

## Optik ve radar görüntüleri ile aşırı gradyan artırma algoritması kullanılarak tarımsal ürün desen tespiti

Fatih Fehmi Şimşek \*<sup>1</sup> 

<sup>1</sup> Tarım ve Orman Bakanlığı, Ankara, Türkiye, [f.fehmisimsek@gmail.com](mailto:f.fehmisimsek@gmail.com)

Kaynak Göster: Şimşek, F. F. (2024). Optik ve radar görüntüleri ile aşırı gradyan artırma algoritması kullanılarak tarımsal ürün desen tespiti. Geomatik, 9 (1), 54-68

<https://doi.org/10.29128/geomatik.1332997>

### Anahtar Kelimeler

Uzaktan Algılama  
Sentinel-1  
Sentinel-2  
ÇKS  
XGBoost

### Araştırma Makalesi

Geliş: 26.07.2023  
Revize: 30.09.2023  
Kabul: 05.10.2023  
Yayınlanma: 05.02.2024



### Öz

Bu çalışmada, Sentinel-1 Sentetik Açıklıklı Radar (Synthetic Aperture Radar-SAR) ve Sentinel-2 (Multispektral) verilerinin, sınıflandırma ile tarımsal ürün deseni tespitine olan etkisi araştırılmıştır. Çalışma alanı Çukurova Ovası sınırları içerisinde bulunan yaklaşık 2200 km<sup>2</sup>'lik alanı kapsamaktadır. Çalışma kapsamında 2021 yılına ait çok zamanlı Sentinel-1 ve Sentinel-2 görüntüleri ile aşırı gradyan artırma (XGBoost) algoritması kullanılarak mısır, pamuk, buğday, ayçiçeği, karpuz, yer fıstığı ve narenciye ağaçlarının yanı sıra, buğdaydan sonra ekilen ikinci ürün mısır, soya ve pamuk ürünlerini içeren tarımsal ürün desen sınıflandırması yapılmıştır. Çalışmada referans parsel olarak Çiftçi Kayıt Sistemi (ÇKS)'ne kayıtlı parseller kullanılmış olup, ÇKS verisinin yer doğruluk verisi olarak kullanılmasından önce ön düzenleme ve kural tabanlı silme işlemleri gerçekleştirilmiş, ardından hatalı ve yanlış beyanlar elemine edilmiştir. Çalışmada yalnızca Sentinel-1 verileri ile (VH, VV, VH/VV) yapılan sınıflandırma sonucu genel doğruluk değeri %72.3, yalnızca Sentinel-2 verileri ile (R, G, B, NIR, NDVI) yapılan sınıflandırma sonucu genel doğruluk değeri %87.2, Sentinel-1 ve Sentinel-2 verilerinin birlikte kullanıldığı sınıflandırma sonucunda ise genel doğruluk değeri %92.1 olarak hesaplanmıştır. Sınıflandırma çalışması ürün bazında incelendiğinde en düşük doğruluğu yine sadece Sentinel-1 verileri ile hesaplanan sınıflara ait iken, en yüksek doğruluk oranı Sentinel-1 ve Sentinel-2 verilerinin birlikte kullanıldığı sınıflandırmaya ait olduğu tespit edilmiştir. Özellikle çok yakın fenolojik dönemlere sahip olan ikinci ürünlerde Sentinel-1 ve Sentinel-2 verilerinin birlikte kullanılmasının, başarı oranını oldukça arttırdığı tespit edilmiştir.

## Agricultural crop product pattern detection using optical and radar images with extreme gradient boosting algorithm

### Keywords

Remote sensing  
Sentinel-1  
Sentinel-2  
FRS  
XGBoost

### Research Article

Received: 26.07.2023  
Revised: 30.09.2023  
Accepted: 05.10.2023  
Published: 05.02.2024

### Abstract

In this study, the effect of Sentinel-1 Synthetic Aperture Radar (SAR) and Sentinel-2 (Multispectral) data on classification and agricultural crop pattern detection was investigated. The study area covers an area of approximately 2200 km<sup>2</sup> within the borders of Çukurova Plain. Within the scope of the study, agricultural crop pattern classification including corn, cotton, wheat, sunflower, watermelon, peanut and citrus trees, as well as second crop corn, soybean and cotton crops planted after wheat, was performed using the extreme gradient boosting (XGBoost) algorithm with multi-temporal Sentinel-1 and Sentinel-2 images of 2021. Parcels registered in the Farmer Registration System (FRS) were used as reference parcels in the study. Before using the FRS data as ground truth data, pre-editing and rule-based deletion processes were performed, and then erroneous and false declarations were eliminated. In the study, the overall accuracy of the classification using only Sentinel-1 data (VH, VV, VH/VV) was 72.3%, and the overall accuracy of the classification using only Sentinel-2 data (R, G, B, NIR, NDVI) was 87.2%, and the overall accuracy of the classification using Sentinel-1 and Sentinel-2 data together was 92.1%. When the classification study was analyzed on a crop basis, it was determined that the lowest accuracy belonged to the classes calculated only with Sentinel-1 data, while the highest accuracy rate belonged to the study in which Sentinel-1 and Sentinel-2 data were used together. Especially in the second crop with very close phenological periods, it was observed that the use of Sentinel-1 and Sentinel-2 data together increased the success rate considerably.

## 1. Giriş

Tarımsal uygulamalar ve özellikle tarımsal ürün desen tespiti küresel gözlem uydularının kullanıldığı en yaygın alanlardan birisidir (Fan ve ark, 2021). Tarımsal üretimin etkili ve etkin bir şekilde yönetilmesi, ürün rekoltesinin tahmin edilmesi, tarımsal sulamanın planlanması ile tarımsal ürünlerin izlenmesinde uzakta algılama teknolojisi aktif bir şekilde kullanılmaktadır (McNairn ve Shang, 2016).

Uzaktan algılamada optik ve sentetik açıklıklı radar (synthetic aperture radar-SAR) uydularının her ikisi de tarımsal uygulamalarda kullanılmaktadır (Lemoine ve Leo, 2015; Lussem ve ark, 2016). Optik görüntüler kullanılarak yapılan sınıflandırma çalışmaları başarılı sonuçlar vermesine rağmen, özellikle kış-bahar aylarında uzun süreli bulut örtüsü olan alanlarda görüntü alımı sınırlanacağından bazı ürünlerin tespiti mümkün olmayabilir ya da istenilen doğruluk seviyesine ulaşılamaya bilememektedir. Bulutlu alanlardaki kısıtlamanın yanı sıra ekim, olgunlaşma, gelişme ve hasat dönemleri aynı olan tarımsal ürünlerin sınıflandırmasında optik görüntülere ait bantlar ve bantlardan üretilen çeşitli vejetasyon indeksleri tek başına yetersiz kalabilmekte olup, sınıflandırma sonucu karışan ürünlerin ayrılması için farklı bilgilere de ihtiyaç duyulabilmektedir. Aktif sensörlere sahip SAR uyduları hava durumlarından etkilenmediğinden herhangi bir yerin görüntü alımında meteorolojik kısıtlama bulunmamakla beraber tarımsal ürün desen tespitinde de kullanılmaktadır. Bu avantajının yanı sıra, karmaşık SAR sinyali (geri saçılan sinyalin faz ve genlik bilgisinin birlikte kaydedilmesi nedeni ile) hedef objenin fiziksel ve geometrik yapısına karşı duyarlı olmakla beraber ürünlerin birbirinden ayrılmasında da önemli rol oynamaktadır (Jiao ve ark 2014; McNairn ve Shang, 2016; Skakun ve ark, 2015).

Tarımsal ürünler, ürün çeşidi ve coğrafya göre yakın dönemlerde yetişebilmekte olduğu gibi, bir ürün hasat edilirken diğer ürünün ekildiği, farklı dönemleri de içermektedir. Bu sebepten dolayı benzer ya da farklı özellik gösteren ürünlerin tespiti için sınıflandırılacak ürünlere ait fenolojik dönemi kapsayan çok zamanlı görüntülerin kullanılması gerekmektedir. Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında uzaya fırlatılan Sentinel-1 ve Sentinel-2 uyduları ile istenilen alana ait görüntüler ücretsiz olarak temin edilmekte olup bu uyduların zengin bant sayısı, yüksek zamansal çözünürlüğü ve yeterli mekânsal çözünürlüğü ile tarım ürün desen tespiti çalışmaları için oldukça kullanışlıdır.

Uzaktan algılama uygulamalarında SAR ve optik görüntülerin birlikte kullanımı spesifik özellik içermelerinden dolayı özellikle son yıllarda popüler hale gelmiştir (Duysak ve Yiğit, 2022). Sentinel-1 ve Sentinel-2 verileri kullanılarak tarımsal ürün desen tespiti ile ilgili literatür incelendiğinde, Nasirzadehdizaji ve ark., (2019), Konya İlinde yaklaşık 40km<sup>2</sup>lik alanda patates, ayçiçeği, mısır ve buğday ürünleri için Sentinel-1 ve Sentinel-2 görüntüleri ile tarımsal ürün desen sınıflandırma çalışması yapılmıştır. Çalışmada Sentinel-1 SAR uydusuna ait (VH, VV), Sentinel-2 uydusuna ait (B8-B4-B3) bantları kullanılmıştır. Tüm sınıflar için sadece

Sentinel-1, Sentinel-1 ve Sentinel-2 uydu görüntülerinin birlikte kullanılması ile farklı sınıflandırma çalışması yapılmıştır. Sınıflandırma sonucunda SAR ve optik görüntü ile yapılan sınıflandırma sonucunun (%93) sadece SAR görüntüsü ile yapılan sınıflandırma sonucuna (%88) kıyasla genel doğruluk değerini %5 arttırdığı tespit edilmiştir. Sun ve ark, (2020), Moğol özerk bölgesinde (Çin) Sentinel-1 ve Sentinel-2 görüntüleri kullanarak tarımsal ürün desen tespiti çalışması yapmışlardır. Çalışmada mart-ekim ayları arasında (2018) kalan 18 Sentinel-1 SAR görüntüsü, 8 adet Sentinel-2 görüntüsü kullanılmıştır. Sentinel-1 için (VH, VV, VH/VV) bantları Sentinel-2 için ise tüm spektral bantlar ile NDVI ve NDWI indeksleri kullanılmıştır. Sadece Sentinel-1 bantları ile genel doğruluk %79.46 kapa 0.69, sadece Sentinel-2 bantları ve indeksleri ile genel doğruluk %79.80 kapa 0.72, Sentinel-1 ve Sentinel-2 bantları ve indeksleri kullanılarak yapılan sınıflandırma sonucu genel doğruluk %83.22 kapa 0.77 değeri elde edilmiş olup en yüksek skoru Sentinel-1 ve Sentinel-2 kombinasyonu vermiştir. Ayrıca çalışmada NDVI indeksi ve Sentinel-1 SAR görüntüsüne ait VH bantının sınıflandırma çalışmasında en önemli bantlar olduğu tespit edilmiştir. Mercier ve ark, (2020), Sentinel-1 ve Sentinel-2 görüntüleri ile Kuzey Fransa bölgesinde yetişen buğday ve kolza ürünlerinin sınıflandırma çalışmasında kullanılmak üzere, ürünlerin fenolojik aşamalarını tespit etme çalışması yapılmıştır. Sentinel-1 ve Sentinel-2 görüntülerinin çok zamanlı olarak kullanılması sonucu buğday ürününün kardeşlenme, ekim, hasat aşamalarını, kolza ürünü için, olgunlaşma, ekim ve hasat aşamalarını yalnızca Sentinel-1 ve yalnızca Sentinel-2 görüntüleri ile yapılan fenolojik evrelerin tespitine kıyasla daha doğru ve kesin belirlendiği tespit edilmiştir. VH/VV indeksinin fenolojik aşamaların tespitinde en önemli bant olduğu sonucuna da varılmıştır. Çabuk (2021), Gediz Ovası bölgesinde yalnızca Sentinel-1 görüntüleri ve aşırı gradyan artırma (XGBoost) makineleri algoritması kullanarak buğday, domates, mısır, pamuk, üzüm, yonca ürünleri için sınıflandırma çalışması yapmıştır. Sentinel-1 SAR görüntüsüne ait VH, VV, VH/VV indeksi ve çeşitli doku özellikleri özelliklerinden oluşturulan bantlarla yapılan sınıflandırma sonucunda %83.67 genel doğruluk, kapa 0.81 değeri elde edilmiştir. Cai ve ark, (2019), Dongting sulak alanında (Çin) Sentinel-1 ve Sentinel-2 görüntüleri ve rastgele orman (RF) makine öğrenme algoritmasını kullanarak obje tabanlı pirinç alanların tespiti çalışmasını yapmışlardır. Yalnızca Sentinel-2 bantları (B5, B6, B7, B8, B8A) ile genel doğruluk %84.28 kapa 0.75, Sentinel-2 ve NDVI indeksi ile genel doğruluk %86.53 kapa 0.81, Sentinel-2, NDVI ve Sentinel-1 (VH, VV) bantları kullanılarak % genel doğruluk 95.26, kapa 0.93 değerleri elde edilmiştir. Dobrinic ve ark, (2020), Güney doğu Fransa'da Sentinel-1 ve Sentinel-2 görüntülerini kullanarak arazi örtüsü ve kullanımı sınıflandırması çalışması yapmışlar. Yapılan sınıflandırma çalışması sonucu Sentinel-1 ve Sentinel-2 görüntülerinin beraber kullanıldığı sınıflandırma sonucu yalnızca Sentinel-1 ve yalnızca Sentinel-2 görüntüleri ile yapılan sınıflandırmaya kıyasla daha yüksek sonuç vermiştir. Çalışmada rastgele orman (RF) ve aşırı gradyan artırma (XGBoost) makine algoritmaları

kullanılarak yapılan sınıflandırma sonucunda XGBoost algoritmasının daha yüksek doğruluk verdiği ve RF'den çok hızlı olduğu sonucuna ulaşılmıştır. [Bağcı ve ark. \(2023\)](#), Diyarbakır İlinde Sentinel-1 ve Landsat 8 uydularına ait görüntüler ile yeni bir öğrenme yaklaşımı olan Deep Transfer Encoder algoritmasını kullanarak pamuk ve mısır alanlarının tespiti çalışması yapılmıştır. Çalışmada 2016-2021 yılları arasında Sentinel-1 uydusu için toplam 434 adet, Landsat-8 için ise toplam 693 adet görüntü kullanılmıştır. Sonuçlar, Sentinel-1 veri seti, Landsat-8 veri seti ve Sentinel-1 & Landsat-8 veri setlerinin bant parametrelerinden sırasıyla %85, %95 ve %87,5 doğruluk değerleri elde edildiğini göstermiştir. [Acar ve Altun \(2021\)](#), Landsat-8 görüntülerinden oluşturulan NDVI indeksi ve destek vektör makineleri (SVM) makine öğrenmesi algoritmasını kullanarak Batman İlinde mercimek ve buğday ürünleri için tarımsal ürün desen sınıflandırma çalışması yapmış olup %83.3 başarımla doğruluğuna ulaşılmıştır. [Üstüner ve ark., \(2020\)](#), yem bitkisi, mısır, patates, ayçiçeği ve buğday ürünleri için tarımsal ürün desen tespit çalışması yapmışlardır. Aşırı gradyan artırma (XGBoost) ve hafif gradyan artırma makineleri (LightGBM) algoritmaları ve Sentinel-1 görüntüleri kullanılarak yapılan sınıflandırma sonucunda tüm ürünlerde LightGBM algoritması ile hem de yüksek skor elde edilmiş hem de toplam işlem süresi çok daha kısa sürmüştür. [Saini ve Ghosh \(2021\)](#), SVM, RF, ve XGBoost algoritmalarını ile Sentinel-2 görüntülerini kullanarak Hindistan'ın Roorkee bölgesinde tarımsal ürün sınıflandırma çalışması yapmışlardır. Çalışmada Red-Edge2, Red-Edge3 ve NIR bandının ürün sınıflandırması için en önemli belirleyiciler olduğu ilginç bir şekilde, Red-Edge1 bandının en az değişken önemi ortaya koymuşlardır. Sınıflandırma sonucunda en düşük doğruluğu SVM algoritması vermiş olup, en yüksek sınıflandırma sonucunu XGBoost algoritmasına aittir. XGBoost'un tarımsal sınıflandırma için büyük bir potansiyele sahip olduğundan bahsetmişlerdir.

Bu çalışmada çok zamanlı Sentinel-1 Sentetik Açıklıklı Radar, (Synthetic Aperture Radar-SAR) (Düşey Düşey-VV ve Düşey Yatay-VH bantlar) ve Sentinel-2 verileri ile makine öğrenmesi algoritması kullanılarak tarımsal ürün desen sınıflandırma çalışması yapılmış olup, sınıflandırma sonuçları karşılaştırılmıştır. Çalışma alanı olarak Adana ve Mersin ilçeleri arasında kalan alan seçilmiştir. Çalışmada Sentinel-1 SAR verisi olarak (VH, VV, VH/VV) bantları, Sentinel-2 verisi olarak (R, G, B, NIR, NDVI) bantları ve makine öğrenmesi olarak XGBoost makine öğrenme algoritması ile sınıflandırma aşamasında eğitim ve test verisi olarak Çiftçi Kayıt Sistemine (ÇKS) kayıtlı parseller kullanılmıştır. Bu parseller çeşitli düzenleme, silme işlemlerinden sonra, parsellere ait hatalı yanlış beyanlar ile uç değerler uygulanan yöntemle elemine edilmiş ve arazi gerçeği verisi olarak sınıflandırma çalışmasında kullanılmıştır.

Çalışmada mısır, pamuk, buğday, ayçiçeği, karpuz, yer fıstığı ve narenciye ağaçlarının yanı sıra, çift ekim (aynı tarım sezonu içerisinde, ilk ürün ekilip hasat edildikten sonra yerine farklı bir ürünün ekilmesi) yapılan buğday\_mısır, buğday\_soya, buğday\_mısır sınıflarının ürün desen tespiti de yapılmıştır. Özellikle çift ekim yapılan ürünlerin çok yakın fenolojik evrelerde bulunması ve optik görüntülerden oluşturulan indeksler

de kullanıldığında da benzer spektral yansıma değerleri vermesi sebebiyle radar görüntüleri ve bu görüntülerden oluşturulan indeksler sınıflandırma çalışmasına dâhil edilmiştir. Çift ekimli ürünlerin birbirine karışmaması sağlanarak sınıflandırma sonucunun yüksek doğruluk değerini ulaşılması hedeflenmiştir.

Çalışma alanında olduğu gibi büyük alanlara sahip alanlarında ürün deseni belirlenecek her bir sınıf için araziden yeterli sayıda ve çalışma alanına homojen olarak dağılmış veri toplamak hem maliyetli, hem de çok zaman alıcıdır. Çalışmanın bir başka amacı ise geliştirilen yöntemle çiftçi beyan parsellerden yer doğruluk verisi oluşturularak bu sınıflandırma çalışmasında ve bundan sonraki çalışmalarda kullanılabilirliği test edilmiştir.

## 2. Yöntem

### 2.1. Çalışma alanı

Çalışma alanı, Adana İli Seyhan, Yüreğir, Karataş ve Yumurtalık İlçeleri ile Mersin İli Tarsus İlçesi'nin güney doğu kısmını kapsamakta olup Çukurova Ovası sınırları içerisinde kalmaktadır. Çalışma alanında yaklaşık 90000 adet tarımsal parseli bulunmakta ve yaklaşık 2200km<sup>2</sup>lik bir alanı kapsamaktadır ([Şekil 1](#)). Tarımsal üretim çeşidi bakımından ülkenin en zengin ovalarından biri olmakla beraber, yıl içerisinde iki hatta bazı bölgelerde üç farklı zamanda ürün hasadı yapılmakla beraber çok yıllık dikili ürünler de bulunmaktadır.

### 2.2. Sentinel-1 uydu görüntüleri

Sentinel-1 ve Sentinel-2 uyduları Avrupa Uzay Ajansı tarafından küresel izleme programına veri sağlamak amacı ile fırlatılmış olup algılanan görüntüler ücretsiz elde edilebilmektedir ([Efe ve Algancı, 2023](#)).

Sentinel-1 uyduları, Sentinel 1A- Sentinel 1B olarak ikiz uydu olmakla beraber, her iki uydunun yörüngesi 6 günde bir aynı coğrafi konumda olacak şekilde planlanmıştır. Sentinel 1A uydusu aktif olarak çalışmaya devam ederken, Sentinel 1B uydusu 23 Aralık 2021 tarihinden itibaren uydu içerisindeki güç elektroniği arızası sebebiyle görüntü sağlayamamaktadır. Sentinel-1 uydusu C bantta veri sağlamakta olup, H ve V polarizasyonu ile çift polarizasyonda çalışmayı desteklemektedir ([URL-1](#)). Sentinel-1 verileri, Stripmap modu (SM), İnterferometrik geniş alan modu (IW), Ekstra geniş alan modu (EW) ve Dalga (WV) olmak üzere dört farklı modda çalışmaktadır. Sentinel-1 görüntüleri Single Look Complex (SLC) ve Ground Range Detected (GRD) formatlarında da kullanılabilir. Çalışmada IW modu ve GRD formatı tercih edilmiş olup, 2021 yılına ait çift polarize (VV/VH) C bant görüntüleri kullanılmıştır.

### 2.3. Sentinel-2 uydu görüntüleri

Sentinel-2 uyduları, Sentinel 2A – Sentinel 2B olmak üzere ikiz uydu olmakla beraber, 5 günlük zamansal çözünürlüğe, farklı bantlara sahip 10m, 20m ve 60m olmak üzere üç farklı konumsal çözünürlüğe ve 13 spektral band içermekte, L1C ve L2A olmak üzere 2 formatta üretilmektedir ([URL-2](#)). Sentinel-2 uydusunun

sık aralıklı çekim periyodu ve 13 spektral banda sahip olması, tarım alanlarının gözlemlenmesi, tarımsal ürünlerin fenolojilerinin izlenmesi ve tarımsal ürün çeşidinin belirlenmesinde avantaj sağlamaktadır.

Çalışmada 2021 yılına ait Sentinel-1 ve Sentinel-2 görüntüleri olmak üzere 11 farklı tarihte görüntü temin edilmiştir.



Şekil 1. Çalışma alanının görünümü.

Tablo 1. Çalışmada kullanılan uydu görüntüleri

Uydu	Görüntü Tarihi	Uydu	Görüntü Tarihi
Sentinel-1 GRD	03.27.2021	Sentinel-2 Level 1C	03.29.2021
	04.20.2021		04.15.2021
	05.02.2021		05.05.2021
	05.14.2021		05.20.2021
	06.11.2021		06.14.2021
	07.13.2021		07.14.2021
	08.12.2021		08.11.2021
	09.11.2021		09.07.2021
	10.04.2021		10.02.2021
	10.17.2021		10.17.2021
	10.29.2021		10.27.2021

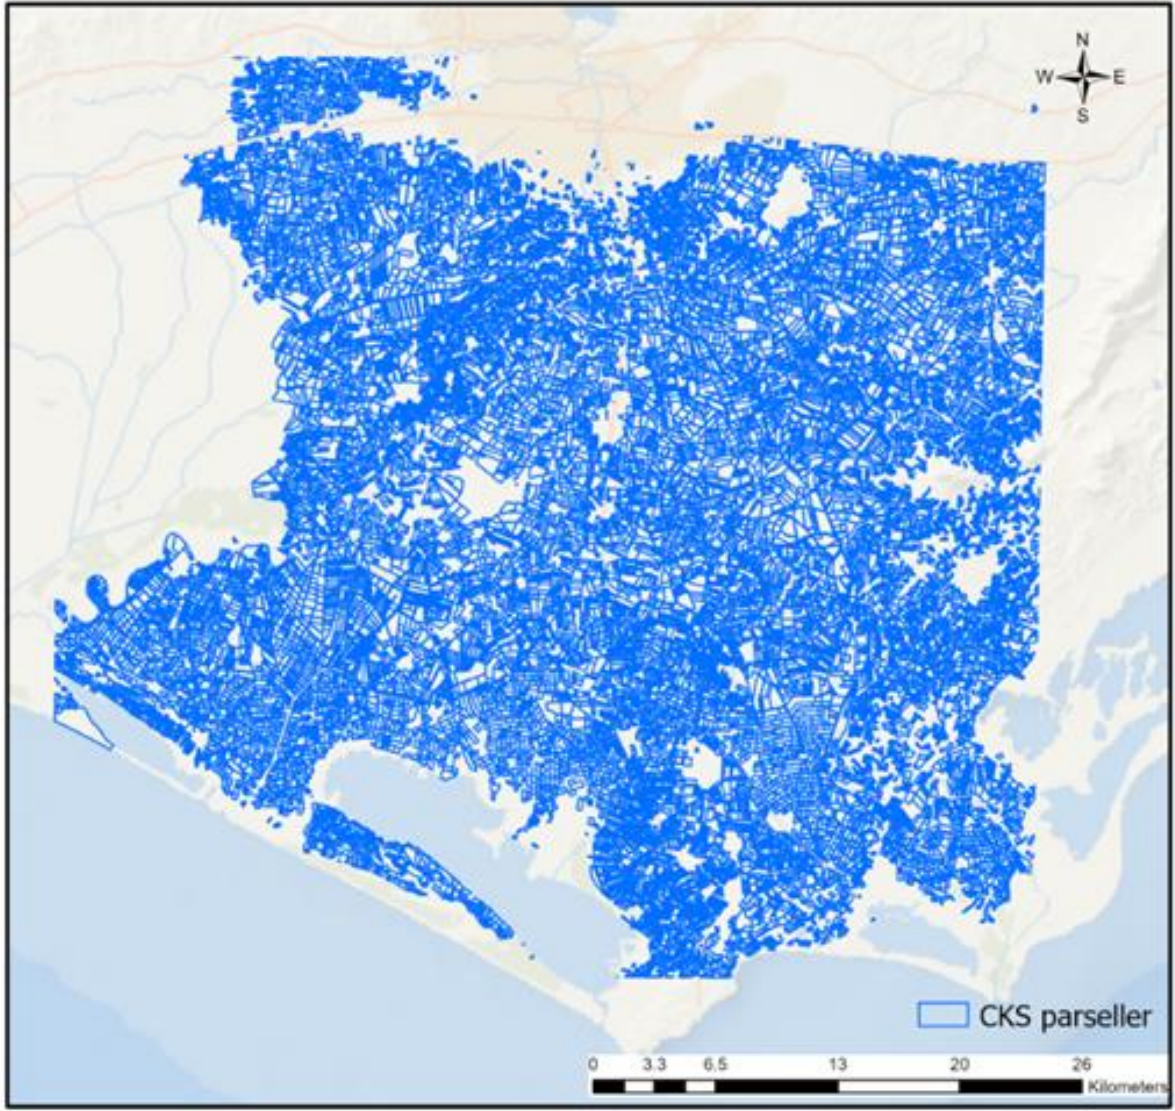
#### 2.4. Yersel referans veriler

Çalışmada yer doğruluk verisi olarak Çifti Kayıt Sistemine kayıtlı parseller kullanılmıştır. Çiftçi Kayıt Sistemi (ÇKS) Tarım ve Orman Bakanlığı tarafından çiftçilere ait tarımsal faaliyetlerin kayıt altına alındığı bir sistemdir. Sistemde parsellere ait geometrik bilgi bulunmasının yanı sıra her bir parsel için; il, ilçe, mahalle, ada no, parsel no, tarım parsel no, ekilen ürün bilgisi, alan, yüz ölçümü, kadastral alan, ekim tarihi ve hasat tarihi bilgileri de yer almaktadır. Çalışma alanında 2021 yılına ait kayıtlı 87692 parsel bulunmaktadır. Beyan esaslı bu parseller incelendiğinde, parsellere ait geometri

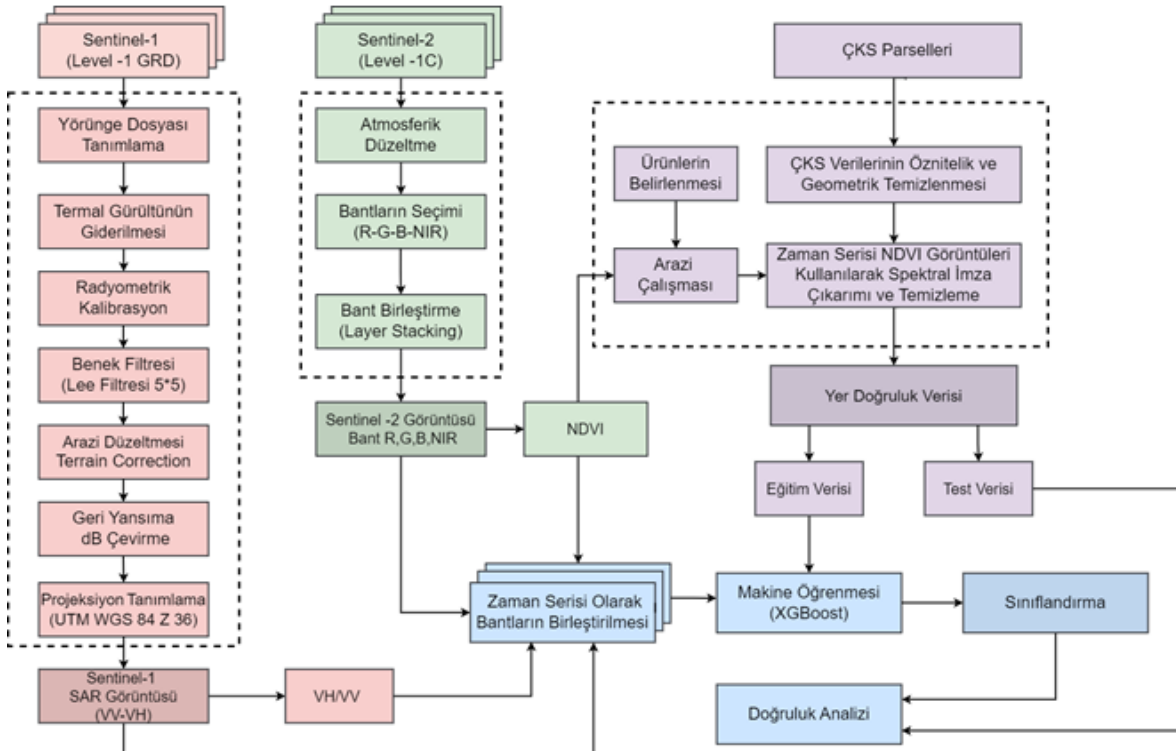
ve öznitelik bilgileri ile arazideki parseller arasında sistematik olan ve olmayan farklılıkların olduğu tespit edilmiştir. Bu farklılıktan kaynaklı olarak beyan esaslı parseller bir dizi düzenleme ve silme işlemine tabi tutulmuş, bu işlemler sonunda beyan esaslı parsellerden yer doğruluk verisi üretilerek sınıflandırma işleminde eğitim ve test verisi olarak kullanılması sağlanmıştır. ÇKS verisi üzerindeki düzenleme ve silme işlemleri sonrasında 8549 adet parsel referans veri olarak sınıflandırma çalışmasında kullanılmıştır.

#### 3. Yöntemler

Çalışmada kullanılan yöntemin adımlarını özetleyen iş akışı Şekil 3' de gösterilmiştir. Yöntem, uydu görüntüsü ön işleme, referans veri hazırlama, makine öğrenmesi ile sınıflandırma ve doğruluk analizi olmak üzere dört temel adımdan oluşmaktadır. İlk olarak Sentinel-1 ve Sentinel-2 görüntülerine ait gerekli ön işleme adımları uygulanmış, sınıflandırma işleminde kullanılan bantlar ve indeksler belirlenmiştir. Sonrasında ÇKS beyanlı parseller üzerinde düzenleme ve silme işlemleri gerçekleştirilmiştir. Bu işlem sonunda kalan parseller ile zaman seri NDVI ve VH/VV indeksleri kullanılarak her bir ürüne ait spektral ayrılma eğrileri belirlenmiştir. Üçüncü olarak aşırı gradyan artırma (XGBoost) algoritması kullanılarak piksel tabanlı sınıflandırma işlemi yapılmış olup, son olarak, elde edilen sonuçların doğruluk analizleri hesaplanmıştır.



Şekil 2. 2022 yılına ait ÇKS beyanlı parsellerin dağılımı.



Şekil 3. Yönteme ait akış diyagramı.

### 3.1. Uydu görüntüsü ön işleme

Uydu görüntüleri sistematik ve sistematik olmayan hatalar içermektedir. Bu hataların giderilebilmesi için birtakım düzeltmelerin yapılması gerekmekte olup bu düzeltme ve ön işleme adımlarının yapılacak sınıflandırma çalışmasının doğruluğuna olumlu etkisi bulunmaktadır. Çalışmada önce SAR sonra da optik görüntüler için ön işleme ve özellik çıkarımı işlemleri yapılmıştır. Çok zamanlı IW modunda Level-1 Grid formatında temin edilen görüntülerin ön işleme işlemleri Avrupa Uzay Ajansı (ESA) tarafından ücretsiz olarak sağlanan SNAP (Sentinel Application Platform) yazılımında yörünge dosyası tanımlama, termal gürültünün giderilmesi, radyometrik kalibrasyon, benek filtresi, topografik düzeltme ve geri yansıma değerlerini db'ye dönüştürme olmak üzere altı adımda gerçekleştirilmiştir.

Yörünge dosyası tanımlama ön işleme adımı ile SAR görüntüsünün uydu yörünge durum vektörlerine güncel düzeltmeler getirilerek doğru uydu konum ve hız bilgisi sağlanmıştır (Altun ve Türker, 2022). SAR görüntülerinde, özellikle düşük geri saçılım alanlarında (durgun deniz, göller vb.) sinyal gürültüleri oluşabilmektedir (Gorelick ve ark, 2017). Sentinel-1 GRD formatı, polarizasyon bilgilerini bulundurmakta ve verilerinin işlenmesi için gerekli olan ön işleme adımlarını sağlamaktadır. Sentinel-1 uydusu, her ölçüm veri seti için kalibre edilmiş GRD verileriyle eşleşen kalibre edilmiş gürültü profilleri oluşturmak için kullanılan doğrusal güçte bir gürültü arama tablosu içermektedir. SAR görüntülerine uygulanan termal gürültü işleme adımı ile uydu görüntülerindeki gürültüler elemine edilmiştir. Piksel değerlerini radyometrik olarak kalibre edilmiş SAR geri saçılım değerlerine dönüştürme işlemi radyometrik düzeltme işlemi olarak tanımlanmaktadır. Radyometrik kalibrasyon adımıyla Sentinel-1 GRD verilerinin yoğunluk değerleri sigma nought değerine dönüştürülür (Polat ve ark, 2022). SAR görüntülerinde taneli gürültü olarak görünen benek, birçok temel geri yansımalarından yansıyan dalgaların kaynağa gelmesinden kaynaklanmaktadır (Lee ve ark, 1994). SAR görüntülerindeki beneklerin olumsuz etkilerini azaltmak amacıyla filtreler geliştirilmiş olup, bunlardan benek filtresi, görüntüdeki benek gürültüsü azaltılarak görüntünün kalitesini artırmak amacıyla kullanılmaktadır (Filipponi, 2019). Benek filtreleme adımıyla Lee Sigma (5x5) filtresi kullanılarak görüntüdeki gürültüler azaltılmıştır. Arazi düzeltmesi adımıyla, sayısal yükseklik modeli kullanılarak (SNAP yazılımı içinde bulunan) SAR görüntüsündeki topoğrafyanın neden olduğu geometrik düzeltmeler yapılmıştır (Small ve Schubert, 2008). Son işlem adımıyla ise bantlardaki dijital piksel değerleri, logaritmik dönüşüm kullanılarak (db) biriminde geri yansıtım değerlerine dönüştürülmüştür. Tüm işlem adımları uygulandıktan sonra, SAR uydu görüntüleri çalışma alanı ait projeksiyon sistemine (UTM Z36 WGS84) tanımlanarak ve 10 metre mekânsal çözünürlüğe yeniden örnekleterek analize hazır hale getirilmiştir.

Sınıflandırma çalışmasında kullanılacak çok zamanlı Sentinel-1 görüntülerinin ön işleme işlemlerinden sonra her bir görüntüye ait VH/VV oranı hesaplanmıştır. Bu oran optik görüntülerdeki NDVI indeksi gibi bitki gelişimi ve fenolojisi hakkında bilgiler sağlamakta ve geri saçılımın zamansal değişimine bağlı olarak ürünler arasında ayrımı yapılabilmesine imkân vermektedir. VH geri yansıtım değerlerinden VV geri yansıtım değerlerinin çıkarılması ile hesaplanan indeks VH/VV gösterimi ile temsil edilmektedir (Khabbazan ve ark, 2019).

SAR görüntülerinin ön işleme ve özellik çıkarımı işlemlerinden sonra çalışmada kullanılacak çok zamanlı Sentinel-2 görüntülerine ait ön işleme işlemleri yapılmıştır. Temin edilen Sentinel-2 görüntüleri Level 1C formatında olup atmosfer üstü yansıtım değerlerine sahiptir. Sınıflandırma çalışmasında bitkilere ait gerçek yansıtım değerlerinin hesaplanması amacıyla atmosfer üstü yansıtım değerlerinin atmosfer altı yansıtım değerlerine dönüştürülmesi gerekmektedir (Müller-Wilm ve ark, 2017). SNAP yazılımındaki Sen2Cor modülü ile her bir piksele ait atmosfer üstü yansıtım değeri, atmosfer altı yansıtım değerine dönüştürülmüştür. Çalışmada Sentinel-2 uydusunun 10 metre mekânsal çözünürlüklü mavi (B02), yeşil, (B03), kırmızı (B04) ve yakın kızılötesi (B04) bantları kullanılmıştır. Bu bantlardan her bir Sentinel-2 görüntüsüne ait NDVI (Normalleştirilmiş Fark Bitki Örtüsü İndeksi) değerleri hesaplanmıştır. NDVI indeksi bitkilerin fenolojik gelişim ve değişimleri hakkında bilgi vermektedir (Zhang ve ark, 2020). Birden farklı tarihte zamana yayılmış olarak temin edilen NDVI görüntüleri ile yıl içerisinde tarımsal ürünlere ait fenolojik süreçlerin tamamı gözlemlenebilmekte ve benzer fenolojik süreçlere sahip sınıfların böylelikle birbirinden ayrılabilmesi sağlanmaktadır (Viana ve ark, 2019). Hem optik hem de radar görüntülerine ait 11 farklı tarihte görüntü çekilmiş olup, radar görüntüleri için girdi bantları, VH, VV, VH/VV, optik görüntüler için ise R, G, B, NIR ve NDVI bantlarıdır. Aynı mekânsal çözünürlüğe sahip (10m) optik ve radar görüntüler ile toplamda 88 farklı özellikli bant sınıflandırma çalışmasında kullanılmak üzere oluşturulmuştur.

### 3.2. Referans veri hazırlama

Çalışma alanının tamamı Çukurova Ovası sınırları içerisinde kalmakta olup çok zengin tarımsal ürün çeşidine sahiptir. Bölgede pamuk, mısır, buğday, arpa ayçiçeği, karpuz, yer fıstığı en çok yetiştirilen bitkiler olmakla beraber, ayrıca buğday hasadından sonra ikinci ürün olarak pamuk, mısır ve soya ürünleri yetiştirilmektedir. Bölge dikili ürünler bakımından da çok zengin olup, portakal, mandalina, greyfurt ve limon gibi ekonomik değeri yüksek olan meyve ağaçları bulunmaktadır. Söz konusu bu ürünler ÇKS beyanları ile kıyaslandığında çalışma alanının neredeyse tamamını kapsamaktadır. Sınıflandırılacak ürünlerden; buğday, arpa ürünleri buğday sınıfı altında, portakal, mandalina, greyfurt ve limon ağaçları narenciye sınıfı altında toplanmıştır. Bu ürünler dışında, mısır, pamuk, karpuz, yer fıstığı, ayçiçeği sınıfları ile ikinci ürün mısır pamuk ve soya ürünleri de sınıflandırma çalışmasına dâhil

edilmiştir. Çalışma alanında 87692 adet ÇKS beyanlı parsel bulunmaktadır.

ÇKS beyanlı parsellerde geometrik ve öznitelik olarak hatalar ve uyumsuzlukların olduğu görülmüş, özellikle birden çok hissedar bulunan bir parselde parsel geometrisinin hissedar sayısı kadar tekrarlı olarak tutulduğu gözlemlenmiştir. Yine sistemde operatör kaynaklı yanlış veri girişi sebebiyle (ekilen ürün, ekilen alan, beyan değişikliği) hataların bulunduğu tespit edilmiştir. Diğer bir problem ise beyanların eşleştiği tarım parsellerinde topolojik hatalar, üst üste çakışmalar ya da tarım dışı alanlarda parsellerin bulunduğu tespit edilmiştir (Şimşek ve Durduran, 2023). Beyan esaslı bu parsellerin yer doğruluk verisi olarak kullanılmasından önce hataların ve uyumsuzlukların giderilmesi amacıyla düzenleme ve silme işlemleri gerçekleştirilmiştir. Bu işlemler sonucunda 87692 olan çiftçi beyanlı parsel sayısı 16333'e düşmüştür.


ÇKS'deki en büyük problem ise, ekimi yapılacak ürüne ait beyan verilmesine rağmen arazide tarımsal bir aktivite yapılmaması veya sistemde beyan edilen ürün ile parselde ekili ürün arasında farklılıklar bulunmasıdır. Söz konusu bu hatalı ve yanlış beyanların yer doğruluk verisi olarak sınıflandırma çalışmasında kullanılması için hatalı beyan içeren parsellerin elemine edilmesi gerekmektedir. Bu kapsamda çalışma alanında bulunan Tarım İl Müdürlüğü'nden bölgedeki ürünlere ait tarımsal fenolojik takvim istenmiş ve bu takvim sayesinde sınıflandırılacak ürünlerin ekim, gelişim, olgunlaşma ve hasat tarihleri hakkında bilgi sahibi olunmuştur. Bunun yanı sıra İl Müdürlüğü personelinde çalışmada referans olarak kullanılmak üzere arazide tespiti yapılan ürünlere ait parsel bilgileri temin edilmiştir.

Tarımsal ürün deseninin belirlenmesinde farklı bitki indeksleri kullanılmakta olup bunlardan biride NDVI indeksidir (Türk ve Balçık, 2023). NDVI indeksi ile bitki sağlığı ve gelişimi hakkında bilgiler elde edilebilmektedir (Morsy ve Hadi, 2022). Çok zamanlı NDVI görüntüleri ile her bir parsel çakıştırılmış ve zaman seri şeklinde her bir

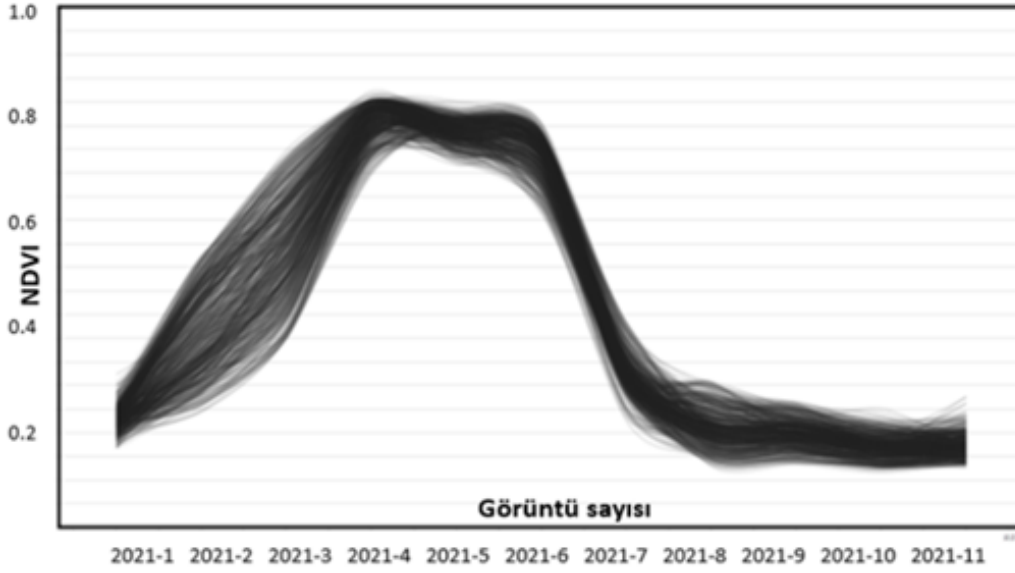
parselin NDVI median değerleri hesaplanmıştır. Bu işlem sonrasında beyan bilgisi içeren her bir parselin vejetatif gelişim ve değişimi dönemleri belirlenmiş, zaman içerisinde değişkenlik gösteren NDVI değerleri ile spektral ayrılma eğrisi çıkarılmıştır. Her bir parsel için oluşturulan spektral ayrılma eğrileri, temin edilen fenolojik takvim ve arazi çalışması sonucu toplanan her ürüne ait spektral yansıma değerleri referans alınarak kontrol edilmiştir. Beyan esaslı parseller spektral olarak arazide bulunduğu tarih aralığında kendi türünün spesifik yansıma değerini vermemiş ise silinmiş, referans yansıma eğrisi ile aynı ve benzer yansıma değeri vermiş ise tutulmuştur. Şekil 4'de mısır beyanlı parsellere ait orijinal ve temizlenmiş spektral ayrılma eğrileri gösterilmiştir.

SAR görüntülerine ait VH/VV oranı ile de NDVI indeksi gibi her bir ürüne ait spektral ayrılma eğrileri oluşturulmuştur. NDVI değerlerinden oluşturulan spektral ayrılma eğrilerinde uç değerler belirlenip çıkarılmış ve kullanılmamıştır. Bu işlem SAR görüntülerinden üretilen spektral ayrılma eğrilerinde tekrarlanmıştır.


Hem NDVI hem de VH/VV indeksi ile zaman serisi şeklinde oluşturulan spektral ayrılma eğrileri, tek ekim yapılan ürünlerde (buğday, ayçiçeği, yer fıstığı, karpuz, narenciye, mısır, pamuk) her bir tarımsal ürün için farklılık göstermektedir (Şekil 5 ve Şekil 6). Yıl içerisinde çift ekim yapılan ürünlerde (buğday\_mısır, buğday\_pamuk, buğday\_soya) ise optik görüntüler ile NDVI değerlerinden üretilen spektral ayrılma eğrilerinin birbirine yakın olduğu (Şekil 7) SAR görüntüleri ile VH/VV indeksinden üretilen spektral ayrılma eğrilerinin, NDVI eğrilerine kıyasla daha fazla farklılık gösterdiği görülmektedir (Şekil 8). Çift ekimli ürünlerde VH/VV indeksi ile ürünlere ait fenolojik ayırımın belirginleşmesi ile veri temizleme işlemi daha kolay ve doğru bir şekilde yapılmıştır. Bu işlemler sonucunda 8549 adet ÇKS beyanlı parsel yer doğruluk verisi olarak sınıflandırma çalışmasında kullanılmıştır.



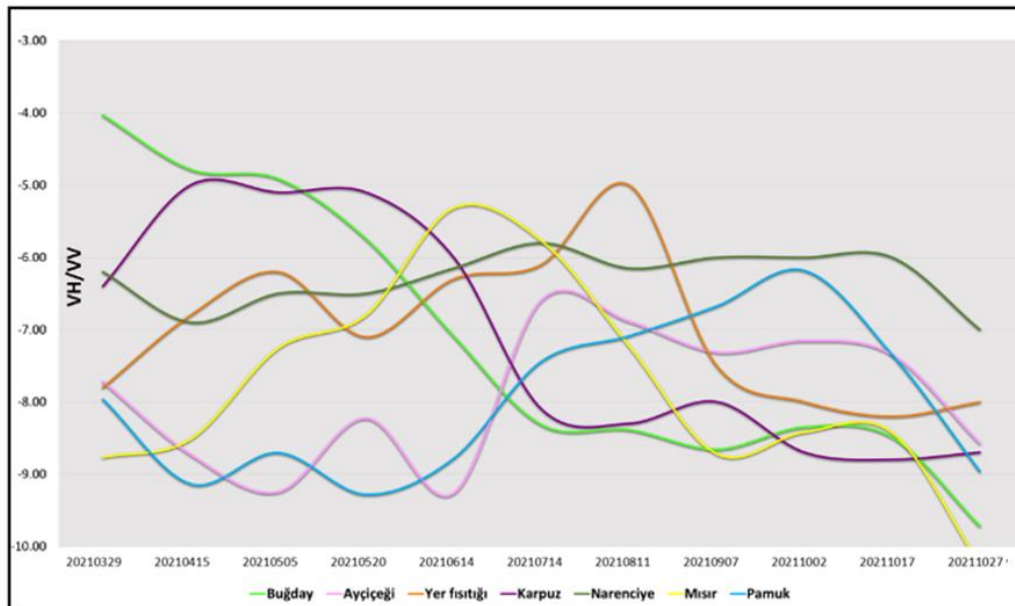
Şekil 4a. Mısır beyanlı parsellere ait spektral ayrılma eğrileri (temizlenmemiş).



Şekil 4b. Mısır beyanlı parsellere ait spektral ayrılma eğrileri (temizlenmiş).

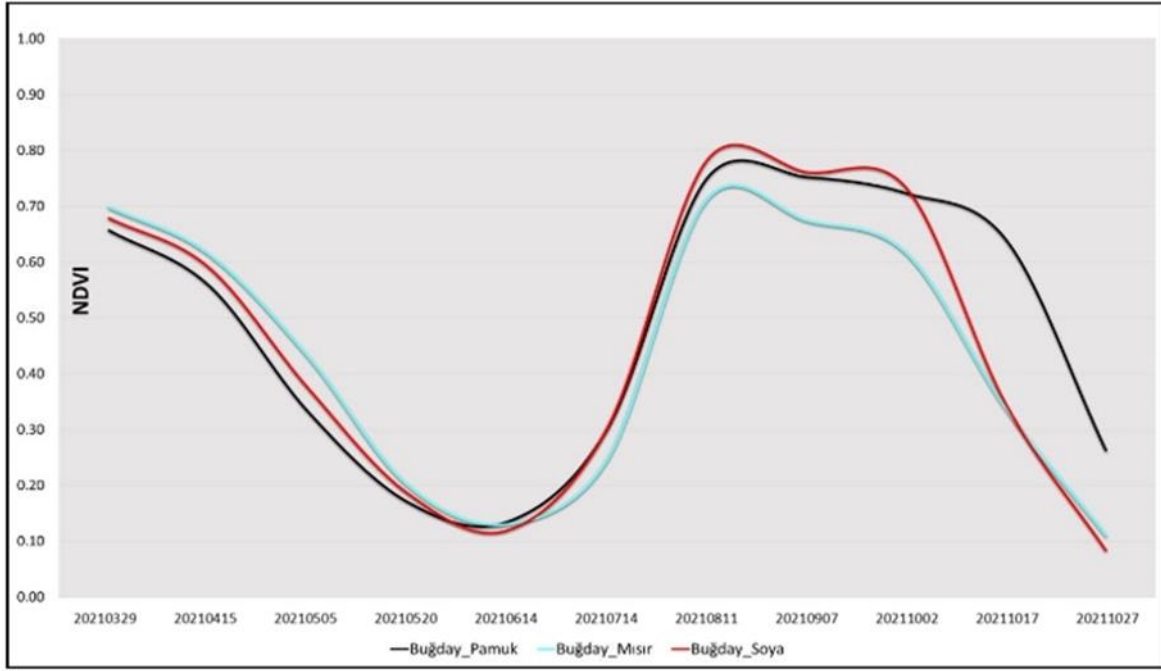


Şekil 5. Tek ekim yapılan ürünlere ait NDVI değerlerine göre zamansal değişim.

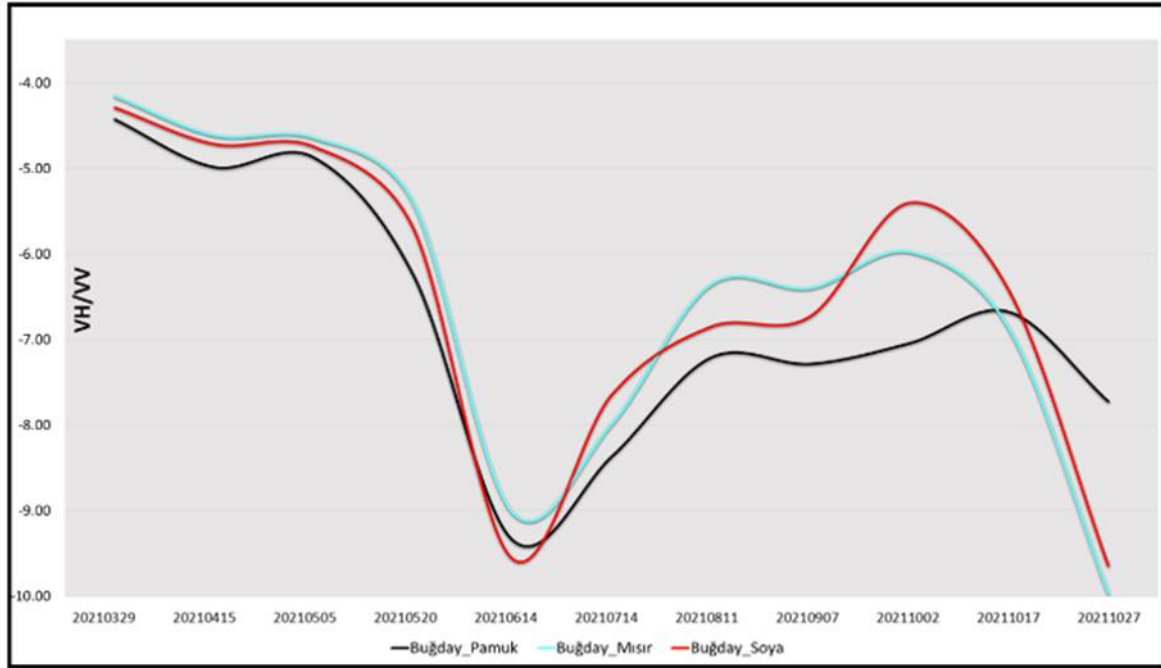


Şekil 6. Tek ekim yapılan ürünlere ait VH/VV değerlerine göre zamansal değişim.





Şekil 7. İki farklı zamanda ekim yapılan ürünlere ait NDVI değerlerine göre zamansal değişim.



Şekil 8. İki farklı zamanda ekim yapılan ürünlere ait VH/VV değerlerine göre zamansal değişim.

### 3.3. Aşırı gradyan algoritması (XGBoost) ile sınıflandırma

Aşırı gradyan artırma (XGBoost) algoritması, ağaç tabanlı bir makine öğrenme algoritmasıdır ve özellikle kendi kendine öğrenen modellerin yüksek performans elde ettiği veri bilimi çalışmalarında başarılı sonuçlar vermekte olup yapay zekâ algoritmaları arasında yapılan yarışmalarda gradyan artırma makineleri (GBM) algoritmasının ölçeklenebilir bir uygulamasıdır (Chen ve Guestrin, 2016). XGBoost, ağaç yapısını artırarak adım adım öğrenerek hata oranını minimize eden ölçeklenebilir bir makine öğrenme algoritmasıdır (Farid ve ark, 2013). XGBoost değişkeni tahmin etmek için bir dizi karar oluşturur ve her ağaç önceki ağaçların tahmin

hatalarını azaltmak için tasarlanmıştır (Mitchell ve Frank, 2017). Farklı düzenleme tekniği kullanarak ağaçların karmaşıklığını kontrol ederek, daha verimli ve yüksek bir performans sağlamaktadır (Patrous, 2018). Yüksek esnekliği sayesinde XGBoost algoritması, kullanıcıların modele yeni bir boyut katan kriterleri değerlendirmesine ve en uygun fonksiyonu tanımlamasına olanak sağlamaktadır. XGBoost aşırı öğrenmeyi ve aşırı uyumluluğu önlemek için, ağaçların derinliği sınırlama, ağaç yapısını basitleştirme ve değişkenlerin önemini belirleme gibi teknikler kullanmaktadır. XGBoost yüksek boyutlu ve düzensiz verilerde başarılı olmakta, endüstriyel uygulamalar, internet arama, finansal hizmetler gibi alanlarda da kullanılmaktadır. Literatür araştırması sonucunda,

çalışma alanın geniş, kullanılan bant sayısının fazla ve yer doğruluk verisi büyük miktarda olması sebebiyle XGBoost algoritması tercih edilmiştir.

XGBoost algoritmasının avantajları; paralelleştirilmiş ağaç yapısı, derin öncelikli yaklaşımı kullanarak uygulanan ağaç budaması, ön bellek farkındalığı ve çekirdek dışı hesaplama, düzenleme ile aşırı uyumdan kaçınma, kayıp gözlemleri etkili bir şekilde işleme ve çapraz doğrulamadır (Chen ve ark, 2019). Dezavantajları ise çok sayıda ağaç oluşturmadan kaynaklı zaman alıcı hesaplama, çok fazla ağaç ekleme eğiliminden kaynaklı aşırı öğrenme riski taşıma, veri dağılımındaki küçük değişikliklere aşırı duyarlı olma ve eksik verilerle başa çıkmada zorlanabilmesidir (Fitriah ve ark, 2017).

XGBoost modeli eğitilirken yüksek sonuçlar elde etmek için önemli bir faktör parametre ayarlamadır. Parametreler algoritmanın kullanılacağı uygulamaya göre değişkenlik göstermektedir. XGBoost için kullanılan parametreler, ağaç derinliği (max depth): Bir ağacın maksimum derinliği belirler, eta(n): Her ağacın katkısını kontrol eden öğrenme oranı, ağaç sayısı (nrounds): Kullanılacak ağaç sayısı, örneklem sayısı (subsample): Eğitim için kullanılacak rastgele örnek oranı, column sample bytree: Her bir ağacı eğitmek için kullanılacak kolon oranı, nthread: Paralel hesaplamayı kullanacak iş parçacığı sayısıdır. XGBoost parametrelerinde en uygun değerlerin seçilmesi algoritmanın performansını yüksek seviyeye çıkarmak için önemlidir. Literatürde araştırmalar XGBoost parametrelerinin ayarlanması için grid search ve random search olmak üzere iki farklı yöntem kullanılmaktadır. Grid search yöntemi, belirli bir parametre aralığını seçerek tüm olası kombinasyonları deneyerek en iyi parametre değerini bulurken, random search yöntemi, belirli bir parametre aralığından rastgele örneklem alarak parametre değerlerini belirler (Bort Escabias, 2017). Bu çalışmada grid search yöntemi kullanılmış olup, seçilen en uygun parametrelere için belirlenen değerler Tablo 2'de gösterilmektedir.

**Tablo 2.** XGBoost parametreleri.

Parametre	Değer
Max depth	10
Eta	0.2
nrounds	800
nthread	2
Subsample	1
Column sample bytree	0.7

Düzenleme ve silme işlemleri sonrası yersel referans veri olarak hazırlanan 8549 adet parselin 4274 adedi eğitim verisi, 4275 adedi ise doğruluk analizinde kullanılmak üzere test verisi olarak seçilmiştir. Çalışmada ürün bazında yersel referans verilerin dağılımı (eğitim ve test parselleri) Tablo 3'de gösterilmiştir. Her bir sınıfa ait parseller QGIS ortamında random selection fonksiyonu ile seçilmiş daha sonra eğitim ve test verisi olarak kendi içinde birleştirilmiştir. Test verisi ile kontrolün daha yüksek oranla yapılması amacıyla eğitim ve test verisi % 50 oranında seçilmiştir.

R Studio yazılımında XGBoost algoritması kullanılarak yalnızca Sentinel-1 bantları ile (VV, VH, VV/VH), yalnızca Sentinel-2 bantları ile (R, G, B, NIR, NDVI) Sentinel-1 ve Sentinel-2 bantlarının (VV, VH,

VV/VH, R, G, B, NIR, NDVI) birlikte kullanılması olmak üzere 3 farklı sınıflandırma çalışması yapılmıştır. Sınıflandırma çalışmaları sonucunda, referans veri seti ile ilişkili sadece tarımsal ürün desenini temsil eden sınıflandırmanın kalması için, raster veri Tarım Reformu Genel Müdürlüğü tarafından Entegre İdare ve Kontrol Sistemi (Integrated Administration and Control System – IACS) projesi kapsamında oluşturulan fiziksel bloklar ve bu fiziksel bloklar içerisindeki tarım dışını kapsayan poligonlar (yollar, yerleşim alanları, ormanlık alanlar, sulak alanlar, çıplak ve kayalık alanlar) kullanılarak maskelenmiş ve elemine edilmiştir.

**Tablo 3.** Eğitim ve test verisinin dağılımı.

Ürün	Eğitim Verisi	Test Verisi
Narenciye	1516	1516
Pamuk	844	844
Mısır	980	980
Yer fıstığı	98	98
Ayçiçeği	131	131
Karpuz	58	58
Buğday	230	231
Buğday_Pamuk	139	139
Buğday_Mısır	16	16
Buğday_Soya	262	262
Toplam	4274	4275

#### 4. Bulgular ve Tartışma

Sınıflandırma çalışması sonucunda genel doğruluk, Cohen's Kappa katsayısı ve her bir sınıfa ait üretici ve kullanıcı doğruluk değerleri hesaplanmış ve oluşturulan hata matrisi üzerinde Tablo 4'te gösterilmiş olup, ortaya çıkan sonuçlar yorumlanmıştır. Hata matrisinin her bir sütunu ayrı bir sınıfa karşılık gelirken, satırlar referans verilerin atandıkları sınıfları temsil etmektedir. Hata matrisi sonucunda sınıflandırma çalışmasına ait genel doğruluk değeri hesaplanmıştır. Genel doğruluk değerinin yanı sıra üretici ve kullanıcı doğrulukları da hesaplanmış olup üretici doğruluğu, doğru sınıflandırılmış örnek sayısının o kategoriye ait sütun sayısına bölünmesi ile hesaplanır iken kullanıcı doğruluğu, doğru sınıflandırılmış örnek sayısının o kategori için olan satır sayısına bölünmesi ile hesaplanmaktadır. Hata matrisindeki genel doğrulukla olasılıklı doğruluk arasındaki farkı gösteren Cohen's Kappa katsayısı da belirlenmiştir (Eşitlik 1-4).

$$KD: \frac{a_{ii}}{\sum_{i=1}^n a_{ik}} \quad (1)$$

$$ÜD: \frac{a_{ii}}{\sum_{i=1}^n a_{ki}} \quad (2)$$

$$\text{Genel doğruluk: } \frac{\sum_{k=1}^N a_{kk}}{\sum_{i,k=1}^N a_{ik}} = \frac{1}{n} \sum_{k=1}^N a_{kk} \quad (3)$$

$$\text{Kappa katsayısı: } \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (4)$$

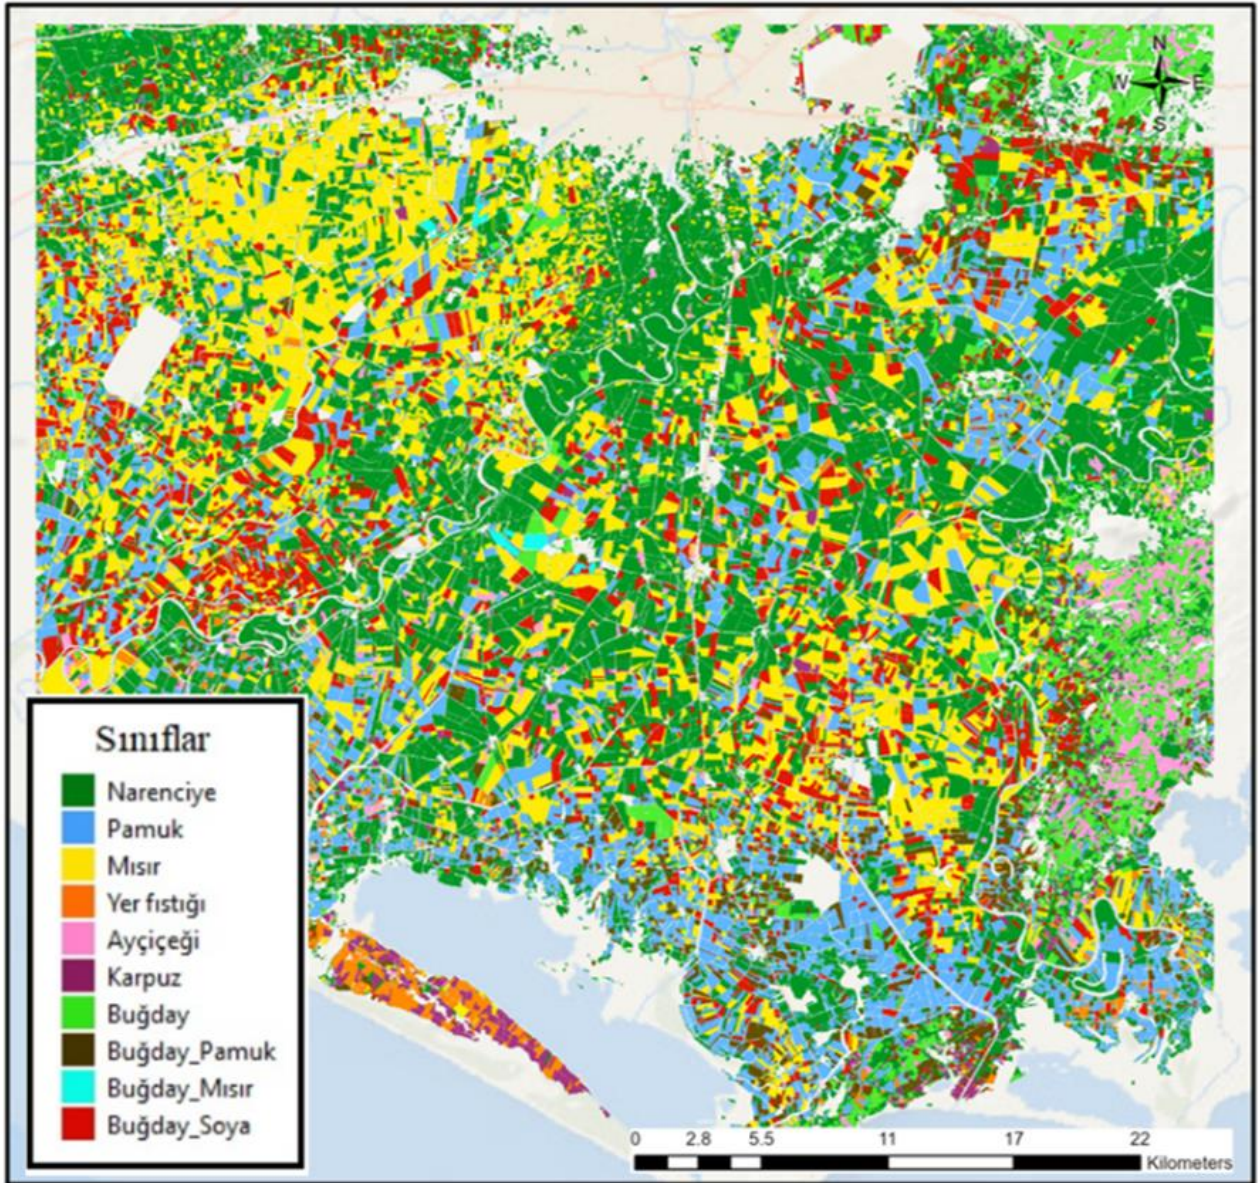

r: hata matrisindeki toplam satır sayısı

$x_{ii}$ : i. satır ve sütundaki piksel sayısı

$x_{i+}$ : i. satırdaki toplam piksel sayısı

$x_{+i}$ : i. sütundaki toplam piksel sayısı

N: matrisin tamamındaki piksel sayısı



**Tablo 4.** Sınıflandırma sonucunda hesaplanan hata matrisi (\*ÜD: Üretici Doğruluğu, \*KD: Kullanıcı Doğruluğu).

SINIFLAR	Sentinel-1 (VH, VV, VH/VV)		Sentinel-2 (R, G, B, NIR, NDVI)		Sentinel-1, Sentinel-2 (VH, VV, VH/VV, R, G, B, NIR, NDVI)	
	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)
Narenciye	70.4	73.2	89.3	87.5	90.4	91.5
Pamuk	73.4	76.9	95.2	91.6	95.6	92.3
Mısır	80.3	75.6	96.2	88.5	96.1	89.3
Yer fıstığı	75.6	73.2	88.5	89.1	89.2	89.3
Ayçiçeği	72.3	69.5	81.1	83.5	88.8	88.4
Karpuz	69.8	71.3	73.4	75.6	83.5	85.4
Buğday	80.5	76.9	94.6	93.2	94.5	96.7
Buğday_Pamuk	69.2	68.5	81.3	75.4	93.6	92.8
Buğday_Mısır	69.8	71.8	73.6	74.5	89.4	88.7
Buğday_Soya	72.3	73.4	74.3	75.2	90.5	90.3
Genel Doğruluk	%72.3		%87.2		%92.1	
Kappa Katsayısı	0.71		0.84		0.92	

Tablo 4'te verilen doğruluk değerlerine göre Sentinel-1 bantları (VH, VV) ve VH/VV indeksi ile yapılan sınıflandırma sonucunda %72.3 genel doğruluk 0.71 kapa katsayısı hesaplanmış olup, diğer sınıflandırma sonuçları ile kıyaslandığında en düşük doğruluk değeri veren sınıflandırma olmuştur. Sentinel-2 bantları (R,G,B,NIR) ve NDVI indeksi ile yapılan sınıflandırma sonucunda %87.2 genel doğruluk 0.84 kapa katsayısı hesaplanmış olup, yalnızca Sentinel-1 bantları ile yapılan sınıflandırma sonucundan yüksek, Sentinel-1 ve Sentinel-2 görüntüleri ile yapılan sınıflandırma sonucuna kıyasla daha düşük bir sonuç elde edilmiştir. Sentinel-1 ve Sentinel-2 bantları ve bantlardan oluşturulan indekslerin (VH, VV, VH/VV, R, G, B, NIR, NDVI) kullanıldığı sınıflandırma sonucunda %92.1 genel doğruluk 0.92 kapa sayısı hesaplanmış olup en yüksek doğruluk değerine ait sınıflandırma sonucuna ulaşılmıştır. Her bir sınıf için doğruluk değerleri incelendiğinde, genel doğruluk değeri ve kapa katsayılarında olduğu gibi tüm sınıflara ait en düşük doğruluk Sentinel-1 bantları ile yapılan sınıflandırma sonucuna ait olup, yine her bir bant için en yüksek doğruluk değerini Sentinel-1 ve Sentinel-2 görüntüleri ile yapılan sınıflandırma sonucu vermiştir. Sentinel-1 bantları (VH, VV) ve VH/VV indeksi ile yapılan sınıflandırma sonucu ürün bazında incelendiğinde, en düşük doğruluk veren sınıflar karpuz (ÜD: % 69.8, KD: %71.3), buğday\_pamuk, (ÜD: % 69.2, KD: %68.5), buğday\_mısır (ÜD: % 69.8, KD: %71.8), olurken en yüksek doğruluk değerine ulaşılan sınıflar, buğday, (ÜD: % 80.5, KD: %76.9) ve mısır (ÜD: % 80.3, KD: %75.6) sınıflarıdır.

Sentinel-2 bantları (R, G, B, NIR) ve NDVI indeksi ile yapılan sınıflandırma sonucu ürün bazında incelendiğinde, en düşük doğruluk veren sınıflar karpuz (ÜD: % 73.4, KD: %75.6), buğday\_mısır, (ÜD: % 73.6, KD: %74.5), buğday\_soya, (ÜD: % 74.3 KD: %75.2) iken en yüksek doğruluk değerine ulaşan sınıflar, pamuk (ÜD: % 95.2, KD: %91.6), mısır (ÜD: % 96.2 KD: %88.5) ve buğday (ÜD: % 94.6 KD: %93.2) sınıflarıdır. Sentinel-1 ve Sentinel-2 bantları ve bantlardan oluşturulan indekslerin (VH, VV, VH/VV, R, G, B, NIR, NDVI) kullanıldığı sınıflandırma sonucunda karpuz sınıfı en düşük doğruluk değerinde olup (ÜD: % 83.5, KD: %85.4), narenciye, yer fıstığı, ayçiçeği, buğday\_mısır sınıfları %90 civarında doğruluk değerine, pamuk, mısır, buğday, buğday\_pamuk

sınıflarında ise %95 civarında doğruluk değeri elde edilmiştir.

Sentinel-2 görüntüleri ile yapılan sınıflandırma ile Sentinel-1 ve Sentinel-2 ile görüntüleri yapılan sınıflandırma sonuçları karşılaştırıldığında, narenciye, pamuk, mısır, yer fıstığı ve buğday sınıflarında neredeyse bir değişiklik olmadığı, Sentinel-1 görüntülerinin eklemesi ile yapılan bu sınıflandırmanın sınıfların doğruluk değerini değiştirmede, karpuz ve ayçiçeği sınıflarında hem üretici hem kullanıcı doğruluğunu yukarı çektiği, özellikle rotasyonlu, çift ekim yapılan ürünlerde ise (buğday\_pamuk, buğday\_mısır, buğday\_soya), doğruluk değerini çok yükselttiği tespit edilmiştir.

Çalışmada Sentinel-1 bantları (VH, VV) ve VH/VV indeksi ile yapılan sınıflandırma sonucunda %72.3 genel doğruluk 0.71 kapa katsayısı hesaplanmış olup, buğday ve mısır sınıfları hariç diğer sınıflara ait doğruluk değerleri genel doğruluk değerine yakın sonuçlar vermiştir. Çalışmada tek ürünlerden pamuk ile ayçiçeği, karpuz ile buğday, rotasyonlu ürünlerden ise buğday\_pamuk ile buğday\_mısır sınıflarının birbirleri ile karıştığı tespit edilmiştir. Radar görüntüleri ile sınıflandırma çalışmasının ürün tespitinde çok yüksek doğruluk vermediği ve tek başına yetersiz kaldığı sonucuna ulaşılmıştır. Sentinel-2 bantları (R,G,B,NIR) ve NDVI indeksi ile yapılan sınıflandırma sonucunda %87.2 genel doğruluk 0.84 kapa katsayısı hesaplanmış olup, ayçiçeği sınıfı mısır sınıfı ile karpuz sınıfı ise mısır, ayçiçeği ve hububat sınıfı ile bir miktar karışmıştır. Rotasyonlu çift ekim yapılan sınıflar ise (buğday\_mısır, buğday\_pamuk, buğday\_soya) Sentinel-2 görüntülerinde spektral ayrılma eğrileri birbirine yakın olan bu sınıflar birbirleri ile karışmış olup söz konusu bu durum doğruluk değerlerini aşağı çekmiştir.

Çift ekim olan sınıflar birbirlerine yakın yansıma yaptıkları NDVI görüntülerden oluşturulan spektral ayrılma eğrilerinde de görülmektedir. Sentinel-1 ve Sentinel-2 bantları ve bantlardan oluşturulan ve vejetasyon indekslerinin (VH, VV, VH/VV, R, G, B, NIR, NDVI) kullanıldığı sınıflandırma sonucunda %92.1 genel doğruluk 0.92 kapa sayısı hesaplanmış olup, sadece karpuz sınıfında çok yüksek doğruluk oranına ulaşamadığı görülmektedir.

Çift ekim yapılan ürünlerde sadece optik görüntülerle yapılan sınıflandırmada sınıfların yüksek doğruluk başarımı göstermediği, optik ile radar görüntüleri ile

yapılan sınıflandırma çalışmasında ise çift ekim yapılan sınıflara ait başarımının, sadece optik görüntüleri kıyasla genel doğruluk değerinin %15 oranında artış yüksek doğruluk oranına ulaştığı tespit edilmiştir. Söz konusu bu durum çift ekim olan alanlarda yapılacak sınıflandırma çalışmalarında radar görüntülerinin de kullanılmasının sınıflandırma başarımını yüksek seviyelere çıkaracağını göstermiştir.

#### 4. Sonuçlar ve Öneriler

Bu çalışmada, Adana İli Seyhan, Yüreğir, Karataş ve Yumurtalık İlçeleri ile Mersin İli Tarsus İlçesine ait tarımsal alanı kapsayan Çukurova Ovası sınırları içerisinde bulunan, 2021 yılına ait Sentinel-1 ve Sentinel-2 uydu görüntüleri ile R Studio ortamında XGBoost makine öğrenme algoritması kullanılarak piksel tabanlı yaklaşımla tarımsal ürün desen sınıflandırma çalışması yapılmıştır. Çalışmada yalnızca Sentinel-1 bantları ile (VV, VH, VV/VH), yalnızca Sentinel-2 bantları ile (R, G, B, NIR, NDVI) Sentinel-1 ve Sentinel-2 bantlarının (VV, VH, VV/VH, R, G, B, NIR, NDVI) birlikte kullanılması olmak üzere 3 farklı sınıflandırma çalışması yapılmış ve sonuçlar birbiri ile karşılaştırılmıştır. Sınıflandırma çalışmasında hem optik hem de radar görüntüler için 11 farklı tarihte görüntü kullanılmış olup, çok zamanlı görüntülerin kullanıldığı bir sınıflandırma çalışması yapılmıştır.

Çalışmada referans veri olarak ÇKS beyanlı parseller kullanılmıştır. ÇKS beyanlı parsellerin referans veri olarak kullanılmasından önce bir dizi düzenleme ve silme işlemi gerçekleştirilmiştir. Tarım İl Müdürlüğünden sahadan toplanan ürünlere ait parseller temin edilmiş olup çok zamanlı Sentinel-2 görüntülerinden üretilen NDVI indeksine ait bantlar ve çok zamanlı Sentinel-1 görüntülerinden üretilen VH/VV indeksine ait bantlar kullanılarak her bir sınıf için spektral ayrılma eğrileri oluşturulmuştur. Her bir sınıfa ait spektral eğri referans alınarak ÇKS beyanlı parsellerdeki hata ya da uç değer taşıyan parseller eleme edilmiş böylece arazi gerçeği verisi bir başka ifade ile sınıflandırma işleminde kullanılacak referans parseller oluşturulmuştur. Çok zamanlı Sentinel-1, Sentinel-2 görüntüleri ile referans parseller kullanılarak XGBoost kütüphanesi aracılığıyla tarımsal ürün desen sınıflandırma çalışması yapılmıştır.

Çalışmada Sentinel-1 bantları (VH, VV) ve VH/VV indeksi ile yapılan sınıflandırma sonucunda %72.3, Sentinel-2 bantları (R,G,B,NIR) ve NDVI indeksi ile yapılan sınıflandırma sonucunda %87.2, Sentinel-1 ve Sentinel-2 bantları ve bantlardan oluşturulan ve vejetasyon indekslerin ( VH, VV, VH/VV, R, G, B, NIR, NDVI) kullanıldığı sınıflandırma sonucunda %92.1 genel doğruluk sonucuna ulaşılmıştır.

Yalnızca Sentinel-1 görüntüleri ile yapılan sınıflandırmanın düşük doğruluk verdiği, ancak optik bir görüntü ile birlikte kullanıldığında genel doğruluk oranı yaklaşık %20 oranında artırarak yüksek doğruluk oranına ulaştığı tespit edilmiştir. Optik ve radar görüntüleri ile yapılan sınıflandırma çalışmasının, sadece optik görüntülerle yapılan sınıflandırma doğruluğuna kıyasla genel doğruluk değerini %5 civarında artırdığı da tespit edilmiştir.

Ücretsiz olarak temin edilebilen Sentinel-1 SAR ve Sentinel-2 görüntülerinin, spektral, mekânsal ve konumsal çözünürlükleri ile bu uydulara ait görüntülerin çok bantlı olarak zaman serisi şeklinde birlikte kullanılması tarımsal ürün desen tespitinin doğru ve yeterli bir seviyede yapılabileceğini göstermiştir.

Sınıflandırma çalışmalarında kullanılan makine öğrenmesi modelinin eğitilmesi için referans (arazi gerçeği) verilerinin kullanılması gerekmektedir. Bu çalışmada olduğu gibi büyük alanlara sahip çalışma alanlarında ürün deseni belirlenecek her bir sınıf için araziden yeterli sayıda ve çalışma alanına homojen olarak dağılmış sayıda veri toplamak hem maliyetli hem de zaman alıcı bir eylem olup sürdürülebilir değildir. Söz konusu bu durumdan dolayı ÇKS beyanlı parsellerin yer doğruluk verisi olarak kullanılması alternatifine gidilmiştir. Sistematiğin ve olmayan birçok hata içeren ÇKS beyanlı parsellerde çeşitli işlem adımları gerçekleştirilerek (topolojik düzeltme, düzenleme, silme, spektral ayrılma eğrilerinin referans alınarak uç değerlerin eleme edilmesi), beyan esaslı bu parsellerden yer doğruluk verisi oluşturulmuş ve sınıflandırma çalışmasında kullanılmıştır. Sınıflandırma sonucunun yüksek doğruluk vermesi beyan esaslı parsellerin doğru bir referans veri haline getirildiği, bu ve benzeri çalışmalarda arazi gerçeği verisi olarak kullanılabileceğini de göstermiştir.

#### Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

#### Kaynakça

- Acar, E., & Altun, M. (2021). Classification of the agricultural crops using landsat-8 NDVI parameters by support vector machine. *Balkan Journal of Electrical and Computer Engineering*, 9(1), 78-82. <https://doi.org/10.17694/bajece.863147>
- Altun, M., & Turker, M. (2022). Integration of Sentinel-1 and Landsat-8 images for crop detection: The case study of Manisa, Turkey. *Advanced Remote Sensing*, 2(1), 23-33.
- Bağcı, R. Ş., Acar, E., & Türk, Ö. (2023). Identification of cotton and corn plant areas by employing deep transformer encoder approach and different time series satellite images: A case study in Diyarbakir, Turkey. *Computers and Electronics in Agriculture*, 209, 107838. <https://doi.org/10.1016/j.compag.2023.107838>
- Bort Escabias, C. (2017). *Tree Boosting Data Competitions with XGBoost* [Master's thesis, Universitat Politècnica de Catalunya].
- Cai, Y., Lin, H., & Zhang, M. (2019). Mapping paddy rice by the object-based random forest method using time series Sentinel-1/Sentinel-2 data. *Advances in Space Research*, 64(11), 2233-2244. <https://doi.org/10.1016/j.asr.2019.08.042>
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. *Proceedings of the 22<sup>nd</sup> ACM Sigkdd International Conference on Knowledge*

- Discovery and Data Mining, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chen, X., Wang, Z. X., & Pan, X. M. (2019). HIV-1 tropism prediction by the XGBoost and HMM methods. *Scientific Reports*, 9(1), 9997. <https://doi.org/10.1038/s41598-019-46420-4>
- Çabuk, S. (2021). Aşırı Gradyan Artırma Algoritması kullanarak Sentinel-1 zaman serisi görüntülerinden ürün sınıflandırma. [Yüksek Lisans Tezi, Hacettepe Üniversitesi].
- Dobrinić, D., Medak, D., & Gašparović, M. (2020). Integration of multitemporal Sentinel-1 and Sentinel-2 imagery for land-cover classification using machine learning methods. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 91-98. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-91-2020>
- Duysak, H., & Yiğit, E. (2022). Investigation of the performance of different wavelet-based fusions of SAR and optical images using Sentinel-1 and Sentinel-2 datasets. *International Journal of Engineering and Geosciences*, 7(1), 81-90. <https://doi.org/10.26833/ijeg.882589>
- Efe, E., & Alganci, U. (2023). Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi. *Geomatik*, 8(1), 27-34. <https://doi.org/10.29128/geomatik.1092838>
- Fan, J., Zhang, X., Zhao, C., Qin, Z., De Vroey, M., & Defourny, P. (2021). Evaluation of crop type classification with different high resolution satellite data sources. *Remote Sensing*, 13(5), 911. <https://doi.org/10.3390/rs13050911>
- Farid, D. M., Maruf, G. M., & Rahman, C. M. (2013, May). A new approach of Boosting using decision tree classifier for classifying noisy data. In 2013 International Conference on Informatics, Electronics and Vision (ICIEV), 1-4. <https://doi.org/10.1109/ICIEV.2013.6572718>
- Filipponi, F. (2019). Sentinel-1 GRD preprocessing workflow. In International Electronic Conference on Remote Sensing (p. 11). <https://doi.org/10.3390/ECRS-3-06201>
- Fitriah, N., Wijaya, S. K., Fanany, M. I., Badri, C., & Rezal, M. (2017, July). EEG channels reduction using PCA to increase XGBoost's accuracy for stroke detection. In AIP Conference Proceedings, 1862(1). <https://doi.org/10.1063/1.4991232>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Jiao, X., Kovacs, J. M., Shang, J., McNairn, H., Walters, D., Ma, B., & Geng, X. (2014). Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 38-46. <https://doi.org/10.1016/j.isprsjprs.2014.06.014>
- Khabbazan, S., Vermunt, P., Steele-Dunne, S., Ratering Arntz, L., Marinetti, C., van der Valk, D., ... & van der Sande, C. (2019). Crop monitoring using Sentinel-1 data: A case study from The Netherlands. *Remote Sensing*, 11(16), 1887. <https://doi.org/10.3390/rs11161887>
- Lee, J. S., Jurkevich, L., Dewaele, P., Wambacq, P., & Oosterlinck, A. (1994). Speckle filtering of synthetic aperture radar images: A review. *Remote sensing reviews*, 8(4), 313-340. <https://doi.org/10.1080/02757259409532206>
- Lemoine, G., & Leo, O. (2015, July). Crop mapping applications at scale: Using Google Earth Engine to enable global crop area and status monitoring using free and open data sources. In 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 1496-1499. <https://doi.org/10.1109/IGARSS.2015.7326063>
- Lussem, U., Hütt, C., & Waldhoff, G. (2016). Combined analysis of Sentinel-1 and RapidEye data for improved crop type classification: An early season approach for rapeseed and cereals. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 959-963. <https://doi.org/10.5194/isprsrarchives-XLI-B8-959-2016>
- McNairn, H., & Shang, J. (2016). A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. *Multitemporal Remote Sensing: Methods and Applications*, 317-340. [https://doi.org/10.1007/978-3-319-47037-5\\_15](https://doi.org/10.1007/978-3-319-47037-5_15)
- Mercier, A., Betbeder, J., Rapinel, S., Jegou, N., Baudry, J., & Hubert-Moy, L. (2020). Evaluation of Sentinel-1 and-2 time series for estimating LAI and biomass of wheat and rapeseed crop types. *Journal of Applied Remote Sensing*, 14(2), 024512. <https://doi.org/10.1117/1.JRS.14.024512>
- Mitchell, R., & Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Science*, 3, e127. <https://doi.org/10.7717/peerj-cs.127>
- Morsy, S., & Hadi, M. (2022). Impact of land use/land cover on land surface temperature and its relationship with spectral indices in Dakahlia Governorate, Egypt. *International Journal of Engineering and Geosciences*, 7(3), 272-282. <https://doi.org/10.26833/ijeg.978961>
- Müller-Wilm, U., Devignot, O., & Pessiot, L. (2017). Sen2Cor Configuration and User Manual. S2-PDGS-MPC-L2A-SUM-V2. 4.
- Nasirzadehdizaji, R., Sanli, F. B., Cakir, Z., & Sertel, E. (2019, July). Crop mapping improvement by combination of optical and SAR datasets. In 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics) 1-6. <https://doi.org/10.1109/Agro-Geoinformatics.2019.8820604>
- Patrous, Z. S. (2018). Evaluating xgboost for user classification by using behavioral features extracted from smartphone sensors, [Master Thesis, KTH Royal Institute of Technology].
- Polat, A. B., Sanli, F. B., & Akcay, O. (2022). Analyzing rice farming between sowing and harvest time with Sentinel-1 SAR data. *Advanced Remote Sensing*, 2(1), 34-39.

- Saini, R., & Ghosh, S. K. (2021). Crop classification in a heterogeneous agricultural environment using ensemble classifiers and single-date Sentinel-2A imagery. *Geocarto international*, 36(19), 2141-2159. <https://doi.org/10.1080/10106049.2019.1700556>
- Skakun, S., Kussul, N., Shelestov, A. Y., Lavreniuk, M., & Kussul, O. (2015). Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(8), 3712-3719. <https://doi.org/10.1109/JSTARS.2015.2454297>
- Small, D., & Schubert, A. (2008). Guide to ASAR geocoding. ESA-ESRIN Technical Note RSL-ASAR-GC-AD, 1, 36.
- Sun, L., Chen, J., Guo, S., Deng, X., & Han, Y. (2020). Integration of time series sentinel-1 and sentinel-2 imagery for crop type mapping over oasis agricultural areas. *Remote Sensing*, 12(1), 158. <https://doi.org/10.3390/rs12010158>
- Şimşek, F. F., & Durduran, S. 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. <https://doi.org/10.9733/JGG.2023R0004.T>
- Türk, S. T., & Balçık, F. (2023). Rastgele orman algoritması ve Sentinel-2 MSI ile fındık ekili alanların belirlenmesi: Piraziz Örneği. *Geomatik*, 8(2), 91-98. <https://doi.org/10.29128/geomatik.1127925>
- URL1: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>
- URL2: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>
- Üstüner, M., Abdikan, S., Bilgin, G., & Şanlı, F. B. (2020). Hafif gradyan artırma makineleri ile tarımsal ürünlerin sınıflandırılması. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(2), 97-105.
- Viana, C. M., Girão, I., & Rocha, J. (2019). Long-term satellite image time-series for land use/land cover change detection using refined open source data in a rural region. *Remote Sensing*, 11(9), 1104. <https://doi.org/10.3390/rs11091104>
- Zhang, H., Kang, J., Xu, X., & Zhang, L. (2020). Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel-2 imagery: A case study of Yi'an County, Heilongjiang province, China. *Computers and Electronics in Agriculture*, 176, 105618. <https://doi.org/10.1016/j.compag.2020.105618>



© Author(s) 2024. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>