın % 67.7'sini kışlık ürünlerin (hububat-haşhaş) %12'sini ise yazlık ürünlerin (ayçiçeği-mısır-şekerpancarı-yonca) oluşturduğu görülmektedir (Şekil 4.1). 2017 yılında ise Çivril-Baklan Ovası'nın %50'dan fazlasını yazlık ürünler oluştururken, kışlık ürünlerin oranının ise %30 seviyelerine kadar gerilediği tespit edilmiştir.

Eskişehir Çifteler bölgesindeki beyan esaslı parsellerin dağılımı incelendiğinde, hububat sınıfının % 50 - 60 aralığında olduğu, nadas sınıfının % 12-20 aralığında olduğu, yazlık ürünleri oluşturan ayçiçeği, mısır, şeker pancarı, yonca ve kabak ürünlerinin ise %30 aralığında olup bölgede kuru tarım alanları ile sulu tarım alanlarının yıllar içerisinde sabit kaldığı görülmektedir (Şekil 4.2).

Ovada tarımsal sulamanın en büyük hatta tek kaynağı RAMSAR sözleşmesine göre A grubu sulak alan kategorisinde bulunan ve koruma altına alınan Işıklı ve Gökgöl gölleridir. 1992 yılında faaliyete geçen Çivril-Baklan Sulama Projesi ile tarımsal sulamada kullanılmak üzere gölden su çekilmeye başlanmıştır (Özdemir ve Tatar, 2017). Proje ile ovayı besleyen sulama kanallarının yıllar içerisinde artması ve ovayı çevrelemesi ile çiftçiler su tüketimi fazla olan yazlık ürünlere (ayçiçeği-mısır-şekerpancarı-yonca) doğru yönelim göstermişlerdir. Fakat son yıllarda özellikle küresel ısınma kaynaklı aşırı kuraklık yaşanması ve yağış azlığı sebebiyle göldeki su seviyesi giderek azalmaktadır. Bu durumdan kaynaklı 2020 yılında DSİ ve sulama birlikleri, 2021 yılı için Ovanın sadece %50 kapasite ile sulanacağını kararını almıştır. Karar doğrultusunda ise çiftçiler 2021 yılı için az su tüketen kışlık ürünlerin ekimine yönelmişlerdir. Söz konusu bu durum hem ÇKS beyanlı parseller de hem de sınıflandırma sonucunda da görülmektedir. 2020 yılında %25 seviyesindeki kuru tarım alanları 2021 yılında %48 seviyesine yükselmiş olup, %60 olan sulu tarım alanları ise yüzde %37 seviyelerine gerilemiştir. 1985-2021 yılları arası, ağustos ayı Landsat uydusuna ait yalancı renk kombinasyonu ile incelendiğinde, 1985 yılında ovada nerdeyse yazlık ürün ekiminin hiç olmadığı, sulama projesinin başlamasının sonucu olarak 1995 yılında yazlık ürün ekiminde bariz bir artış olduğu, süre gelen yıllarda ise yazlık ürün ekiminin artarak devam ettiği görülmektedir. 2020 ve 2021 yıllarındaki uydu görüntüleri incelediğinde ise, sulama suyunun azaltılması kaynaklı 2021 yılında yazlık ürün ekiminin 2020 yılına göre düştüğü görülmektedir (Şekil 4.3)



Şekil 4.3 Civril-Baklan Ovası üzerindeki yazlık ürün ekiminin yıllar içerisindeki değişimi

5. SONUÇLAR VE ÖNERİLER

Çok sayıda yer doğruluk verisinin kullandığı çok zamanlı (multi-temporal) görüntülerle yapılan çalışmalarda görüntü ön işleme işlemleri (pre-image processing) ve sınıflandırma çalışmaları çok zaman alabilmektedir. Özellikle tarımsal ürün desen sınıflandırması gibi birçok görüntünün kullanıldığı çalışmalarda çok miktarda veri olup çalışma alanı genişledikçe iş yükü artmakta dolayısıyla işlem süreçleri de uzamaktadır. Bunun yanı sıra sınıflandırma çalışması öncesi görüntü işleme aşamalarında her farklı iş kalemi için farklı yazılım ya da farklı kütüphaneler kullanılabilmekte olup kullanıcılar tarafından da çalışmalarda kimi zaman bir bütünlük sağlanamamaktadır.

Bu tez çalışmasında, çalışma alanını kapsayan uydu görüntülerinin istenilen tarih aralığında ve sıklığında bir bütün olarak görüntü yığını şeklinde indirilmesi, görüntü üzerindeki bulut ve bulut kaynaklı gölge alanların belirlenmesi, belirlenen alanların maskelenmesi, farklı çözünürlükteki bantların yeniden örneklendirilmesi, birleştirilmesi, bantlardan farklı indekslerin ve özelliklerin oluşturulması, vektör ve raster veri dönüşümleri, eğitim ve test verilerinin otomatik olarak ayrılması, makine öğrenmesi ile sınıflandırma çalışmasının yapılması ve son aşama olan hata matrisleri ile doğruluk analizi işlemleri, açık kaynak kodlu Eo-Learn kütüphanesi ve kütüphane içerisindeki entegre iş akışları ile bir bütünlük içerisinde hızlı ve otomatik olarak yapılmıştır.

Tez çalışması kapsamında Denizli Çivril-Baklan Ovası'nda (60000 hektar), 2017-2021 tarihleri arasında beş farklı tarihte, Eskişehir İli Çifteler bölgesinde ise (45000 hektar) 2019 ve 2020 yılları olmak üzere iki farklı tarihte, yedi farklı tarımsal ürün desen sınıflandırma çalışması açık kaynak kodlu Eo-Learn kütüphanesi ile yapılmış ve yüksek başarımlar sağlamıştır. Her bir çalışmada 250'den fazla farklı özellik içeren bant, raster veri olarak sınıflandırma işlemine dâhil edilmiştir.

Tarımsal ürün desen tespitinde, ürünlerin fenolojik evrelerini kapsayan ve benzer fenolojiye sahip ürünlerin birbirinden ayrılabilmesini sağlayan çok zamanlı görüntülerin kullanılması hem yer doğruluk verisinin oluşturulmasında hem de sınıflandırma çalışmasında çok önemlidir. Ürünlerin fenolojik süreçlerinde gösterdikleri değişimler geri yansıma değerlerini etkilemektedir. Geri yansıma değerlerindeki bu değişimler ürünlerin birbirlerinden ayrılması ve aynı zamanda karışmasını da engellemekte olup, hem yer doğruluk verisinin oluşturulmasında referans olarak kullanmakta hem de sınıflandırma çalışmalarında başarımları artırmaktadır. Bu çalışma kapsamında, her yıl için yaklaşık 22 farklı tarihteki NDVI görüntüsü ve arazide ürün bilgisi kaydedilen az sayıdaki

parcel kullanılarak, sınıflandırılacak ürünlere ait referans spektral ayrılma eğrileri oluşturulmuş ve ÇKS beyanlı parsellerin temizlenmesi işleminde bu eğriler referans olarak kullanılmıştır.

Makine öğrenmesi algoritmaları ile sınıflandırma çalışmalarında modelin eğitilmesi için bir diğer girdi veri seti olan referans verilerin (arazi gerçeği verilerinin) kullanılması gerekmektedir. Büyük alana sahip iki farklı çalışma alanında araziden çok sayıda veri toplamak hem maliyetli hem de zaman alan bir eylem olup, her yıl için de bu işlemi tekrarlamak sürdürülebilir değildir. Bu sebeple de ÇKS beyanlı parsellerin sınıflandırma çalışmasında arazi gerçeği verisi olarak kullanılması amaçlanmıştır. ÇKS beyanlı parseller incelendiğinde ise birbirinden farklı ve çeşitli hatalar içerdiği ayrıca beyanların ciddi bir oranda gerçeği temsil etmediği tespit edilmiştir. Beyan esaslı bu parsellerden yer doğruluk verisi oluşturmak için bir dizi işlem adımı uygulanmış ve hatalı parsellerin elemine edilmesi için bir uygulama geliştirilmiştir. İlk olarak parsellerin öznitelik ve geometrik olarak düzenlenme işlemi yapılmış sonrasında ise özgün olarak geliştirilen uygulama ile zaman serisi NDVI görüntüleri ve referans parsellere ait spektral ayrılma eğrileri kullanılarak parsel tabanlı temizleme işlemi uygulanmıştır. Üçüncü ve son aşama olarak parsel tabanlı vektör veri raster veriye dönüştürülerek ve yine zaman serisi NDVI görüntüleri kullanarak piksel tabanlı temizleme işlemi ile beyan esaslı parseller sınıflandırma çalışmasında yer doğruluk verisi (arazi gerçeği verisi) olarak kullanılmıştır.

Yapılan sınıflandırma çalışması sonucunda EO-Learn kütüphanesi içerisindeki hata matrisleri ile birinci doğruluk analizi yapılmıştır. Denizli Çivril-Baklan Ovası'nda 5 farklı yılda yapılan sınıflandırma sonucunda genel doğruluk oranı ortalama %93, Eskişehir Çifteler bölgesinde ise iki farklı yılda yapılan sınıflandırma sonucunda genel doğruluk oranında ortalama %91 seviyesine ulaşmıştır. Yapılan sınıflandırma çalışması ve birinci doğruluk analizleri incelendiğinde yakın fenolojik evrelere sahip ürünlerin birbirleri ile miktar karıştığı sonucuna varılmıştır. Söz konusu bu durum, yakın fenolojik evrelere sahip ürünlerin birbirlerinden daha belirgin olarak ayrılması ve özellikle bu sınıflara ait sonuçlarının daha yükseğe çıkarılması için, farklı spektral aralıktaki bantlar ile farklı indekslerin kullanılarak, yapılacak sınıflandırma çalışmalarında denenmesi gerektiği durumunu ortaya koymuştur. Birinci doğruluk analizi sonrasında TARSİM parselleri ile ikinci bir doğruluk analizi çalışması yapılmıştır. İkinci doğruluk analizinde Denizli Çivril-Baklan Ovası'nda beş farklı yılda yapılan sınıflandırma sonucunda genel doğruluk ortalama % 91 oranında olup Eskişehir Çifteler bölgesinde ise iki farklı yılda

genel doğruluk ortalama % 90 olarak tespit edilmiştir. Sınıflandırma çalışması sonucunda, makine öğrenmesi modelinde eğitim verisi olarak kullanılmayan, sadece test verisi olarak kullanılan TARSİM parselleri ile yapılan ikinci doğruluk analizlerinin de yüksek skorlar vermesi sınıflandırma çalışmasının başarılı olduğunu bir kez daha göstermiştir. TARSİM parselleri ile yapılan doğruluk analizinin yüksek olması, geliştirilen yöntem ile yapılan sınıflandırmanın doğru ve güvenilir olduğunun da kanıtı olmuştur.

Geliştirilen yöntem ve açık kaynak kodlu Eo-Learn kütüphanesi kullanılarak, iki farklı alanda, toplamda on farklı üründe, yedi farklı sınıflandırma çalışmasında, her iki doğruluk analizinin hem ürün hem de genel doğruluk seviyesinde yüksek sonuçlar vermesi, çalışmanın başarılı, güvenilir ve sürdürülebilir olduğunu göstermesinin yanı sıra spesifik bir bölge, tarih ve ürüne bağlı kalmadığını, farklı alan, tarih ve ürünlerde de uygulanabileceğini ispatlamıştır.

Denizli Çivril-Baklan Ovası ve Eskişehir Çifteler bölgesinde 2021 yılları için R yazılımı ile bütün işlem adımlarının manuel olarak yapıldığı klasik makine öğrenmesi yöntemleri ile de sınıflandırma çalışması tekrarlanmıştır. İki farklı bölgede yapılan sınıflandırma sonucunda, ham görüntülerin indirilmesinden sınıflandırma çalışması sonunda oluşturulan tematik haritaya kadar kullanılan tüm verilerin toplamı kıyaslandığında, numpy formatında çok boyutlu dizin olarak tutulan Eo-Learn kütüphanesinin içindeki verilerin, klasik yöntemle yapılan çalışmaya kıyasla 10 kat daha az veri boyutu kapsadığı ve tüm işlemler sonucundaki toplam sürenin ise 14 kat daha kısa olduğu sonucuna varılmıştır.

81 il ve 973 ilçeyi kapsayan 10 milyonun üzerindeki parsel her sene ÇKS'ye kayıt edilmektedir. Tarımsal ürün desen bilgisi içeren bu parsellerden, iklim, doğal bitki örtüsü, toprak yapısı, tarımsal ürünlerin dağılımı gibi kriterler kullanılarak ova veya coğrafi bölge ölçeğinde yer doğruluk verisi oluşturularak, yüksek kapasite ve donanımlı sunucularda EO-Learn kütüphanesinin çalıştırılması ile tarımsal ürün desen sınıflandırmasının her sene bölgesel ve ülkesel ölçekte uygulanabileceğini bu tez çalışması göstermektedir.

Ülkemizde ortalama 2 milyon işletme ile 15 milyon hektar alan ÇKS'ye kayıtlı bulunmakta olup bu kayıtlar ise her sene yenilenmektedir. ÇKS'ye kayıtlı bu işletmeler birçok farklı destekleme çeşidinden yararlanmakta olup, ekilen ürün çeşidine göre verilen (Kr/Kg) fark ödemesi desteği, tarımsal desteklemelerdeki en büyük kalemlerden bir tanesidir. Geçmişten günümüze ÇKS beyanlı parseller incelendiğinde ürün beyanı ile ekilen ürün arasında, hem ürün çeşidi hem de alansal olarak sapmalar ve farklılıklar

olduğu tespit edilmiş olup, söz konusu bu durum bir kontrol mekanizmasının olması gerektiği sonucu doğurmuştur. ÇKS'ye kayıtlı 15 milyon hektar alanı kapsayan 10 milyon üzerindeki tarım parsellerinin tek tek yerinde kontrol edilmesi elbette mümkün değildir. Bakanlık ve taşra teşkilatları bünyesinde bu parsellerin kontrolü uydu görüntüleri ile sadece görsel olarak yapılmakta olup hataya açık bir durum içermektedir. Yapılan bu tarımsal ürün desen sınıflandırması ile hangi parselde hangi ürünün ekildiği tespit edilerek ÇKS'ye kayıtlı parseller otomatik olarak kontrol edilebilecek, olası uyuşmazlıklar ve farklılıklar var ise ortaya çıkarılarak haksız yere olan ödemelerin de önüne geçilebilecektir.

Yine sulama birlikleri aracılığı ile çiftçilere sağlanan su hizmetlerinin özellikle büyük alanları kapsayan mesaha ve tahakkuk işlemlerinde, sulanan bitki çeşidinin ve ne kadar alanı kapsadığının belirlenmesinde tarımsal ürün desen sınıflandırması atlık olarak kullanılabilecektir. Tarımsal ürün desen sınıflandırması ile türü ve ekim alanı tespit edilen ürünler yardımıyla ortalama ne kadar bir tarımsal sulama yapıldığı, bir sonraki yıl için ne kadar tarımsal sulamaya ihtiyaç duyulacağı hakkında öngörü sahibi olunup, tarım alanları etrafındaki kaynak veya kaynakların potansiyeline göre kullanılması ile gelecek yıllar için planlama yapılmasına da kılavuz olacaktır.

Tarımsal ürün desen sınıflandırması ile Ne? Nerede? Ne kadar alana? Ne zamandan beri? Ne kadar? sorularının cevabı verilerek tarımsal üretim, rekolte, verim ve tarımsal su tüketimi hakkında bilgi sahibi olunacak, istatistikler çıkarılacak ve tarımsal üretim politikasının oluşturulmasında etken bir rol oynayarak tarımsal faaliyetlerin "sürdürülebilirlik" ilkesi doğrultusunda değerlendirilmesi için güçlü bir referans olacaktır.

KAYNAKLAR

- Aksever, F., ve Eroğlu, A. (2016), Çivril-Baklan (Denizli) ovasında yeraltısuyuna iklim değişikliğinin etkisi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(1), 11–26.
- Altun, M., ve Türker, M. (2021), Çoklu zamanlı Sentinel-2 görüntülerinden tarımsal ürün tespiti: Mardin – Kızıltepe Örneği. *Afyon Kocatepe University Journal of Sciences and Engineering*, 21(4), 881–899.
- Arslanoğlu, M. C. (2019), Optik ve radar uydu görüntüleri kullanılarak zeytinin farklı fenolojik dönemlerindeki özelliklerinin araştırılması, Doktora tezi, Tekirdağ Namık Kemal Üniversitesi, *Fen Bilimleri Enstitüsü, Biyosistem Mühendisliği Anabilim Dalı*, Ankara
- Atalay, İ. (2018), Ekosistem ekolojisi ve coğrafyası. *Çevre ve Orman Bakanlığı Yayınları*, Ankara.
- Breiman, L. (2001), Random forest, *Kluwer Academic Publishers*, 45, 5-32.
- Carrizosa, E., Nogales E. A., and Romero M. D. (2017), Clustering categories in support vector machines, *Omega* 66,(PA) 28–37.
- Chen, T. and Guestrin, C. (2016), XGBoost: A scalable tree boosting system,, California.
- Chen, L., Ren, C., Zhang, B., and Wang, Z. (2020), Multi-sensor prediction of stand volume by a hybrid model of support vector machine for regression kriging. *Forests*, 11(3) – 296.
- Cleckner, H. L., Allen, T. R., and Scott Bellows, A. (2011), Remote sensing and modeling of mosquito abundance and habitats in Coastal Virginia, USA. *Remote Sensing*, 3(12), 2663–2681.
- Csillik, O., and Belgiu, M. (2017), Cropland mapping from Sentinel-2 time series data using object-based image analysis. *20th AGILE Conference on Geographic Information Science Conference*, Wageningen.
- Csillik, O., Belgiu, M., Asner, G. P., and Kelly, M. (2019), Object-based time-constrained dynamic time warping classification of crops using Sentinel-2. *Remote Sensing*, 11(10).
- Çağlayan, E. B., Erel, F., Samur, E. B., Deniz, M., Asef, M., ve Kaplan, G. (2020), Uzaktan algılama teknikler ile Akşehir Gölü’ndeki alansal değişiminin izlenmesi, *Türkiye Uzaktan Algılama Dergisi* 2(2), 70–76.
- Çelik, M. A., ve Gülersoy, A. E. (2013), Işıklı gölü (Çivril-Denizli) çevresindeki arazi kullanım faaliyetlerinin göl üzerine etkilerinin incelenmesi. *SDÜ Fen Edebiyat Fakültesi Sosyal Bilimler Dergisi*, 29 191–200.

- Demirci, A. (2019), Işıklı-Gökgöl (Denizli-Çivril) sulak alanları ve civarındaki yüzey ve yeraltı sularında klorür, nitrat ve nitrit kirliliğinin araştırılması, Yüksek lisans tezi, *Pamukkale Üniversitesi Fen Bilimler Enstitüsü, Jeoloji Mühendisliği Anabilim Dalı*, Denizli.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., and Bargellini, P. (2012), Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment* 120(5), 25–36.
- Eitel, J. U. H., Vierling, L. A., Litvak, M. E., Long, D. S., Schulthess, U., Ager, A. A., Krofcheck, D. J., and 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.
- Erden, İ. H. (2008), Türkiye'de fonksiyonel entegre idare ve kontrol sisteminin kurulması ve benimsenmesi üzerine bir araştırma, Doktora tezi, Ankara Üniversitesi, *Fen Bilimleri Enstitüsü, Tarım Ekonomisi Anabilim Dalı*, Ankara
- Farid, D.M., Maruf, G. M., and Rahman, C. M. (2013), A new approach of Boosting using decision tree classifier for classifying noisy data, *2013 International Conference on Informatics, Electron. Vision*, Dhaka
- Feng, S., Zhao, J., Liu, T., Zhang, H., Zhang, Z., and Guo, X. (2019). Crop type identification and mapping using machine learning algorithms and sentinel-2 time series data. *IEEE Journal of Selected Topics in Applied Earth Observations* 12(9), 3295-3306
- Fontanelli, G., Crema, A., Azar, R., Stroppiana, D., Villa, P., and Boschetti, M. (2014), Agricultural crop mapping using optical and SAR multi-temporal seasonal data: A case study in Lombardy region, Italy. *International Geoscience and Remote Sensing Symposium (IGARSS) Conference*, Quebec.
- Gao, B. C. (1996), NDWI a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266.
- Gómez, C., White, J. C., and Wulder, M. A. (2016), Optical remotely sensed time series data for land cover classification:. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 55–72.
- Guolin, K, Men, Q., Finley, T., Wang, T., Chen., W, Ma, W., Ye Q., and Liu, T.Y. (2017) Light GBM: a highly efficient gradient boosting decision tree. *31st Conference on Neural Information Processing Systems (NIPS 2017)*, California.
- Hatfield J.L., Kanemasu E.T., Asrar G., Jackson R.D., Pinter P.J.J., Reginato R.J., and Idso S.B. (1985), Leaf area estimates from spectral measurements over various planting dates of wheat. *Int. J. Remote Sensing*, 6, 167–175.

- Huete, A. R. (1988), A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309
- Jarray, N., Abbes, A. Ben., Rhif, M., Chouikhi, F., and Farah, I. R. (2021), An open source platform to estimate soil moisture using machine learning methods based on eo-learn library. *International Congress of Advanced Technology and Engineering*.
- Kalkan, K., ve Maktav, D. (2016a), Landsat görüntülerinden gölge ve bulut belirleme. VI. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, Adana
- Kalkan, K., ve Maktav, D. (2016b), Çok zamanlı uydu görüntülerinde bulut-gölge alanlarının klonlanması. VI. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, Adana
- Kauth, R. J. and Thomas G. S. (1976), Tasseled cap - a graphic description of the spectral-temporal development of agricultural crops as seen by landsat. *LARS Symposia, Indiana, ABD*
- Keser, T. Z. (2007), Entegre idare ve kontrol sistemi, mevcut durum ve AB üye ülkeleri arasından seçilen örnekler üzerinden incelenmesi, AB uzmanlık tezi, *Tarım ve Köyişleri Bakanlığı, Dış İlişkiler ve Avrupa Birliği Koordinasyon Dairesi Başkanlığı*, Ankara
- Kim, Y., and Lee, K. (2005), An experimental study on the image-based atmospheric correction method for high resolution multispectral data. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1, 434–436.
- Kobayashi, N., Tani, H., Wang, X., & Sonobe, R. (2020), Crop classification using spectral indices derived from Sentinel-2 imagery. *Journal of Information and Telecommunication*, 4(1), 67–90.
- Kohavi, R. (1995), A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference of Artificial Intelligence*, Stanford.
- Kuş, İ., Keser, B.S., ve Yolaçan N. E. (2021), Saldırı tespit sistemlerinde topluluk öğrenme yöntemlerinin kıyaslanması, *European Journal of Science and Technology* 31(1) 725-734
- Li, W., Ding, S., Chen, Y., Wang, H., and Yang, S. (2019), Transfer learning-based default prediction model for consumer credit in China. *Journal of Supercomputing*, 75(2), 862–884.
- Liu, L., Ji, M., and Buchroithner, M. (2017), Combining partial least squares and the gradient-boosting method for soil property retrieval using visible near-infrared shortwave infrared spectra. *Remote Sensing* (9)12.
- LPIS Guideline (2015), LPIS Data Capture Photointerpretation and Digization Guidelines. *Republic of Turkey Ministry of Agriculture and Forestry*, 50-70
- Lu, D., and Weng, Q. (2007), A survey of image classification methods and techniques

- for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870.
- Long, J. A., Lawrence, R. L., Greenwood, M. C., Marshall, L., and Miller, P. R. (2013), Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest. *GIScience and Remote Sensing*, 50(4), 418–436.
- Lubej, M., Aleksandrov, M., Batic, M., Kadunc, M., Milcinski, G., Peressutti, D., and Zupanc, A. (2019), Spatio-temporal deep learning: an application to land cover classification. *Living Planet Symposium*, Milano.
- Mantero, P., Moser, G., and Serpico, S. (2005), Partially supervised classification of remotesensing images through SVM-based probability density estimation, *IEEE Transactions on Geoscience and Remote Sensing*, 3(43), 559–570.
- Marszalek, M., Schmidhalter, U., Marszalek, M. L., Lösch, M., and Körner, M. (2020), Multi-temporal crop type and field boundary classification with google earth engine. *Pre-prints April*, 1–28.
- Maxwell, A. E., Warner, T. A., and Fang, F. (2018), Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing* 39(9) 2784–2817.
- Mishra, S., Oza, M. P., and Sharma, S. A. (2017), Crop phenology identification using NDVI time-series and its dissemination using WebGIS. *38th Asian Conference on Remote Sensing - Space Applications: Touching Human Lives*, New Delhi.
- Mitchell, T. M. (1997) Machine learning, WCB/McGraw-Hill, ABD.
- Murthy, C. S., Raju, P. V., and Badrinath, K. V. S. (2003), Classification of wheat crop with multitemporal images: Performance of maximum likelihood and artificial neural networks. *International Journal of Remote Sensing*, 24(23), 4871–4890.
- Nazlı, C. (2006), Avrupa Birliği tarım muhasebesi veri ağı (FADN) sistemi çerçevesinde Türkiye’de Çiftçi Kayıt Sistemi’nin incelenmesi, Yüksek lisans tezi, *Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Ekonomisi Anabilim Dalı*, Ankara
- Onojeghuo, A. O., Blackburn, G. A., Wang, Q., Atkinson, P. M., Kindred, D., and Miao, Y. (2018), Mapping paddy rice fields by applying machine learning algorithms to multi-temporal Sentinel-1A and Landsat data. *International Journal of Remote Sensing*, 39(4), 1042–1067.
- Özdemir, M.A., ve Tatar, S. (2017), Işıklı gölü ve gökgöl seviye değişimleri ile sucul bitki alanı etkileşimi. *International Symposium On Geomorphology*, 2017, 436–452
- Özen, S. (2015), Sarayköy ve çevril ovalarında (Denizli) iklimik süreçlerin tarımsal ürün çeşitliliğine etkisi, Yüksek lisans tezi, *Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü, Coğrafya Anabilim Dalı*, Afyon.
- Özsoy, İ. (2011), Denizli İli 2011 yılı çevre durum raporu, TC Denizli Valiliği İl Çevre

ve Şehircilik Müdürlüğü,

- Pan, Z., Huang, J., Zhou, Q., Wang, L., Cheng, Y., Zhang, H., Blackburn, G. A., Yan, J., and Liu, J. (2015), Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. *International Journal of Applied Earth Observation and Geoinformation*, 34(1),
- Peña-Barragán, J. M., Ngugi, M. K., Plant, R. E., and Six, J. (2011), Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6).
- Račić, M., Oštir, K., Peressutti, D., Zupanc, A., and Cehovin 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 and Spatial Information Sciences - ISPRS Archives*, 43(B2), 1337–1342.
- Ros, V. C., Sarria, A. F., and Castillo, F. G. (2021), Effect of different atmospheric correction algorithms on Sentinel-2 imagery classification accuracy in a semiarid mediterranean area. *Remote Sensing*, 13(9).
- Rouse, J.W, Haas, R.H., Scheel, J.A., and Deering, D.W. (1974), Monitoring vegetation systems in the great plains with erts, *Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium*, vol. 1, p. 48-62
- Saçlı, Y. (2009), Türkiye’de tarım istatistikleri gelişim, sorunlar ve çözüm önerileri, *Devlet Planlama Teşkilatı*, Ankara 25-35
- Schowengerdt, R. A. (2006), Remote sensing: models and methods for image processing. Elsevier.
- Serra, P., and Pons, X. (2008), Monitoring farmers’ decisions on Mediterranean irrigated crops using satellite image time series. *International Journal of Remote Sensing*, 29(8), 2293–2316.
- Siachalou, S., Mallinis, G., and Tsakiri-Strati, M. (2015), A hidden markov models approach for crop classification: Linking crop phenology to time series of multi-sensor remote sensing data. *Remote Sensing* (7) 4, 3633–3650.
- Skakun, S., Wevers, J., Brockmann, C., Doxani, G., Aleksandrov, M., Batič, M., Frantz, D., Gascon, F., Gómez-Chova, L., Hagolle, O., López-Puigdollers, D., Louis, J., Lubej, M., Mateo-García, G., Osman, J., Peressutti, D., Pflug, B., Puc, J., Richter, R., and Žust, L. (2022), Cloud mask intercomparison exercise (CMIX): An evaluation of cloud masking algorithms for Landsat 8 and Sentinel-2. *Remote Sensing of Environment*, 274.
- Şimşek, F. F. (2016), Uzaktan algılama tekniği ile tarım arazilerinde çiftçi ürün beyanlarının kontrolü: Harran Ovası örneği, Yüksek lisans tezi, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı*, Konya.
- Şimşek, F. F., ve Durduran S. (2023), Açık kaynak kodlu EO - Learn kütüphanesi ve çok

- zamanlı sentinel-2 görüntüleri ile tarımsal ürün sınıflandırması. *Jeodezi ve Jeoinformasyon Dergisi*, 10(1), 45–62.
- Şimşek, F. F., Teke, M., ve Altuntaş, C. (2016), Uzaktan algılama tekniği ile tarım arazilerinde çiftçi ürün beyanlarının kontrolü: Harran Ovası örneği. 6.*Uzaktan Algılama-CBS Sempozyumu (Uzal-Cbs 2016)*, Adana.
- Tane, Z., Roberts, D., Koltunov, A., Sweeney, S., and Ramirez, C. (2018), A framework for detecting conifer mortality across an ecoregion using high spatial resolution spaceborne imaging spectroscopy. *Remote Sensing of Environment*, 209(2), 195–210.
- Teke, M., ve Yardımcı, Y. (2016), Göktürk-2 Zaman Serisi Görüntüleri ile Ürün Sınıflandırma. *24th Signal Processing and Communication Application Conference, SIU Proceedings*.
- Üstüner, M., Abdikan, S., Bilgin, G., ve Şanlı F. (2020), Hafif gradyan artırma makineleri ile tarımsal ürünlerin sınıflandırılması. *Tük Uzaktan Algılma ve CBS Dergisi*, 1(2) 97-105.
- Üstüner, M., ve Şanlı, F. (2019), Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 7(1), 1–10.
- Üstüner, M., Şanlı, F., ve Yıldız, A. (2015), Spektral band ve bitki indeksi seçiminin ürün deseni sınıflandırma doğruluğuna Etkisi: Karşılaştırmalı analiz. *TUFUAB VIII. Teknik Sempozyumu*, Konya
- Viana, C. M., Girão, I., and 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).
- Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., and 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(6), 122–130.
- Wesseling J. G., and Fedes R. A. (2006), Assessing crop water productivity from field to regional scale, *Agricultural Water Management*, 86(1), 30-39,
- Yeler, O., Şatir, O., ve Berberoğlu, S. (2017). Tarım alanlarında çok zamanlı uydu verileri kullanılarak ürün deseninin obje tabanlı sınıflama yöntemiyle belirlenmesi: Aşağı Seyhan Ovası Örneği, *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi* 27(1):1-9.
- Zhu, Z., and Woodcock, C. E. (2012), Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83–94.

- URL-1: <https://www.resmigazete.gov.tr/eskiler/2022/09/20220923-3.htm> ,Erişim tarihi: 21.07.2022
- URL-2: <https://www.tarsim.gov.tr/pages/aboutUs/tanimlar.jsp> ,Erişim tarihi: 23.07.2022
- URL-3: <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir/> ,Erişim tarihi: 24.07.2022
- URL-4: <https://eo-learn.readthedocs.io/en/latest/> ,Erişim tarihi: 27.09.2022
- URL-5: <https://medium.com/sentinel-hub/land-cover-classification-with-eo-learn-part-1-2471e8098195> ,Erişim tarihi: 24.09.2022
- URL-6: <https://medium.com/sentinel-hub/land-cover-classification-with-eo-learn-part-2-bd9aa86f8500> ,Erişim tarihi: 14.07.2022
- URL-7: <https://medium.com/sentinel-hub/introducing-eo-learn-ab37f2869f5c> ,Erişim tarihi: 12.11.2022
- URL-8: <https://github.com/sentinel-hub/eo-learn/> ,Erişim tarihi: 04.11.2022
- URL-9: <https://medium.com/sentinel-hub/introducing-eo-learn-ab37f2869f5c> ,Erişim tarihi: 25.06.2022
- URL-10: <https://eo-learn.readthedocs.io/en/latest/examples/core/CoreOverview.html#EOPatch> ,Erişim tarihi: 2.05.2022
- URL-11: <https://github.com/sentinel-hub/eo-learn/tree/master/examples/land-cover-map> ,Erişim tarihi: 13.06.2021
- URL-12: <https://eo-learn.readthedocs.io/en/latest/eotasks.html> ,Erişim tarihi: 8.9.2022
- URL-13: <https://sentinelhub-py.readthedocs.io/en/latest/configure.html#sentinel-hub-configuration> ,Erişim tarihi: 28.08.2022
- URL-14: <https://github.com/sentinel-hub/sentinelhub-py/> ,Erişim tarihi: 22.10.2022
- URL-15: <https://medium.com/sentinel-hub/improving-cloud-detection-with-machine-learning-c09dc5d7cf13> ,Erişim tarihi: 30.08.2022
- URL-16: https://en.wikipedia.org/wiki/Tasseled_cap_transformation ,Erişim tarihi: 27.9.2022
- URL-17: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/tasseled-cap-function.htm> ,Erişim tarihi: 11.9.2022
- URL-18: <https://www.veribilimiokulu.com/lightgbm/> ,Erişim tarihi: 18.08.2021

- URL-19: <https://medium.com/kaveai/matemati%C4%9Fi-ve-python-uygulamas%C4%B1yla-lightgbm-hafif-gradyan-art%C4%B1rma-makinesi-18d2f12e7870> ,Eriřim tarihi: 12.10.2022
- URL-20:<https://medium.com/@senapati.dipak97/grid-search-vs-random-search-d34c92946318> ,Eriřim tarihi: 12.09.2022
- URL-21: <https://medium.com/@gulcanogundur/model-se%C3%A7imi-k-fold-cross-validation-4635b61f143c> ,Eriřim tarihi: 17.08.2022
- URL-22:<https://medium.com/@gulcanogundur/overfitting-a%C5%9F%C4%B1r%C4%B1-%C3%B6%C4%9Frenme-underfitting-eksik-%C3%B6%C4%9Frenme-ve-bias-variance-%C3%A7eli%C5%9Fkisi-b92bef2f770d> ,Eriřim tarihi: 7.10.2022
- URL-23:<https://medium.com/kodluyoruz/makine-%C3%B6%C4%9Frenmesinde-overfitting-underfitting-best-fitting-kavramlar%C4%B1-9f80a5d42719> ,
Eriřim tarihi: 5.10.2022
- URL-24:<https://medium.com/bili%C5%9Fim-hareketi/cross-validation-nedir-nasıl-çalışır-4ec4736e5142> ,Eriřim tarihi: 1.10.2022