

**SENTINEL-1 VE SENTINEL-2 VERİLERİNDEN  
TARIMSAL ÜRÜN SINIFLANDIRMASI İÇİN MAKİNE  
ÖĞRENME ALGORİTMALARININ  
KARŞILAŞTIRILMASI**

**COMPARISON OF MACHINE LEARNING  
ALGORITHMS FOR AGRICULTURAL CROP  
CLASSIFICATION FROM SENTINEL-1 AND SENTINEL-  
2 DATA**

**TİMUÇİN DİZDAROĞLU**

**PROF. DR. MUSTAFA TÜRKER**

**Tez Danışmanı**

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin  
Geomatik Mühendisliği Anabilim Dalı için Öngördüğü

**YÜKSEK LİSANS TEZİ**

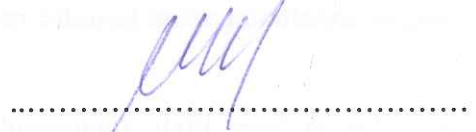
olarak hazırlanmıştır.

2019

**TİMUÇİN DİZDAROĞLU'nun hazırladığı "Sentinel-1 ve Sentinel-2 Verilerinden Tarımsal Ürün Sınıflandırması İçin Makine Öğrenme Algoritmalarının Karşılaştırılması" adlı bu çalışma aşağıdaki jüri tarafından GEOMATİK ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.**

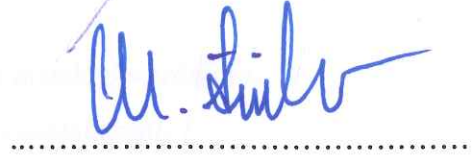
Prof. Dr. Mahmut YÜKSEL

Başkan



Prof. Dr. Mustafa TÜRKER

Danışman



Prof. Dr. Tekin YÜRÜR

Üye



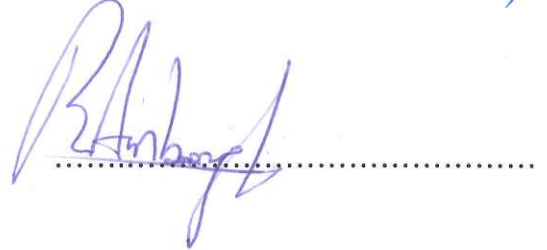
Doç. Dr. Selim L. SANIN

Üye



Dr. Öğr. Üyesi Berk ANBAROĞLU

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak ..... / ..... / ..... tarihinde onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

## ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

08 / 02 / 2019



TİMUÇİN DİZDAROĞLU

## YAYINLANMA FİKRİ MÜLKİYET HAKKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.
- Enstitü / Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren .... ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

08 / 02 / 2019

  
TİMÜÇİN DİZDAROĞLU

# ÖZET

## SENTINEL-1 VE SENTINEL-2 VERİLERİNDEN TARIMSAL ÜRÜN SINIFLANDIRMASI İÇİN MAKİNE ÖĞRENME ALGORİTMALARININ KARŞILAŞTIRILMASI

**Timuçin DİZDAROĞLU**

**Yüksek Lisans, Geomatik Mühendisliği Bölümü**

**Tez Danışmanı: Prof. Dr. Mustafa TÜRKER**

**Şubat 2019, 126 Sayfa**

Bu çalışmada, Gediz ovasında yetiştirilen tarımsal yaz ürünlerinin çok zamanlı Sentinel-1 SAR ve Sentinel-2 optik uydu görüntülerinden nesne-tabanlı sınıflandırması için makine öğrenme algoritmalarının karşılaştırması yapılmıştır. Çalışmada kullanılan makine öğrenme algoritmaları KA (Karar Ağacı), RO (Rastgele Orman) ve DVM (Destek Vektör Makineleri) dir. Çalışmada ayrıca Sentinel-1 ve Sentinel-2 uydu görüntülerinin orijinal bantlarına ek olarak NDVI (Normalize Edilmiş Bitki İndeksi Farkı) bitki indeksi bantı ve farklılık (dissimilarity), entropi (entropy), homojenlik (homogeneity), açılal ikinci moment (angular second moment), korelasyon (correlation) ve kontrast (contrast) doku bantları da hesaplanmış ve sınıflandırma işleminde kullanılmıştır.

Çalışmada Sentinel-1 ve Sentinel-2 uydu görüntülerinin, Nisan-Kasım 2017 tarihleri arasında belirlenen 8 tarihe ait görüntüleri kullanılmıştır. Sentinel-1 uydusu için seçilen görüntü tarihleri 13 Nisan, 1 Mayıs, 1 Haziran, 30 Haziran, 31 Temmuz, 5 Eylül, 11 Ekim ve 16 Kasım 2017 iken Sentinel-2 uydu görüntüleri için seçilen görüntü tarihleri 10 Nisan, 3 Mayıs, 2 Haziran, 2 Temmuz, 1 Ağustos, 7 Eylül, 10 Ekim ve 16 Kasım 2017 olarak belirlenmiştir.

Çalışmada öncelikle çoklu çözünürlük görüntü segmentasyonu işlemi yapılarak segmentler oluşturulmuştur. Oluşturulan segmentlerden her segmente ait özellikler hesaplanmıştır. Sınıflandırma işlemi KA, RO ve DVM algoritmalarıyla segment tabanlı gerçekleştirilmiştir. Sınıflandırma işleminde ayrıca Sentinel-1, Sentinel-2 orijinal bantları, doku özellikleri ve NDVI bitki indeksinden oluşan farklı kombinasyonlar kullanılmıştır. Sınıflandırmada yalnız orijinal bantlar kullanıldığında Sentinel-1 görüntüleri için en yüksek sınıflandırma doğruluğu (%90,48) RO algoritması ile elde edilmiştir. Sentinel-2 görüntüleri için yine en yüksek sınıflandırma doğruluğu (%90,96) RO algoritması ile hesaplanmıştır. Her iki uyduya ait görüntüler birlikte kullanıldığında (Sentinel-1+ Sentinel-2+NDVI) ise, en yüksek doğruluğu (%93,37) DVM algoritması vermiştir. Bu doğruluk oranı çalışmada elde edilen en yüksek sınıflandırma doğruluğudur.

Elde edilen sonuçlara göre özellik kombinasyonları değerlendirdiğinde, doku ve standart sapma bantları sınıflandırma doğruluğunu arttırmamış aksine azaltmıştır. Doğrulukta bu azalma, kullanılan özellik kombinasyonu ve algoritmaya göre %1 - %5 arasında değişmektedir. Öte yandan, Sentinel-1 orijinal bantlarının, Sentinel-2 bantlarıyla birlikte kullanıldığı kombinasyonlarda Sentinel-1 bantlarının sınıflandırma doğruluğuna olumlu etkisi tüm kombinasyonlarda yaklaşık %1-2 kadar olmuştur. Ayrıca, sadece Sentinel-1 bantlarının kullanıldığı kombinasyonlarda oldukça yüksek doğruluk değerlerine ulaşılmıştır. Son olarak NDVI ortalama değerlerine bakıldığında NDVI bantlarının tüm özellik kombinasyonları ve algoritmalarda doğruluğu artırıcı etkisi olduğu görülmüştür. Bunun yanı sıra sınıflandırmada yalnızca NDVI bantları kullanıldığında bile yüksek doğruluk değerlerine ulaşılmıştır. Sadece NDVI bantlarının RO algoritmasıyla sınıflandırıldığı işlem sonucunda %92,65 genel doğruluk değeri hesaplanmıştır.

**Anahtar Kelimeler:** Görüntü Sınıflandırma, Sentinel-1 SAR, Sentinel-2, Karar Ağacı, Rastgele Orman, Destek Vektör Makineleri, Doku Çıkarımı, Nesne-Tabanlı, Tarımsal Ürün

# **ABSTRACT**

## **COMPARISON OF MACHINE LEARNING ALGORITHMS FOR AGRICULTURAL CROP CLASSIFICATION FROM SENTINEL-1 AND SENTINEL-2 DATA**

**Timuçin DİZDAROĞLU**

**Master of Science, Department of Geomatics Engineering**

**Supervisor: Prof. Dr. Mustafa TÜRKER**

**February 2019, 126 Pages**

In this thesis, machine learning algorithms were compared for object-based classification of multi-date Sentinel-1 SAR and Sentinel-2 optical satellite images of agricultural summer crops grown in Gediz plain. The machine learning algorithms used in the study were DT (Decision Tree), RF (Random Forest) and SVM (Support Vector Machines). In addition to the original bands of Sentinel-1 and Sentinel-2 satellite images, NDVI (Normalized Difference Vegetation Index) bands and texture (dissimilarity, entropy, homogeneity, angular second moment, correlation and correlation) bands were also calculated and used in the classification process.

Eight images selected between April and November 2017 of the Sentinel-1 and Sentinel-2 satellite images have been used in the study. The selected dates of Sentinel-1 satellite images were 13 April, 1 May, 1 June, 30 June, 31 July, 5 September, 11 October and 16 November 2017, while the dates selected for Sentinel-2 satellite images were 10 April, 3 May, 2 June, 2 July, 1 August, 7 September, 10 October and 16 November 2017.

In the first step of the study segments were created by performing multi-resolution image segmentation. Features were calculated for each of the generated segments. The classification process was carried out through object-based DT, RF and SVM algorithms. Different combinations of Sentinel-1, Sentinel-2 original bands, texture bands and NDVI bands were used in the classification process. When only the original bands are used in classification, the highest classification accuracy for Sentinel-1 images was obtained by the RF algorithm (90.48%). Similarly, for the Sentinel-2 images, the highest classification accuracy was also calculated by the RF algorithm (90.96%). When the images of both satellites were used together (Sentinel-1 + Sentinel-2 + NDVI), the highest accuracy (93.37%) was given by the SVM algorithm and this was the highest accuracy value obtained in this study.

Based on the results, when the combination of features were evaluated, the texture and standard deviation bands did not increase the classification accuracy, whereas they decreased the accuracy. The reduction in the accuracy varies between 1% and 5% depending on the combination of features and the classification algorithm used. On the other hand, when Sentinel-1 original bands were used in combination with Sentinel-2 bands, the positive effect of Sentinel-1 bands on the classification accuracy was approximately 1-2% in all combinations. In addition, in the feature combinations where Sentinel-1 bands were used alone, very high accuracy values have been calculated. Finally, when NDVI mean values were considered, it was seen that NDVI bands have increased the accuracy in all feature combinations and algorithms. Furthermore, high accuracy values were achieved when the classification was carried out using the NDVI bands only. The overall accuracy of 92.65% was calculated when classification was carried out using the RF algorithm and NDVI bands only.

Keywords: Image Classification, Sentinel-1 SAR, Sentinel-2, Decision Tree, Random Forest, Support Vector Machines, Texture Extraction, Object-Based, Crops



## TEŞEKKÜR

Yüksek lisans tez çalışmamın ortaya çıkmasında, tez konumun seçiminden hazırlanmasına kadar tüm aşamalarında bana yol gösteren değerli görüşlerinden ve engin bilgi birikiminden istifade ettiğim danışman hocam Prof. Dr. Mustafa TÜRKER'e,

Tez çalışmaları sürecinde yardımını ve desteğini esirgemeyen arkadaşım ve meslektaşım Geomatik Yüksek Mühendisi Mesut Yılmaz'a

Tez çalışmam süresince bana her zaman destek olan ve daima yanımda olduğunu bildiğim sevgili eşim Fatma Dizdaroğlu'na

Tez çalışmalarının yoğun olduğu günlerde sevimlilikleriyle bana moral ve enerji veren değerli evlatlarım Bilge Dizdaroğlu ve Mehmet Dizdaroğlu'na

Son olarak bugünlere gelmem de büyük emekleri olan annem Leyla Dizdaroğlu'na ve yakın zamanda kaybettiğim babam Mehmet Dizdaroğlu'na

Teşekkürlerimi sunarım.

Timuçin DİZDAROĞLU

Şubat 2019, Ankara

# İÇİNDEKİLER

ÖZET .....	i
ABSTRACT .....	ii
TEŞEKKÜR .....	v
İÇİNDEKİLER .....	vi
TABLolar .....	vii
ŞEKİLLER .....	viii
KISALTMALAR .....	xi
1. GİRİŞ .....	1
1.1. Tezin Amacı .....	5
1.2. Geçmiş Çalışmalar .....	6
1.3. Kullanılan Yazılımlar .....	10
1.4. Tezin Organizasyonu .....	11
2. YÖNTEM .....	12
2.1. Çalışma Alanı ve Veriler .....	12
2.1.1. Uydu Görüntüleri Tarihlerinin Seçimi .....	13
2.1.2. Arazi Gerçeği Verileri .....	24
2.2. Uydu Görüntüleri .....	27
2.2.1. Sentinel-1 Uydu Görüntüleri – SAR ( Sentetik Açıklıklı Radar) .....	27
2.2.2. Sentinel-2 Optik Uydu Görüntüleri .....	28
2.3. Makine Öğrenme Algoritmaları .....	30
2.3.1. Karar Ağacı .....	30
2.3.2. Rastgele Orman .....	32
2.3.3. Destek Vektör Makineleri .....	34
2.4. Görüntülerin İşlenmesi ve Sınıflandırılması .....	36
2.4.1. Eğitim ve Test Verilerinin Oluşturulması .....	42

2.4.2. Sentinel-1 SAR Uydu Görüntülerine Ön-İşlemelerin Uygulanması.....	45
2.4.3. Görüntü Segmentasyonu.....	46
2.4.4. Eğitim ve Test Alanlarına Özellik Değerlerinin Aktarılması .....	52
2.4.5. Sınıflandırma .....	55
2.4.6. Doğruluk Analizleri.....	57
3. BULGULAR ve KARŞILAŞTIRMALAR .....	60
3.1. Karar Ağacı Algoritması İle Elde Edilen Sonuçlar .....	69
3.2. Rastgele Orman Algoritması İle Elde Edilen Sonuçlar .....	72
3.3. Destek Vektör Makineleri İle Elde Edilen Sonuçlar .....	76
3.4. KA, DVM ve RO Algoritmalarıyla Elde Edilen Sınıflandırma Sonuçlarının Ürün Bazında Karşılaştırılması .....	78
4. SONUÇLAR.....	84
KAYNAKLAR.....	87
5. EKLER.....	96
ÖZGEÇMİŞ .....	112

## TABLULAR

Tablo 2.1. Tarımsal ürünlerin gelişim süreçleri. ....	14
Tablo 2.2. Çalışmada kullanılan uydu görüntülerinin tarihleri. ....	14
Tablo 2.3. Kullanılan ÇKS verilerinden bir örnek. ....	26
Tablo 2.4. Sentinel-2 uydusunun genel özellikleri. ....	29
Tablo 2.5. Sentinel-2 uydusunun spektral özellikleri. ....	29
Tablo 2.6. Çalışmada kullanılan özellik (bant) kombinasyonları. ....	41
Tablo 2.7. Çalışma alanında kullanılan eğitim ve test verileri. ....	43
Tablo 2.8. ESP-2 Algoritmasında Kullanılan Bantlar. ....	48
Tablo 2.9. Dengelenmiş Doğruluğu Bulmak İçin Kullanılan 2x2 Hata Matrisi Örneği [76] .....	58
Tablo 2.10. Çalışmadan alınan bir hata matrisi örneği. ....	59
Tablo 3.1. Çalışmada kullanılan özellik kombinasyonları ve KA, RO ve DVM makine öğrenme algoritmaları için hesaplanan $K$ ve genel doğruluk değerlerinin karşılaştırması. ....	61
Tablo 3.2. En yüksek doğruluk oranının elde edildiği S1+S2 orijinal bantlar+NDVI kullanarak ( $OrtS1, OrtS2, OrtNDVI$ ) DVM algoritması ile yapılan nesne- tabanlı sınıflandırma sonucunda hesaplanan ürünlerin alansal dağılımı. ....	66
Tablo 3.3. KA algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri. ....	70
Tablo 3.4. RO algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri. ....	73
Tablo 3.5. DVM algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri. ....	77
Tablo 3.6. Ürünlerin KA, RO ve DVM algoritmalarındaki dengelenmiş doğruluk değerleri. ....	81

## ŞEKİLLER

Şekil 2.1. Çalışma alanı.	13
Şekil 2.2. Tarımsal ürünlerin ortalama NDVI değerlerinin aylara göre değişimi.	15
Şekil 2.3. Biberin ortalama NDVI değerlerinin aylara göre değişimi	16
Şekil 2.4. Buğdayın ortalama NDVI değerlerinin aylara göre değişimi	16
Şekil 2.5. Domatesin ortalama NDVI değerlerinin aylara göre değişimi	17
Şekil 2.6. Mısırın ortalama NDVI değerlerinin aylara göre değişimi	17
Şekil 2.7. Mısır2'nin ortalama NDVI değerlerinin aylara göre değişimi	18
Şekil 2.8. Pamuğun ortalama NDVI değerlerinin aylara göre değişimi	18
Şekil 2.9. Patlıcanın ortalama NDVI değerlerinin aylara göre değişimi	19
Şekil 2.10. Üzümün ortalama NDVI değerlerinin aylara göre değişimi	19
Şekil 2.11. Yoncanın ortalama NDVI değerlerinin aylara göre değişimi	20
Şekil 2.12. Zeytinin ortalama NDVI değerlerinin aylara göre değişimi	20
Şekil 2.13. Çalışmada kullanılan Sentinel-1 uydu görüntüleri VV bantları (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).	21
Şekil 2.14. Çalışmada kullanılan Sentinel-1 uydu görüntüleri VH bantları (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).	22
Şekil 2.15. Çalışmada uydu görüntüleri kullanılan Sentinel-2 uydu görüntüleri K,Y,M bantları gerçek renk (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).	23
Şekil 2.16. Çalışma sahasından zeytin bahçesi fotoğrafı [30].	25
Şekil 2.17. Çalışma sahasından mısır tarlası fotoğrafı [30].	25
Şekil 2.18. Arazi gerçeği verilerinin dağılımı.	26
Şekil 2.19. Örnek karar ağacı yapısı [48].	31
Şekil 2.20. Doğrusal destek vektör makineleri örneği [56].	34
Şekil 2.21. Çalışmada Kullanılan Akış Diagramı	37
Şekil 2.22. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, YKÖ, K, Y bant kombinasyonu).	43
Şekil 2.23. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, NDVI bantı).	44
Şekil 2.24. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, Sentinel-1 VV Bantı).	44

Şekil 2.25. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, Sentinel-1 VH Bantı).....	45
Şekil 2.26. Çalışmada kullanılan bantların önem dereceleri.....	47
Şekil 2.27. Tahmini ölçek parametresi LV grafiği.....	49
Şekil 2.28. Çalışma alanının seçili bir kısmına ait, arazi gerçeği verileriyle segmentlerin kesişimi.....	50
Şekil 2.29. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Gerçek Renk)..	50
Şekil 2.30. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Sentinel-1 VV). .....	51
Şekil 2.31. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Sentinel-1 VH). .....	51
Şekil 2.32. Çalışma alanından segmentler ile arazi gerçeği verilerinin çakışmasına bir örnek.....	53
Şekil 2.33. Çalışma alanının bir bölümüne ait arazi gerçeği verilerinin orta noktaları...53	
Şekil 2.34. Çalışma alanının bir bölümüne ait 30 m genişliğinde tampon oluşturulmuş büyük parsellerdeki arazi gerçeği verileri. ....	54
Şekil 2.35. Büyük parsellerde oluşturulan ek noktalara çalışma alanından bir örnek. ...54	
Şekil 3.1. S1 orijinal bantlar, ( <i>OrtS1</i> ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu. ....	62
Şekil 3.2 S1 orijinal bantlar+standart sapma+S1 doku özellikleri ( <i>OrtS1, StdS1, HmjS1, KontS1, FrkS1, EntS1, A2MoS1, KorS1</i> ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu. ....	63
Şekil 3.3. S2 orijinal bantlar kullanılarak ( <i>OrtS2</i> ) RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu. ....	64
Şekil 3.4. Yalnız NDVI bantları kullanılarak ( <i>OrtNDVI</i> ) RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu. ....	65
Şekil 3.5. S2 Orijinal bantlar+NDVI kullanılarak ( <i>OrtS2, Ort NDVI</i> ) DVM algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu. ....	65
Şekil 3.6. S2 orijinal bantlar+NDVI+S2 Doku değerleri kullanılarak ( <i>OrtS2, Ort NDVI, StdS2, HmjS2, KontS2, FrkS2, EntS2, A2MoS2, KorS2</i> ) RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu .....	67

Şekil 3.7. S1+S2 orijinal bantlar+NDVI kullanılarak ( <i>OrtS1, OrtS2, OrtNDVI</i> ) DVM algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.....	68
Şekil 3.8. S1 ve S2 orijinal bantlar+S1 ve S2 doku+NDVI kullanılarak ( <i>OrtS1, OrtS2, OrtNDVI, StdS1, StdS2, HmjS1, HmjS2, KontS1, KontS2, FrkS1, FrkS2, FrkS1, FrkS2,</i> ) RO algoritmasıyla yapılan nesne tabanlı sınıflandırma sonucu .....	69
Şekil 3.9. KA algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri. ....	72
Şekil 3.10. RO algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri. ....	75
Şekil 3.11. DVM algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri. ....	78

## KISALTMALAR

Bant: Sentinel- 1 uydularının VH ve VV bantları, Sentinel-2 uydularının Mavi, Yeşil, Kırmızı ve Yakın Kızılötesi bantları ve bu bantlardan üretilen NDVI bantları

CBS: Coğrafi Bilgi Sistemleri

ÇKS: Çiftçi Kayıt Sistemi

DVM: Destek Vektör Makineleri

ESA : European Space Agency (Avrupa Uzay Ajansı)

Ent: Segmentlerin Entropisi

FAO : Food and Agriculture Organization ( Gıda ve Tarım Örgütü)

Frk: Segmentlerin Farklılığı

GRD : Ground Range Detected (Zemin Aralığı Tespiti)

Hmj: Segmentlerin Homojenliği

KA: Karar Ağacı

K: Kırmızı Bant

RO: Rastgele Orman

M: Mavi Bant

MLC : Maximum Likelihood Classification ( Maksimum Olabilirlik Sınıflandırıcısı)

Mtree: Rastgele Orman Algoritması Rastgele Özellik (Değişken) Sayısı

NDVI: Normalized Difference Vegetation Index (Normalize Edilmiş Bitki İndeksi Farkı)

NIR: Near Infrared (Yakın Kızıl Ötesi)

Ntree: Rastgele Orman Algoritması Ağaç Sayısı

OOB: Out of Bag (Genelleştirilmiş Hatalar)

Ort: Segmentlerin Ortalaması

Özellikler: Ortalama, standart sapma, farklılık, entropi, homojenlik, açısız ikinci moment, korelasyon ve kontrast

S1: Sentinel-1

S2: Sentinel-2



SAR : Synthetic Aperture RADAR (Sentetik Açıklıklı Radar)

SLC : Single Look Complex ( Tek Görünüş Kompleksi)

SNAP: Sentinel Uygulama Platformu

Std: Segmentlerin Standart Sapması

UTM: Universal Transverse Mercator ( Evrensel Transversal Merkator)

WGS: World Geodetic System (Dünya Jeodezik Sistemi)

Y: Yeşil Bant

YKÖ: Yakın Kızılötesi Bantlar



# 1. GİRİŞ

Son yıllarda, artan nüfus ve enerji ihtiyacı gibi itici güçler, doğal kaynakların daha yoğun kullanılmasına yol açmaktadır. Küresel ihtiyaçlardaki bu değişim, mevcut arazi örtüsü doğaya zarar veren bir noktaya getirmiştir. Artan gıda arzına yanıt verebilmek için tarımsal alanların genişletilmesi, üretimin gelişmesi ve ürün verimliliğinin artırılması gerekmektedir [1]. Bu nedenle tarımsal ürünlerin izlenmesi ve tarımsal üretime yön verilmesi önümüzde ki yıllarda daha da önem kazanacaktır.

Tarımın etkili bir şekilde yönetilmesi ve izlenmesinde kullanılan ana araçlardan biri tarımsal ürünler ve diğer zirai kaynaklar hakkında istatistik ve bilgi toplanmasını sağlayan tarımsal tematik haritalamadır. Yetiştirilecek ürünlerin yönetilebilmesi ve karar verilebilmesi için, mahsul tipleri ve ekilmekte olan arazi alanı hakkında bilgi sahibi olmak gerekmektedir. Ek olarak, üretilen mahsullerin kalitesi ve sağlığı hakkında elde edilecek verilerde sürdürülebilir tarımsal üretim açısından önem arz etmektedir. Gerekli verileri toplamak için, arazi örtüsü bilgisine ve dolayısıyla tarımsal haritalamaya ekonomik ve uygulanabilir bir yaklaşım sağlayan önemli teknolojilerden biri uzaktan algılamadır [2].

Tarımsal uygulamalar, uzaktan algılamanın en yaygın kullanım alanlarından biridir. Arazi örtüsü ve arazi örtüsünün uydu görüntülerinden sınıflandırmaları, tarımda izleme ve değerlendirme için mekansal bilgi birikimini arttırmaktadır. Uzaktan algılama yöntemleriyle tarımsal ürün deseni tespiti ayrıca biyokütle, ürün verimi, evapotranspirasyon ve ürün suyu verimliliği gibi tarımsal ekosistem değişkenlerinin modellenmesini de sağlar [3].

Uzaktan algılama, farklı konumsal ve zamansal çözünürlüklerle arazi dinamiğinin uygun şekilde gözlemlenmesini, tanımlanmasını, haritalanmasını, değerlendirilmesini ve izlenmesini sağlar [4]. Uzaktan algılamanın avantajlarının en iyi şekilde kullanılabileceği alanlardan biri de dinamik alanlar olması nedeniyle tarımsal alanlardır.

Tarımda uzaktan algılama uygulamaları, optik ve SAR (Sentetik Açıklıklı RADAR) uydularının her ikisiyle de yapılabilmektedir.

Optik uydular pasif algılayıcılara sahiptir, güneşi ışınım kaynağı olarak kullanır ve yansıtılan radyasyonu elektromanyetik spektrumun görünür ve kızılötesi bölümünde ölçer. Görünür kısımda, yeşil bitkiler mavi ve kırmızı bantlarda düşük yansımaya değerleri verirler [5]. Aksine yaprak için hücreler arası yapı, tepe tacı yoğunluğu ve tepe tacı yapısı etkilerinin bir sonucu olarak, yakın kızılötesi (Near Infra Red–NIR) bölgede bitki yansımaları yüksektir [6]. Bu bitki yansıtma özelliklerini kullanarak, farklı amaçlar için birçok çalışma geliştirilmiştir. Optik sensörler ile sınıflandırma işleminde pek çok ilerleme kaydedilmesine rağmen bulut örtüsü ve zamansal çözünürlük gibi kısıtlamalar nedeniyle istenen bilgiyi sağlamak her zaman mümkün olmamaktadır.

Elektromanyetik spektrumun görünür ve kızılötesi bölgesindeki güçlü kontrast, çeşitli indekslerin üretilmesine ve sınıflandırma işleminde kullanılmasını mümkün kılar. Bu matematiksel nicel kombinasyonlar, bitki örtüsü indeksleri olarak bilinir. Bunlar arasında en sık kullanılanı 1974 yılında Rouse vd. tarafından geliştirilmiş olan NDVI (Normalize Edilmiş Bitki İndeksi Farkı)'dır [7]. Çok sayıdaki çalışmada, uzaktan algılama uygulamalarında bitki örtüsü indekslerinin kullanımı yer almıştır [8] [9] [10] [11].

Optik uyduların aksine, SAR uyduları kendi enerji kaynaklarını kullanırlar. SAR uydularının pek çok avantajı da vardır. Örneğin hava durumundan etkilenmezler ve gece gündüz görüntüleme yeteneğine sahiptirler.

Optik ve SAR uydularının uzaktan algılama teknolojilerindeki çeşitli sınırlamalarından dolayı, her iki sensörün birleştirilmesi farklı sınıfların ayırt edilmesine yardımcı olabileceğinden, her ikisinin de tarımsal amaçlar için ortak kullanımına olan ilgi artmaktadır [12]. Pek çok çalışmada farklı sensörlere sahip uydular kullanılarak tarımsal alanların sınıflandırmasını amaçlayan analizler gerçekleştirilmiştir [13] [14] [15] [16] [17].

Tarım için uyduların kullanımı 1973 yılında Bauer vd. tarafından başlatılmıştır [4]. Bauer tarafından yapılan ilk uydu görüntüsü sınıflandırma işlemi, ilk Landsat (Landsat 1) uydusunun ABD tarafından fırlatılmasıyla başlamıştır. Bauer bu çalışmada ABD'nin ortabatı bölgesindeki mısır ve soya tarlalarını sınıflandırmıştır [5]. Daha sonra, SPOT 1 uydusu Fransa tarafından 1986 yılında ve IRS-1A uydusu Hindistan tarafından 1988 yılında fırlatılmıştır. Tarımsal sınıflandırmanın geniş çapta benimsenmesi ve uzaktan algılanmanın kullanışlı bir teknoloji olarak dahil edilmesi, daha yeni ve daha iyi uydu sistemlerinin fırlatılmasını sağlamıştır.

Tek zamanlı uydu görüntülerinin kullanımının, ürünlerin spektral benzerliği nedeniyle tarımsal arazi sınıflandırması için uygun olmadığı kanıtlanmıştır. Çok zamanlı yöntemler, mahsullerin fenolojik gelişimini göz önünde bulundurdıkları için tarımsal ürünlerin sınıflandırmasında daha uygundur [18]. Örneğin Sakamoto vd. (2002), 250 m konumsal çözünürlüklü ve 16 gün zamansal çözünürlüklü, MODIS Geliştirilmiş Bitki İndeksi (Enhanced Vegetation Index - EVI) ile çok zamanlı pirinç ürününün sınıflandırılması işlemi başarılı bir şekilde gerçekleştirmişlerdir [19]. Turker, vd. (2005) ise çok zamanlı Landsat 7 ETM+ görüntülerini kullanarak parsel tabanlı tarımsal ürün sınıflandırması gerçekleştirmişlerdir. Karnchanasutham vd.(1995), ERS-1 (European Remote Sensing) SAR verilerinin Tayland'da pirinç ekim alanlarının ve büyümelerinin izlenmesi konusundaki kabiliyetlerini değerlendirmek için bir çalışma yapmıştır. En Yüksek Olasılık Sınıflandırıcısının kullanıldığı bu çalışmada 7 farklı tarımsal ürün deseni tespit edilmiştir [20]. Kaojarern vd. (2002) pirinç mahsulünü, genel arazi tiplerini ve Tayland'daki arazi kullanım sınıflarını tanımlamak için altı adet çok zamanlı ERS-2 (SAR) ve Landsat-5 (TM) görüntülerini birlikte kullanmıştır. Sınıflandırma işlemi En Yüksek Olasılık Sınıflandırma yöntemiyle gerçekleştirilmiştir [21]. Murthy vd. (2002), IRS 1-B ( Indian Remote Sensing- Hint Uzaktan Algılama) uydusuyla yaptıkları çalışmada, buğday ürününün desen tespitini, En Yüksek Olasılık Sınıflandırıcısı ve Yapay Sinir Ağları Yöntemiyle yapmış ve bu iki yöntemi karşılaştırmıştır [22]. Yüksek vd.(2008), tarafından ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) uydu görüntüleri arazi örtüsü türlerini sınıflandırmak için etkin bir şekilde kullanılmıştır [23].

Son yıllarda IKONOS, QuickBird ve SPOT 5, 6, 7 gibi yüksek çözünürlüklü uydu sistemleri de tarımsal ürün deseni tespitinde kullanılmaya başlanmıştır. Yüksek çözünürlüklü uydu görüntüleri, tarımsal ürünlerin daha doğru sınıflandırılması ve alan tahmini için düşük konumsal çözünürlüklü uydu görüntülerine göre daha yüksek doğruluklu sonuçlar vermektedir. Yang vd. (2010) tarafından yapılan çalışmada SPOT-5 uydu görüntüleri kullanılarak tarımsal ürün desenini tespit etmek için, parametrik ve parametrik olmayan sınıflandırma algoritmaları karşılaştırılmıştır. Bu çalışmada Destek Vektör Makineleri (DVM), Mahalonobis Mesafe, En Yakın Mesafe, En Yüksek Olasılık ve Spektral Açık Haritalayıcı yöntemleri kullanılmıştır. Çalışma sonucunda SPOT-5 için en yüksek doğruluğa, En Yüksek Olasılık Sınıflandırıcı ve Destek Vektör Makineleri yöntemleriyle ulaşılmıştır [24]. Turker vd. (2011) tarafından yapılan parsel tabanlı sınıflandırma çalışmasında SPOT4, SPOT5, IKONOS, QuickBird XS ve QuickBird PS uydularının sınıflandırma performansları karşılaştırılmıştır. Çalışmanın sonucunda en yüksek doğruluğa IKONOS uydu görüntüleriyle ulaşılmıştır (%85,5) [25].

Ancak yüksek çözünürlüklü uydu görüntülerinin ücretli olması nedeniyle kullanımları sınırlı kalmaktadır. Görüntülerin ücretsiz olarak Avrupa Uzay Ajansı (ESA)'ndan elde edilebildiği Sentinel-1 SAR ve Sentinel-2 optik uydu görüntülerinin tarımsal arazi sınıflandırmasındaki kullanımının son yıllarda yaygınlaştığı görülmektedir [26] [27] [28] [29] [30] [31] [32] [33]. Sentinel-1 uyduları 1A ve 1B olmak üzere ikiz uydulardan oluşmaktadır. Bu uydulardan ilki 3 Nisan 2014'te ikincisi ise 25 Nisan 2016'da fırlatılmıştır. Bu uyduların eş zamanlı ikiz uydular olması zamansal çözünürlüklerini 6 güne kadar düşürmektedir. Aynı şekilde Sentinel-2 uyduları da 1A ve 1B olmak üzere eş zamanlı ikiz uydulardır. Bu uydulardan ilki Haziran 2015'te, ikincisi Temmuz 2016'da fırlatılmıştır. Sentinel-2 uyduları da ikiz uydular olması sebebiyle 5 günlük zamansal çözünürlüğe sahiptir. Yüksek zamansal çözünürlükleri tarım alanları gibi dinamik alanlarda yapılan çalışmalarda, Sentinel uyduları görüntülerini çok değerli veriler haline getirmiştir. Küresel tarım alanlarının önemli bölümleri sıklıkla bulutla kaplı olduğu için, sentetik açıklık radarı (SAR), net optik görüntü elde etmenin zor olduğu bölgelerde tarımsal ürün desenini tespit etmek için kullanılan bir yöntemdir. Whelen ve Sequeira (2017), yaptıkları çalışmada tarımsal arazi örtüsü türlerini sınıflandırmak için Sentinel-1 uydusu C-bandına ait çok zamanlı görüntüleri kullanmıştır. Çalışmada hem VV hem de VH polarizasyonları ayrı ayrı ve kombine olarak kullanılmış ve yüksek doğruluk

değerlerine ulaşılmıştır. Bu çalışmada sonuç olarak, zaman serileri kullanarak yapılacak sınıflandırmada SAR verilerinin kıymetli veriler olduğu görülmüştür [33]. Vuolo vd. (2018), tarafından yapılan çalışmada Sentinel-2 uydu görüntüleri kullanarak 9 farklı tarımsal ürünün sınıflandırması yapılmıştır. Sonuç olarak, S2 uydu görüntülerinin çok zamanlı görüntü kullanımının sınıflandırmada doğruluğunu arttırdığı görülmüştür [32]. Sonobe vd. (2017) tarafından yapılan çalışmada, çok zamanlı Sentinel-1 ve Sentinel-2 uydu görüntüleri birlikte kullanılarak 6 farklı tarımsal ürün sınıflandırılmıştır. Bu çalışmada, S1 VV polarizasyonu verilerinin ve S2 Kırmızı bantın tarımsal ürün sınıflandırılmasında yüksek potansiyele sahip olduğu tespit edilmiştir.

Bu tez çalışmasında, Avrupa Uzay Ajansı (ESA) tarafından ücretsiz sağlanan Sentinel-1 (SAR) ve Sentinel-2 (Optik) uydu verilerinin tarımsal alanların sınıflandırmasında kullanımı araştırılmıştır. Çalışmada ESA'dan temin edilen çok zamanlı uydu görüntüleri kullanılmış, nesne-tabanlı sınıflandırma tekniğiyle ve 3 farklı makine öğrenme algoritmasıyla, farklı veri kombinasyonları da denenerek sınıflandırma doğrulukları araştırılmıştır.

Bu çalışmanın geçmiş çalışmalardan farkı, tarımsal yaz ürünlerin Sentinel-1 SAR ve Sentinel-2 optik uydu görüntülerini birlikte ve ayrı ayrı farklı veri özelliği kombinasyonları kullanarak nesne-tabanlı sınıflandırma yaklaşımıyla tespit edilmesidir. Ayrıca çalışmada KA, RO ve DVM olmak üzere 3 farklı makine öğrenme algoritması kullanılmış ve sonuçlar karşılaştırılmıştır.

### **1.1. Tezin Amacı**

Bu tez çalışmasının ana amacı, Gediz ovasının bir bölümünde bulunan tarımsal yaz ürünlerinin çok zamanlı Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanılarak makine öğrenme algoritmalarıyla nesne tabanlı sınıflandırılmasıdır. Çalışmanın diğer amaçları şu şekildedir:

- KA, RO ve DVM makine öğrenme algoritmalarının sınıflandırma performanslarını karşılaştırmak.

- Yalnız Sentinel-1 radar görüntülerinin sınıflandırma performansını belirlemek.
- Yalnız Sentinel-2 görüntülerinin sınıflandırma performansını belirlemek.
- Yalnız NDVI bantlarıyla sınıflandırma doğruluğunu test etmek.
- Sentinel-1, Sentinel-2 orijinal bantları ve NDVI değerlerinin sınıflandırma performansını belirlemek.
- Farklılık (dissimilarity), entropi (entropy), homojenlik (homogeneity), açısız ikinci moment (angular second moment), korelasyon (correlation) ve kontrast (contrast) doku özelliklerinin sınıflandırmaya etkisini belirlemek.
- Sınıflandırma işlemini farklı veri kombinasyonlarıyla yapmak ve dolayısıyla her bir veri kombinasyonunun performansını test etmektir.

## 1.2. Geçmiş Çalışmalar

Geçtiğimiz son 40 yıl boyunca, arazi örtüsünü, arazi örtüsüne tarım alanlarında ürün türlerini belirlemek için pek çok yöntem geliştirilmiştir. Literatürde, uzaktan algılama yöntemleriyle tarımsal ürün tespitine yönelik bir çok çalışma bulunmaktadır.

Yapılan bu çalışmalar geçmişten günümüze, farklı teknikleri kapsamaktadır. Bu teknikler kontrolsüz sınıflandırmadan, kontrollü sınıflandırmaya parametrik olmayan algoritmalarından, parametrik algoritmalar kullanılarak yapılan sınıflandırmalara ve piksel tabanlı sınıflandırmalardan, nesne-tabanlı sınıflandırmalara kadar çeşitlilik göstermektedir.

Karnchanasutham vd. (1995), ERS-1 (European Remote Sensing – Avrupa Uzaktan Algılama) SAR verilerinin Tayland'da pirinç ekim alanlarının ve büyümelerinin



izlenmesi konusundaki kabiliyetlerini deęerlendirmek için bir çalıřma yapmıřtır. En Yüksek Olasılık Sınıflandırıcısının kullanıldıęı bu çalıřmada 7 farklı tarımsal ürün deseni tespit edilmiřtir ve genel doęruluk %79 olarak bulunmuřtur [20].

Kaojarern vd. (2002) pirinç mahsulünü, genel arazi tiplerini ve Tayland'daki arazi kullanım sınıflarını tanımlamak için altı adet çok zamanlı ERS-2 (SAR) ve Landsat-5 (TM) görüntülerini birlikte kullanmıřtır. Sınıflandırma iřlemi En Yüksek Olasılık Sınıflandırıcısı yöntemiyle yapılmıřtır ve doęruluk %84,7 olarak bulunmuřtur [21].

Murthy vd. (2002) , IRS 1-B ( Indian Remote Sensing- Hint Uzaktan Algılama) uydusuyla yaptıkları çalıřmada, buęday ürünün desen tespitini, En Yüksek Olasılık Sınıflandırıcısı ve Yapay Sinir Ağları Yöntemiyle yapmıř ve bu iki yöntemi karřılařtırmıřtır [22]. Bu karřılařtırma sonucunda Yapay Sinir Ağları yönteminin En Yüksek Olasılık Sınıflandırıcısı yönetimine göre daha iyi sonuçlar verdięi görölmüřtür.

Otomatik kontrolsüz sınıflandırma 10 yıl öncesine kadar, en çok tercih edilen sınıflandırma yöntemlerinden biriydi. Kontrolsüz sınıflandırma, önceden oluřturulmuř bir eęitim verisine ihtiyaç duymaz. Örneęin Mayaux vd. (2004), birkaç farklı uydudan gelen verileri kullanarak, kontrolsüz sınıflandırma yöntemiyle 100 arazi örtüsü sınıfı üreterek, Afrika kıtasının arazi örtüsü haritasını oluřturmuřlardır [34].

Tarımsal ürün sınıflandırmasında bir dięer yaklařım parsel tabanlı sınıflandırma yöntemleridir. Turker vd. (2005), parsel tabanlı sınıflandırma yöntemleriyle çok zamanlı Landsat 7 ETM+ görüntülerini kullanarak tarımsal ürünlerin tespitini gerçekleřtirmişlerdir. Çalıřmada elde edilen genel doęruluk %81,03 olmuřtur [35].

DVM sınıflandırma iřlemlerinde sıklıkla kullanılan bir algoritmadır. Bu algoritmanın dezavantajlarından birisi, giriř parametrelerine duyulan ihtiyaçtır. Bununla birlikte, önemli bir avantajı, eęitim verilerine daha düşük baęımlılıktır. DVM, küçük eęitim veri kümeleriyle iyi çalıřır ve eksik verilere dirençlidir [36]. Dash vd. (2007)'nin DVM ile

yaptıkları sınıflandırma bu algoritmanın etkinliğini göstermiştir. Sınıflandırma sonucunda %88 genel doğruluğa ulaşılmıştır [10].

RO sınıflandırıcısının popülaritesinin artmasıyla bir çok çalışmada bu metod kullanılmıştır. Pal (2007), Landsat-7 uydu görüntülerini kullanarak RO ve DVM ile elde edilen sonuçları karşılaştırmıştır. Pal, çalışma sonucunda RO'nun DVM'ye benzer bir genel doğruluk elde ettiğini hesaplamıştır (%88). Ancak, RO'nun değişken önemi hakkında bilgi sunması ve veri setindeki aykırı değerlerin tespit edilmesinde bir yol sunması gibi avantajlarının, RO'yu daha ilginç bir algoritma haline getirdiği sonucuna varmıştır [37].

Yüksel vd. (2008), tarafından ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer - Gelişmiş Uzay Termal Emisyonu ve Yansıma Radyometresi) çok zamanlı uydu görüntüleri arazi örtüsü türlerini sınıflandırmak için etkin bir şekilde kullanılmıştır. Çalışma sonucunda %83,2 genel doğruluk değeri hesaplanmıştır [23].

Yang vd. (2010) tarafından yapılan çalışmada SPOT-5 uydu görüntüleri kullanılarak tarımsal ürün desenini tespit etmek için, parametrik ve parametrik olmayan sınıflandırma algoritmaları karşılaştırılmıştır. Bu çalışmada Destek Vektör Makineleri (DVM), Mahalonobis Mesafe, En Yakın Mesafe, En Yüksek Olasılık ve Spektral Açılı Haritalayıcı yöntemleri kullanılmıştır. Çalışma sonucunda SPOT-5 için en yüksek doğruluğa, En Yüksek Olasılık Sınıflandırıcı ve Destek Vektör Makineleri yöntemleriyle ulaşılmıştır. Çalışmada elde edilen en yüksek genel doğruluk değeri En Yüksek Olasılık Sınıflandırıcısıyla, çalışmada kullanılan iki farklı alanda sırasıyla %91 ve %87 olarak hesaplanmıştır [24].

Turker vd. (2011) tarafından yapılan bir diğer parsel tabanlı sınıflandırmada farklı uydu görüntüleri kullanılarak tarımsal ürün tespitindeki genel doğruluk oranları karşılaştırılmıştır. Çalışma sonucunda ulaşılan genel doğruluk oranı SPOT4 için %76,3, SPOT5 için %77,9, IKONOS için %88,9, QuickBird XS için %85,0 ve QuickBird PS için %85,5 olarak bulunmuştur [25].

Du vd. (2012) yaptığı çalışmada, Destek Vektör Makinesi ve Rastgele Orman (RO) algoritmasını birleştirerek DWDCS (Distance-Weighted Dynamic Classifier Selection) algoritmasını oluşturmuşlardır. AVIRIS uydu görüntüleriyle tarımsal alanlar sınıflandırılmıştır. Destek Vektör Makinesi ve RO algoritmalarının sırasıyla genel doğruluğu %94,3, %95,1 iken DWDCS algoritmasında %98,1 genel doğruluk değeri hesaplanmıştır. [38].

Akar ve Güngör (2013) tarafından yapılan çalışmada, Trabzon Sürmene’de yetiştirilen fındık ve çay ürünleri WorldView-II görüntüleriyle sınıflandırılmıştır. Çalışmada çok zamanlı uydu görüntüleri kullanılmıştır. Bu görüntüler RO, DVM ve Gentle Adaboost makine öğrenme algoritmalarıyla birlikte, En Çok Benzerlik yöntemiyle de sınıflandırılmıştır. RO algoritmasının genel doğruluğu sırasıyla yaz dönemi için %79,05 ve kış dönemi için %71,84 olarak elde edilmiştir. Bu çalışmada RO algoritması diğer algoritmalara göre daha yüksek sınıflandırma doğruluğu vermiştir [39].

Kussul vd. (2016), Ukrayna’nın Kiev ve Odessa kentleri yakınlarında yaptıkları tarımsal ürün sınıflandırmasında çok zamanlı optik Landsat-8 ve sentetik açıklıklı radar (SAR) Sentinel-1 görüntülerini kullanmışlardır. Bu çalışmada piksel ve parsel bazlı sınıflandırma yaklaşımlarını karşılaştırmışlardır. Her iki sınıflandırma yaklaşımında MLP (Multilayer Perceptron) algoritmasıyla gerçekleştirilmiştir. Sınıflandırma sonucunda piksel bazlı sınıflandırmada %85,32 ve parsel bazlı sınıflandırmada %89,40 genel doğruluk değerlerine ulaşılmıştır [40].

Whelen ve Sequeira (2017), yaptıkları çalışmada Amerika Birleşik Devletleri’nin Kuzey Dakota Eyaleti’nin bir bölümünde tarımsal arazi örtüsü türlerini sınıflandırmak için Sentinel-1 uydusu C-bandına ait çok zamanlı görüntüleri kullanmıştır. Çalışmada, Hem VV hem de VH polarizasyonları ayrı ayrı ve kombine olarak, model oluşturmada çoklu yinelemeler kullanıldığında rutin olarak %90’ın üzerinde genel doğruluklar üretebildiği gösterilmiştir. Bu sonuçlar, kapsamlı zaman serileri verilerinden oluşturulan SAR tabanlı tarımsal arazi örtüsü sınıflandırmaları için potansiyeli göstermektedir [33].

Sonobe vd. (2017) , tarafından yapılan çalışmada, çok zamanlı Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanılarak 6 farklı tarımsal ürün sınıflandırılmıştır. Çalışmada 2016 yılına ait 5 farklı tarihe ait görüntüler kullanılmıştır. Çalışmada ayrıca farklı sınıflandırma modellerindeki potansiyeli de belirleyebilmek için, Kernel Temelli Aşırı Öğrenme Makinesi (KELM), Çok Katmanlı İleri Beslemeli Sinir Ağları, RO ve DVM gibi dört farklı yaklaşım karşılaştırılmıştır. Algoritma hiperparametreleri, Bayesian optimizasyonu kullanılarak ayarlanmıştır. Genel olarak, KELM en yüksek performansı vermiş ve %96,8 genel sınıflandırma doğruluğu sağlamıştır. Bu çalışmada, S1 VV polarizasyonu verilerinin ve S2 Kırmızı bantın tarımsal ürün sınıflandırılmasında doğruluğa olan etkisinin yüksek olduğu tespit edilmiştir [31].

Vuolo vd. (2018) tarafından yapılan çalışmada, Sentinel-2 uydu görüntüleri ile 9 farklı tarımsal ürünün sınıflandırması yapılmıştır. Sınıflandırma, Avusturya'daki tarımsal bir bölgede yapılmış olup, 2016 ve 2017 yıllarına ait iki yıllık veriler kullanılmıştır. Çalışmada Rastgele Orman (RO) sınıflandırıcısı uygulanmıştır. Ayrıca, görüntü alınan 2 farklı yılın doğrulukları da karşılaştırılarak S2 uydu görüntülerinin farklı yıllarda verdiği sınıflandırma sonuçlarının güvenilirliği karşılaştırılmıştır. Sonuç olarak, çoklu-zamansal görüntü kullanımının, 2016 ve 2017 yılları için benzer eğilimlerle ürün tipi sınıflandırmada doğruluğunu nasıl arttırdığını göstermektedir. Rastgele Orman algoritmasıyla yapılan sınıflandırmada 2016 yılında %95 ve 2017 yılında %96 genel doğruluk değeri hesaplanmıştır [32].

### **1.3. Kullanılan Yazılımlar**

Bu çalışmada SNAP, ArcGIS, e-Cognition ve R yazılımları kullanılmıştır. SNAP programıyla Sentinel-1 SAR uydu görüntülerinin ön-işlenmesi yapılmıştır. ArcGIS programıyla ise eğitim ve test verilerinin CBS ortamına aktarılması ve sınıflandırma sonuçlarının görsel olarak değerlendirilmesi gerçekleştirilmiştir. Çalışmada kullanılan çoklu çözünürlük segmentasyon işlemleri e-Cognition yazılımı kullanılarak gerçekleştirilmiştir.

KA, RO ve DVM algoritmaları kullanılarak yapılan sınıflandırma işlemleri ise R programında gerçekleştirilmiştir.

#### **1.4. Tezin Organizasyonu**

Bu tez çalışması 5 bölümden meydana gelmektedir. Tezin 1. bölümünde geçmiş çalışmalar ve tezin amacına değinilmiştir. Tezin 2. bölümünde çalışma alanı, kullanılan veriler, çalışmada kullanılan makine öğrenme algoritmaları ve görüntülerin işlenmesi ve sınıflandırması esnasında uygulanan yöntemler anlatılmıştır. Tezin 3. bölümünde sınıflandırma sonucunda elde edilen bulguların değerlendirmesi ve karşılaştırması yapılmıştır. Tezin 4. bölümünde bu tez çalışması neticesinde varılan sonuçlar açıklanmıştır. Son olarak tezin 5. bölümünde tez çalışması süresince elde edilen analiz tabloları ek olarak verilmektedir.

## 2. YÖNTEM

### 2.1. Çalışma Alanı ve Veriler

Çalışma alanı Türkiye'nin en verimli tarım alanlarından biri olan Gediz ovasında bulunmaktadır. Çalışma alanının siyasi sınırları Manisa İlinin sınırları içerisinde olup Ahmetli ve Salihli ilçelerinin sınırları içerisinde (Sol Üst Boylam: 27,844° Enlem: 38,625° Sağ Alt Boylam: 28,181° Enlem: 38,463° ) yer almaktadır.

Çalışma alanının büyük kısmı tarım alanlarıyla kaplıdır. Alanın içerisinde ayrıca bazı küçük yerleşim birimleri, ormanlar ve meralarda bulunabilir. Bu çalışmada sınıflandırma için sadece tarım alanları dikkate alınmıştır. Kalan sınıflar “diğerleri” olarak kabul edilmiştir. Çalışma alanında başlıca yetiştirilen tarım ürünleri mısır, yonca, zeytin, domates, biber, patlıcan, pamuk, buğday ve üzüm olarak sıralanabilir. Bununla birlikte küçük alanlarda lahana, fiğ, brokoli, arpa, ıspanak ve meyve bahçeleri de bulunmaktadır. Çalışma alanının yaklaşık yüz ölçümü 520 km<sup>2</sup> olup, batı-doğu yönünde yaklaşık 30 km, kuzey-güney yönünde 18 yaklaşık km'dir.

Gediz ovası yetiştirilen ürün çeşitliliğinin fazla olmasıyla ve bir yıl içerisinde birden fazla ürün alınabilmesiyle Türkiye'nin tarımsal üretimi açısından önemli bir bölgedir. Ayrıca alanda tarım arazileri büyüklükleri de çeşitlilik göstermektedir. En küçüğü yaklaşık 3 dekar, en büyüğü yaklaşık 4700 dekar olmak üzere irili ufaklı pek çok tarım parseli bulunmaktadır. Bir senede birden fazla ürün alınabilmesi, ürün çeşitliliğinin fazla olması ve irili ufaklı tarım parsellerinin çokluğu gibi nedenlerden ötürü çalışma alanı zorlu bir alan olma özelliği taşımaktadır. Şekil 1.1, seçilen çalışma alanının kapsamını göstermektedir.



Şekil 2.1. Çalışma alanı.

Bu çalışmada kullanılan toplamda 8 farklı tarihli Sentinel-1 SAR (Sentetik Açıklık Radarı) ve Sentinel-2 optik uydu görüntülerinden oluşan bir veri kümesi kullanılmıştır. Kullanılan uydu görüntüleri Avrupa Uzay Ajansı'nın (AUA) Copernicus Açık Erişim Merkezi adındaki internet sitesinden (<https://scihub.copernicus.eu/dhus/#/home>) ücretsiz olarak temin edilmiştir [41]. Çalışmada uydu görüntülerinin yanı sıra Arazi Gerçeği Verileri ve Çiftçi Kayıt Sistemi (ÇKS) Verileri de kullanılmıştır.

### 2.1.1. Uydu Görüntüleri Tarihlerinin Seçimi

Daha önce de belirtildiği gibi bu çalışmada çok zamanlı Sentinel-1 SAR ve Sentinel-2 optik uydu görüntüleri kullanılmıştır. Kullanılacak uydu görüntülerinin tarihlerinin belirlenebilmesi için sınıflandırılacak tarım ürünlerinin fenolojik özelliklerini bilmek gerekmektedir. Sınıflandırılacak bitkilere ait fenolojik özellikler Türkiye Fenoloji Atlası'ndan temin edilmiştir [42]. Fenoloji atlasında yer almayan biber, domates, patlıcan ve yonca ise arazi çalışmaları sırasında bölge halkına sorularak ve uzman görüşü alınarak oluşturulmuş ve Tablo 2.1' e eklenmiştir.

Tablo 2.1. Tarımsal ürünlerin gelişim süreçleri.

Biber													
Buğday													
Domates													
Mısır													
Mısır 2	Buğday												
	Mısır												
Pamuk													
Patlıcan													
Üzüm	Üzümün anlamlı değişim gösterdiği tek dönem yaprak dökme dönemidir.												
Yonca	Yonca hasadı birkaç haftada bir yapıldığından tabloda gösterilmemiştir.												
Zeytin	Zeytinin yansımaya değerleri yapraklarını dökmediği için belirgin bir değişim göstermemektedir.												
	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	
	Ekim	Gelişim				Hasat	Yaprak Dökme						


Elde edilen bulgular neticesinde çalışmada kullanılacak uydu görüntülerinin Nisan-Kasım tarihleri arasında olması gerektiğine karar verilmiştir. Çalışmada 8 adet çok zamanlı uydu görüntüsü kullanılmıştır. Uydu görüntüleri seçilirken Sentinel-1 ve Sentinel-2'ye ait olan uydu görüntülerinin tarihlerinin birbirine yakın olmasına özen gösterilmiştir ve her ay için bir görüntü seçilmeye çalışılmıştır. Çalışmada kullanılan uydu görüntülerinin tarihleri Tablo 2.2' de gösterilmektedir. Tablo 2.2'de gösterilen görüntü tarihleri, Tablo 2.1'de gösterilen tarımsal ürünlerin gelişim süreçleri dikkate alınarak belirlenmiştir.

Tablo 2.2. Çalışmada kullanılan uydu görüntülerinin tarihleri.

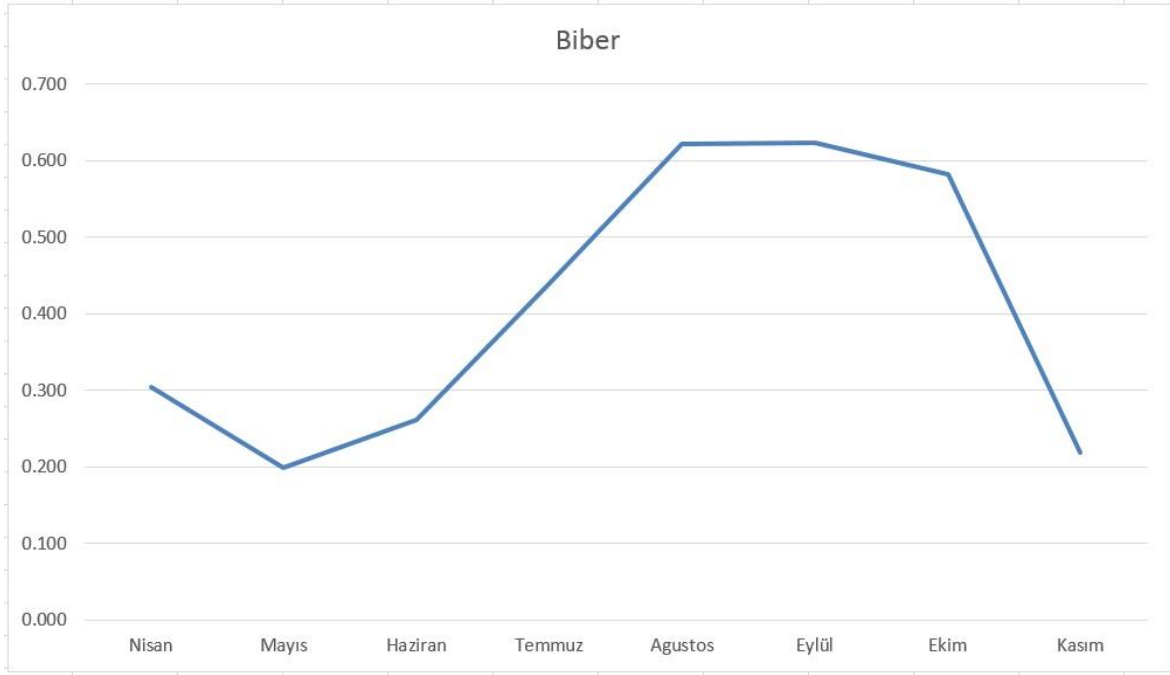
Görüntü Tarihleri	Sentinel-1	Sentinel-2
	13 Nisan 2017	10 Nisan 2017
	1 Mayıs 2017	3 Mayıs 2017
	1 Haziran 2017	2 Haziran 2017
	30 Haziran 2017	2 Temmuz 2017
	31 Temmuz 2017	1 Ağustos 2017
	5 Eylül 2017	7 Eylül 2017
	11 Ekim 2017	10 Ekim 2017
	16 Kasım 2017	16 Kasım 2017



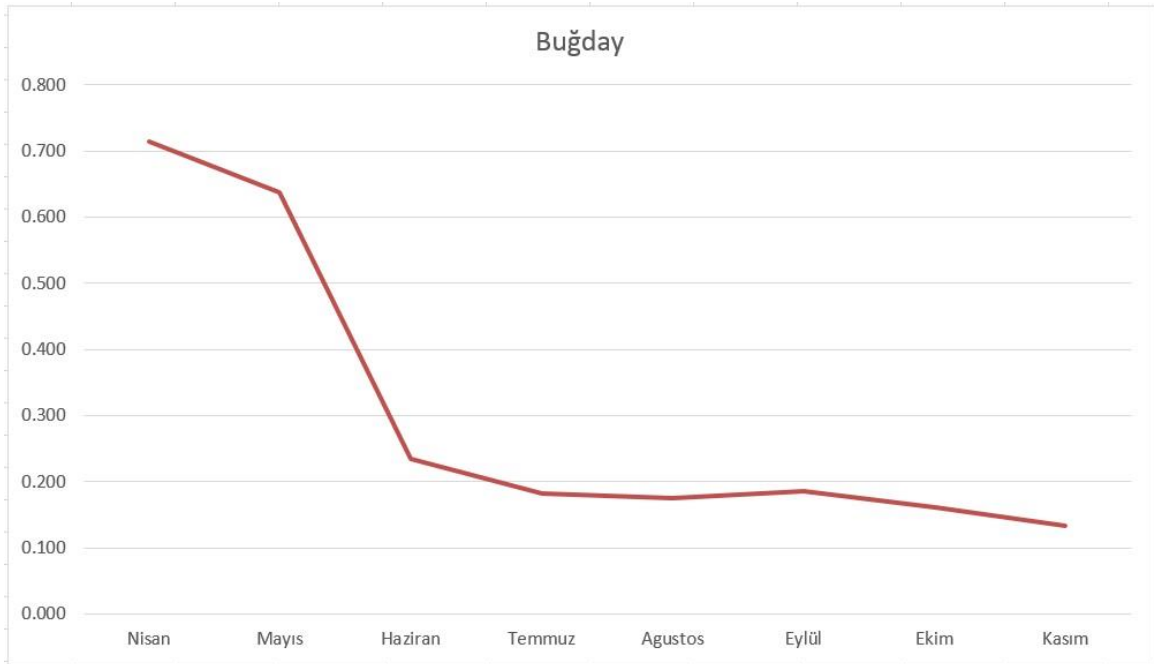
Daha sonra, Sentinel-2 görüntülerinden NDVI değerleri hesaplanmıştır. Eğitim ve test verilerinden NDVI ortalamaları değeri hesaplanmıştır. Daha sonra her bir görüntüdeki NDVI değerleri görsel olarak incelenmiş, sınıflandırılacak ürünlerin anlamlı değişim gösterdiği tarihler olup olmadığına bakılmıştır. Böylece seçilen uydu görüntüsü tarihlerinin doğruluğu test edilmiştir. Elde edilen NDVI değerleri Şekil 2.2’de gösterilmektedir. Ayrıca arazi gerçeği verisi olarak kullanılan ürün poligonlarının ortalama NDVI değerleri Şekil 2.3, Şekil 2.4, Şekil 2.5, Şekil 2.6, Şekil 2.7, Şekil 2.8, Şekil 2.9, Şekil 2.10, Şekil 2.11 ve Şekil 2.12’de her bir ürün için ayrı ayrı gösterilmiştir. Çalışmada kullanılan uydu görüntüleri ise Şekil 2.13, Şekil 2.14 ve Şekil 2.15’de gösterilmektedir.



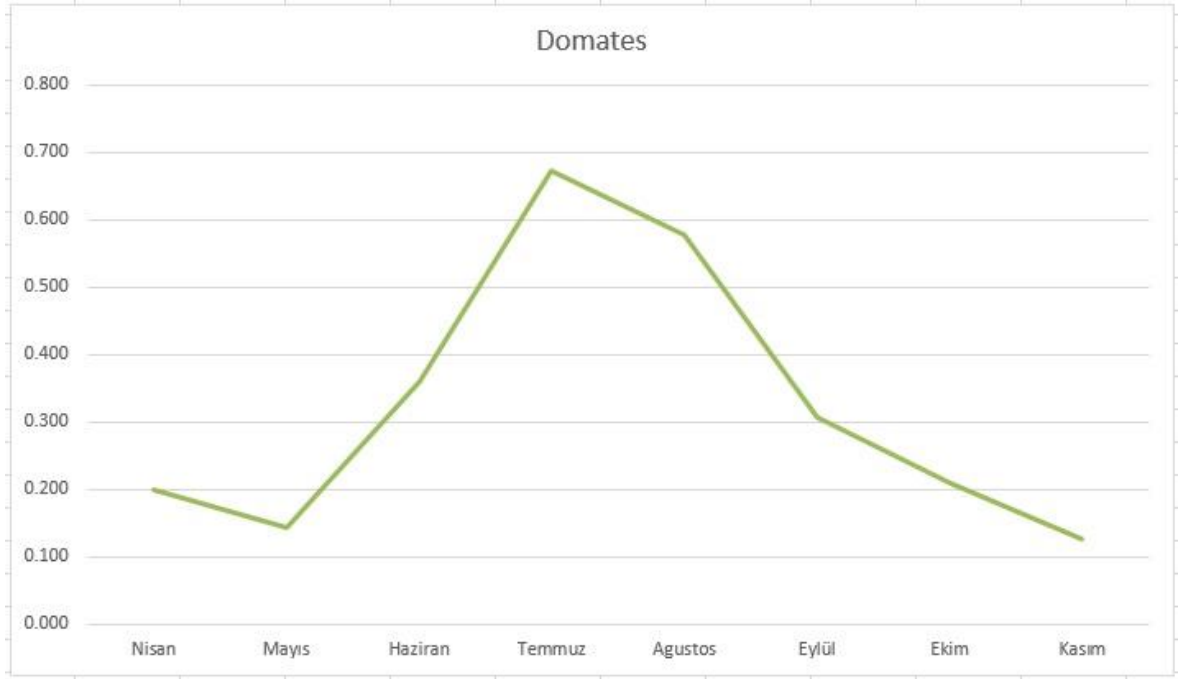
Şekil 2.2. Tarımsal ürünlerin ortalama NDVI değerlerinin aylara göre değişimi.



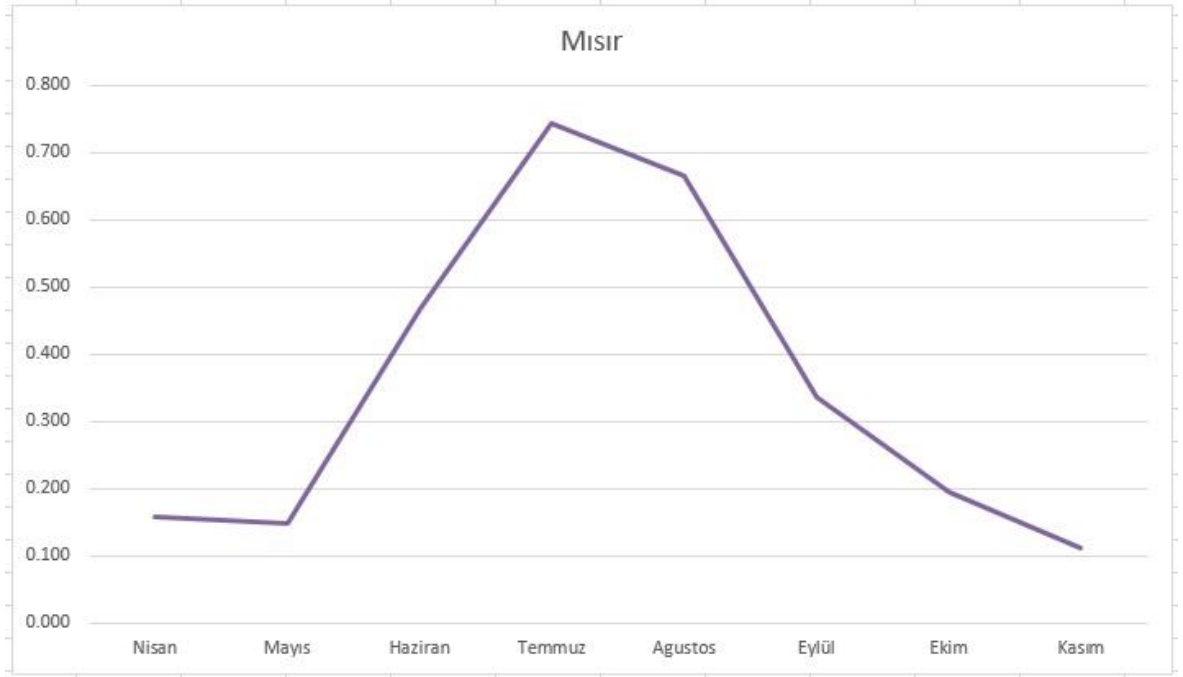
Şekil 2.3. Biberin ortalama NDVI değerlerinin aylara göre değişimi.



Şekil 2.4. Buğdayın ortalama NDVI değerlerinin aylara göre değişimi.



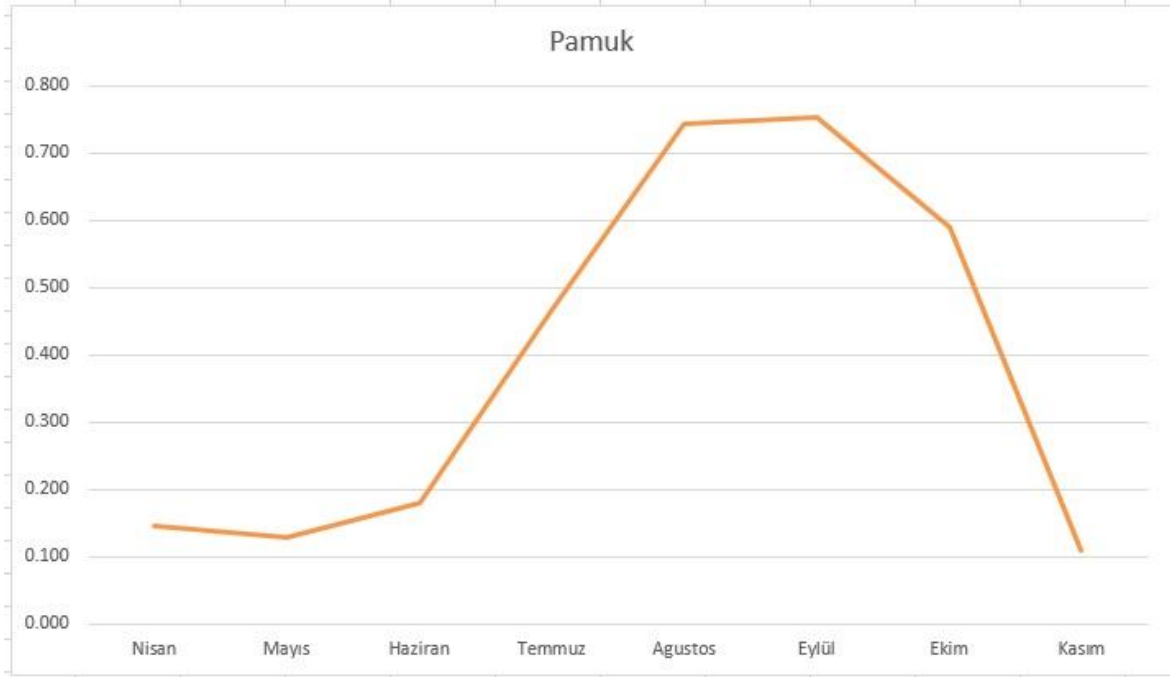
Şekil 2.5. Domatesin ortalama NDVI değerlerinin aylara göre değişimi.



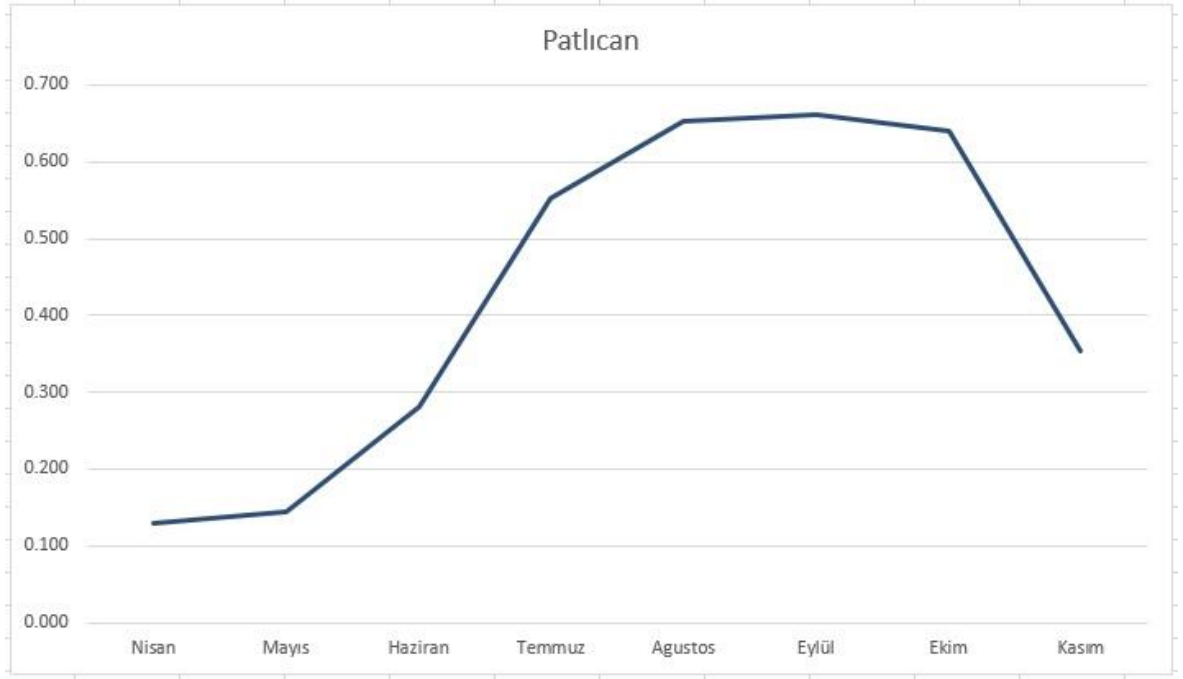
Şekil 2.6. Mısırın ortalama NDVI değerlerinin aylara göre değişimi.



Şekil 2.7. Mısır2'nin ortalama NDVI değerlerinin aylara göre değişimi.



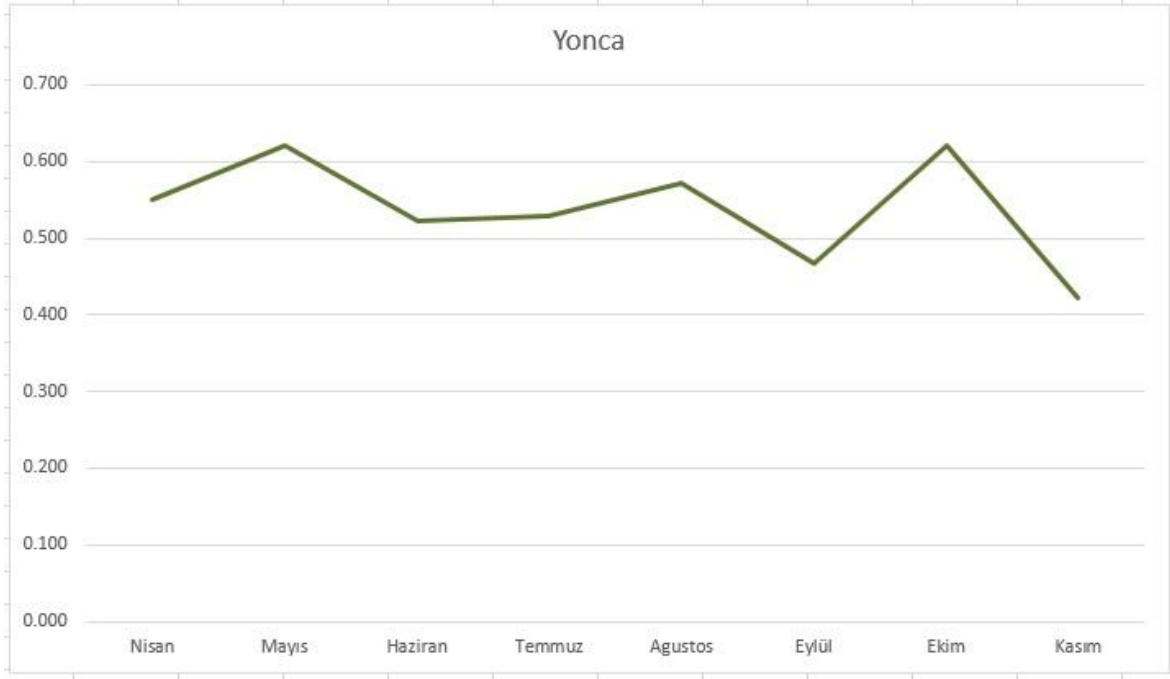
Şekil 2.8. Pamuğun ortalama NDVI değerlerinin aylara göre değişimi.



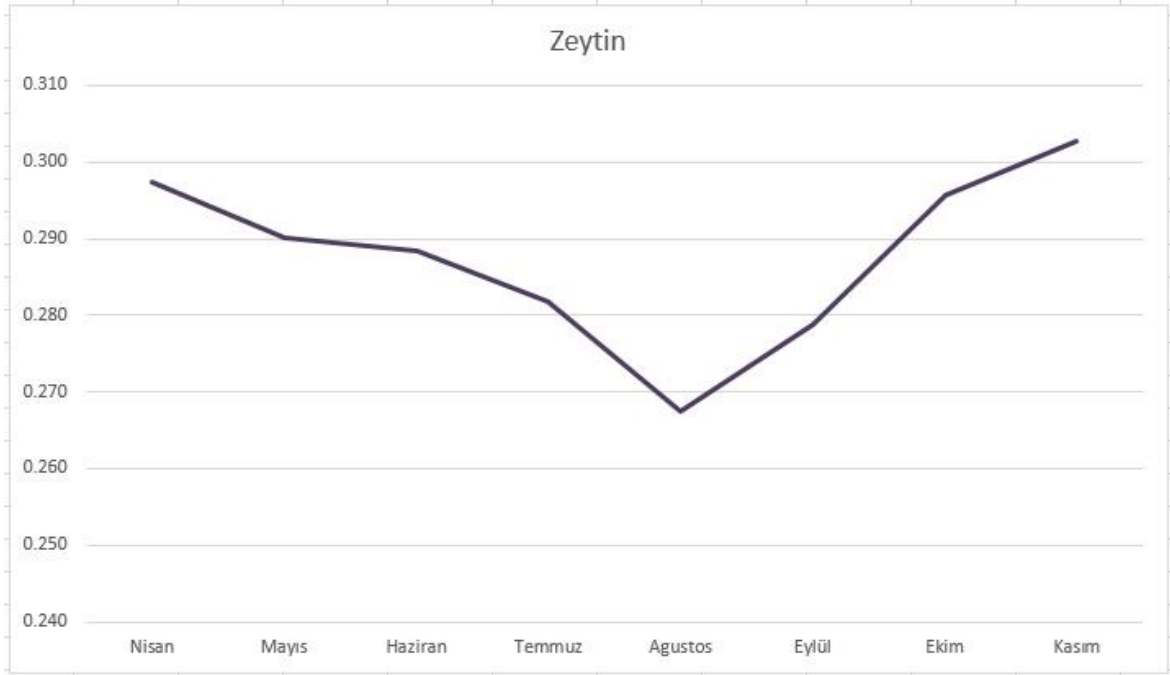
Şekil 2.9. Patlıcanın ortalama NDVI değerlerinin aylara göre değişimi.




Şekil 2.10. Üzümün ortalama NDVI değerlerinin aylara göre değişimi.




Şekil 2.11. Yoncunun ortalama NDVI değerlerinin aylara göre değişimi.



Şekil 2.12. Zeytinin ortalama NDVI değerlerinin aylara göre değişimi.




Şekil 2.13. Çalışmada kullanılan Sentinel-1 uydu görüntüleri VV bantları (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).



Şekil 2.14. Çalışmada kullanılan Sentinel-1 uydu görüntüleri VH bantları (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).





Şekil 2.15. Çalışmada kullanılan Sentinel-2 uydu görüntüleri K,Y,M bantları gerçek renk (nisan, mayıs, haziran, temmuz, ağustos, eylül, ekim, kasım ayları ).

### 2.1.2. Arazi Gerçeđi Verileri

Eđitim ve test veri setlerinin oluřturulabilmesi iin Hacettepe niversitesi Geomatik Mhendisliđi Anabilim Dalı'nda daha nce aynı alanda yapılan bařka bir tez alıřması iin toplanan Arazi Gerçeđi Verileri kullanılmıřtır [30]. Arazi gerçeđi verileri, rnlerin byk blmnn arazide olduđu 25.08.2017-05.09.2017 tarihleri arasında arazi alıřmaları yapılarak yerinde tespit edilmiřtir (řekil 2.16-2.17). Eđitim veri setini zenginleřtirmek amacıyla KS verileri de arazi gerçeđi verileriyle karřılařtırılarak uygun grlen KS verileri arazi gerçeđi verisi olarak kullanılmıřtır (Tablo 2.3).

Arazi alıřmaları esnasında 430 adet alan tespit edilmiřtir. Bunun yanı sıra KS verilerinden elde edilen parsellerin de kullanılmasıyla toplam 1195 adet parsel eđitim verisi olarak kullanılmıřtır. Bir kadastro parselinin ierisinde birden fazla rn olması durumunda rnleri ayıran sınırlar sayısallařtırılmıř ve ayrı parseller gibi deđerlendirilmiřtir. Kullanılan arazi gerçeđi verilerinin alıřma alanı zerindeki dađılımı řekil 2.18'de gsterilmektedir.

Kullanılan her bir parselin spektral yansımadađerlerine bakılmıř ilgili parsele ait yansımadađerlerinin farklı tarihlerdeki NIR bantı ve NDVI'a ait yansımadađerleri karřılařtırılmıř ve ilgili parseller eđer rnlere ait yansımadađerleriyle uyulmuyorsa bu parseller eđitim verisi kmesinden ıkarılmıřtır.

Eđitim verisine ait parseller oluřturulduktan sonra bu alıřmada nesne tabanlı sınıflandırma yaklařımı kullanıldıđı iin segmentlerdeki verileri eđitim verisine aktarabilmek iin poligon formatındaki parsel verileri, nokta formatında verilere dnřtrlmř ve her bir poligonun orta noktası bulunmuřtur.

Ayrıca ok byk parsellerde daha fazla eđitim noktası rneđi almanın mmkn hale gelebilmesi iin 100 dekadandan byk parsellerde her 100 dekada 1 nokta daha atılarak eđitim verisi olarak kullanılmak nokta sayısı arttırılmıř ve toplamda 1660 nokta kullanılmıřtır.




Şekil 2.16. Çalışma sahasından zeytin bahçesi fotoğrafı [30].



Şekil 2.17. Çalışma sahasından mısır tarlası fotoğrafı [30].

Tablo 2.3. Kullanılan ÇKS verilerinden bir örnek.

İl	İlçe	Köy	Ada No	Parsel No	Kullanılan Alan(da)	Parsel Alanı(da)	Ürün	Tarım Şekli	Ekim Tarihi	Hasat Tarihi	Ekili Alan (da)
MANISA	SALİHLİ	ÇAVLU	0	1966	21.56	21.56	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	21/08/2015	19/08/2017	21.56
MANISA	SALİHLİ	ÇAVLU	0	1777	29.054	106.2	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/02/2000	15/08/2018	29.054
MANISA	SALİHLİ	ÇAVLU	0	1710	16.598	16.6	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	30/08/2016	20/08/2018	16.568
MANISA	SALİHLİ	ÇAVLU	0	1170	5.593	16.782	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	10/02/1975	15/08/2018	5.593
MANISA	SALİHLİ	ÇAVLU	0	1219	1.978	27.71	FİĞ (MUHTELİF)	Sulu	01/11/2016	01/06/2017	1.978
MANISA	SALİHLİ	ÇAVLU	0	1219	1.978	27.71	MISIR (SILAJLIK)	Sulu	01/07/2017	10/10/2017	1.978
MANISA	SALİHLİ	ÇAVLU	0	1221	11.245	11.245	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	10/02/1975	15/08/2017	11.245
MANISA	SALİHLİ	ÇAVLU	0	1685	15.199	26.6	FİĞ (MUHTELİF)	Sulu	01/11/2016	01/06/2017	15.199
MANISA	SALİHLİ	ÇAVLU	0	1685	15.199	26.6	MISIR (SILAJLIK)	Sulu	01/07/2017	10/10/2017	15.199
MANISA	SALİHLİ	ÇAVLU	0	393	6.991	30.375	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	12/02/1993	15/08/2018	6.991
MANISA	SALİHLİ	ÇAVLU	0	413	3.625	3.625	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	20/02/2012	20/08/2018	3.625
MANISA	SALİHLİ	ÇAVLU	0	1139	6.093	6.093	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/01/1988	15/08/2017	6.093
MANISA	SALİHLİ	ÇAVLU	0	1475	3.32	3.32	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/01/1988	15/08/2017	3.32



Şekil 2.18. Arazi gerçeği verilerinin dağılımı.

## 2.2. Uydu Görüntüleri

### 2.2.1. Sentinel-1 Uydu Görüntüleri – SAR ( Sentetik Açıklıklı Radar)

Sentinel-1 A ve B SAR (Sentetik Açıklıklı Radar) uyduları, 3 Nisan 2014 ve 25 Nisan 2016 tarihlerinde yörüngeye yerleştirilmiştir. Sentinel-1 uydu takımı, Copernicus Programındaki Avrupa Uzay Ajansı (AUA) tarafından geliştirilmiştir. Program, Avrupa ülkelerine C bantı (5,6 cm) içinde eksiksiz ve güncel veri sağlamak için geliştirilmiştir. İki uydunun yörüngesi, her 6 günde bir aynı coğrafi alanın araştırılmasına olanak sağlayacak şekilde planlanmıştır [43].

Sentinel, verilere kolay erişilebilmesinden ve ücretsiz olduğu için çok çeşitli uygulamalarda kullanılır. Veriler dört modda toplanabilir:

•**Stripmap modu (SM)** – 5 m x 5 m uzamsal çözünürlükte 80 km genişlikteki verileri toplar. SM, ERS ve Envisat misyonlarının doğrudan bir devamıdır. 1991 yılında başlatılan Avrupa Uzaktan Algılama Uydusu (ERS) ve 2002 yılında Envisat, ESA tarafından finanse edilen ilk Dünya gözlem uydu programlarından ikisidir. Stripmap modu, temel olarak afet yönetimi faaliyetlerini desteklemek için kullanılır [44].

•**İnterferometrik Geniş Alan (Interferometric Wide Swath) (IW)** - Bu mod, kapsama alanı için 250 metrelik genişliğe ve 5 m'ye 20 m'lik mekansal çözünürlüğe sahiptir (tek görünüm). İnterferometrik geniş alan, Sentinel-1 için arazi üzerinde birincil moddur [44].

•**Ekstra Geniş Alan (Extra Wide Swath) (EW)**- EW modunun IW moduna göre beş alt bölümü vardır ve 20 m'ye 40 m'lik düşük bir çözünürlük sağlar [63]. Geniş kapsamın gerekli olduğu denizcilik gibi hizmetlerde kullanılır [44].

•**Dalga (Wave) (WV)** - Bu modda, veri edinimi 5 m x 5 m uzamsal çözünürlük ve 20 km 20 km'lik stripmap görüntüleri ile yapılır. Bu imgeler, her 100 km'de iki farklı geliş açısında dönüşümlü olarak elde edilir [44].

Sentinel-1 interferometrik alan (IW) tarama modu, veri elde etmek için Aşamalı Tarama SAR (TOPSAR) görüntüleme tekniği ile Arazi Gözlemine kullanır. Yukarıda belirtildiği

gibi IW modu, 250 m genişliğinde ve 5 m'de 20 m uzamsal çözünürlük aralığında ve azimutta geniş bir açı ile veri toplar [44]. IW modu, Sentinel-1 için arazi üzerinde birincil çalışma modudur.

Sentinel-1 görüntüleri SLC (Single Look Complex) veya GRD (Ground Range Detected) formatında ve çeşitli alım modlarında kullanılabilir. Bu tez çalışmasında, görüntülerin 250 km tarama alanı ve 5 m x 20 m uzaysal çözünürlüğe göre kaydedildiği bir mod olan İnterferometrik Geniş Alan (IW) modu ve GRD formatı tercih edilmiştir. Bu çalışmada, Avrupa Uzay Ajansı'nın (ESA) Sentinel-1A ve 1B uydularından çift polarize (VV / VH) C-bantı görüntüleri kullanmıştır.

### **2.2.2.Sentinel-2 Optik Uydu Görüntüleri**

Sentinel-2 misyonu Sentinel-2A ve Sentinel-2B olmak üzere 2 uydudan oluşmaktadır. Bu uydular 786 km yörünge yüksekliği ve 13 adet spektral bantıyla, kutupsal yörüngeli multi-spektral görüntü alabilmektedir.

Sentinel-2A 23 Haziran 2015 tarihinde ve Sentinel-2B 7 Mart 2017 tarihinde fırlatılmıştır. İki uydu ekvator da 5 günlük bir tekrar ziyaret süresi sağlamaktadır.

Sentinel-2 uyduları, ekvator da beş gün yüksek bir tekrar ziyareti, yüksek mekansal çözünürlüğe sahip oluşu ve geniş bir görüş alanına sahip olması gibi özellikleriyle benzeri görülmemiş bir kombinasyon sunar [29]. Sentinel-2 uydusunun genel özellikleri Tablo 2.4'te, spektral özellikleri Tablo 2.5'te gösterilmiştir.

Bu çalışmada tarımsal yaz ürünlerinin sınıflandırması amaçlandığı için Nisan-Kasım tarihleri arasında her aydan bir görüntü olacak şekilde 8 adet uydu görüntüsü seçilmiştir. Uydu görüntüleri seçilirken tamamen bulutsuz görüntülerin seçilmesine özen gösterilmiştir. Seçilen tarihler Tablo 2.2'de gösterilmiştir.

Tablo 2.4. Sentinel-2 uydusunun genel özellikleri.

Görev Özellikleri	Veriler
Görevin Ömrü	15 yıl
Uydu Sayısı	2
Yörünge	786 km
Coğrafi Çekim Alanı	-54 ile +84 enlemleri arasında sistematik olarak çalışmaktadır.
Zamansal Çözünürlük	< 5 gün
Konumsal Çözünürlük	10, 20 ve 60 m
Spektral Bantlar	13 (VIS-NIR-SWIR)

Tablo 2.5. Sentinel-2 uydusunun spektral özellikleri.

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 - Bitki Sıcak Nokta-1	698-713	20
Bant 6 - Bitki Sıcak Nokta	733-748	20
Bant 7 - Bitki Sıcak Nokta	785-900	20
Bant 8 - Yakın Kızılötesi	785-900	10
Bant 8A - Bitki Sıcak Nokta	855-875	20
Bant 9 – Su Buharı	930-950	60
Bant 10 - Kısa Dalga Kızılötesi (Cirrus)	1 365-1385	60
Bant 11 - Kısa Dalga Kızılötesi	1565-1655	20
Bant 12 - Kısa Dalga Kızılötesi	2100-2280	20

## 2.3. Makine Öğrenme Algoritmaları


### 2.3.1. Karar Ağacı

Karar ağacı (KA), tümevarımsal öğrenme algoritmalarından biridir. Bu algoritma eğitim verilerini / örneklerini kullanarak sınıflandırma ağacı oluşturur. KA'nın çalışma prensibi "böl ve yönet" stratejisine dayanır [1]. Bu algoritma doğası gereği parametrik olmayan bir dağılımdır, dolayısıyla verilerin dağılımından bağımsızdır. Bu nedenle sınıflandırma işlemine sınıflandırılmamış veriyi dahil etmek için uygundur. Böylelikle sınıf ayrışmasında iyileşme sağlanabilir. Anlamsız Sınıflama problemlerini ikiden fazla sınıfla destekler ve regresyon problemlerini ele almak için modifiye edilebilir [45] [46].

KA, her seviyede bir testin olduğu hiyerarşik bir yapıyı takip eder. İki sonuçtan birine sahip olabilecek bir veya daha fazla özellik değerine uygulanır. Bir nesneyi sınıflandırmak için, ağacın kökünden başlar, testi değerlendirir ve dalı sonuca uygun olarak alır. Süreç, bir yaprak kalana kadar devam eder. Her eğitim örneği doğru şekilde sınıflandırılincaya kadar ağaç genişletilebilir.

Karar ağacı yaklaşımı, arazi örtüsünüsınıflandırma problemleri için önemli avantajlara sahiptir, çünkü özellikler ile sınıflar arasındaki doğrusal olmayan ilişkilerin üstesinden gelebilme yeteneğinden dolayı sınıflandırma doğruluğunu büyük ölçüde geliştirir [47]. Karar ağacı sınıflandırma tekniğinin en büyük dezavantajı, öznelik uzayı ve eğitim alanları değiştiğinde kararsız olmasıdır. Şekil 2.19'da örnek bir karar ağacı modeli gösterilmiştir.





Şekil 2.19. Örnek karar ağacı yapısı [48].

Bu çalışmada karar ağacı sınıflandırmasını gerçekleştirmek için R programında bulunan Rweka kütüphanesinde yer alan J48 algoritması kullanılmıştır. J48, Ross Quinlan tarafından geliştirilen karar ağacı oluşturmak için kullanılan bir algoritmadır [49]. J48, bir dizi eğitim verisinden karar ağaçlarını bilgi entropisi kavramını kullanarak oluşturur. Bilgi kazanç oranı bu algortmada bölme kriteri olarak kullanılır. Bölünecek örneklerin sayısı belirli bir eşğin altında olduğunda bölünme durur [50]. Ağacın her bir düğümünde, J48, bir dizi veya bir diğeriyle zenginleştirilmiş alt kümelere örnek kümesini en etkili şekilde ayıran verilerin bir özneliğini seçer. Verileri birbirinden ayırmak için ölçek olarak entropi farkını kullanır. En yüksek normalleştirilmiş bilgi kazancı olan özellik, karar vermek için seçilir.

Bu çalışmada Quinlann (1993) tarafından geliştirilen C.4.5 algoritması kullanılmıştır [51]. Bu algortmada Entropi ve Bilgi Kazancı olmak üzere iki önemli parametre

$$Entropi(M) = \sum_{i=1}^J -p_i * \log p_i \quad (1)$$

bulunmaktadır (Eşitlik 1 ve 2). C4.5 algoritması R programında J48 algoritması adı altında bulunmaktadır.

$$Bilgi Kazancı(S) = Entropi(M) - \sum_{i=1}^K \frac{|M_i|}{|M|} * Entropi(M_i) \quad (2)$$

Eşitlik 1 ve 2 'de M düğümdeki örnek kümeyi,  $p_i...p_j$  örneklenen her bir sınıfı ve S,  $M_1...M_i$  örnek veri kümesini alt kümelere bölen en yüksek bilgi kazancını ifade etmektedir.

J48 algoritması daha sonra küçük alt listelerde yinelenir. Her düğüm kararı için kullanılan eşikler, minimum entropi veya minimum hata miktarı kullanılarak seçilir. Bu algorithmada uygulanan budama yöntemi, Hata Tabanlı Budama (HTB) [50] [52]'dir. Eğitim setindeki bilgiler ağaçları oluşturmak ve sadeleştirmek için kullanılır. HTB'nin uzmanlık alanı, bir dalın ana kökün yerine aşılmasını ve düğümlerin budanmasıyla birlikte karar ağacını basitleştirmesidir [50]. J48 algoritması üzerine inşa edilen bu sınıflandırıcıya J48 KAS denir. Öznitelik ayırma kriteri olarak bilgi kazanım oranını içerir [53].

### 2.3.2. Rastgele Orman

Rasgele orman (RO), temel sınıf olarak karar ağacını kullanan en tanınmış topluluk algoritmalarından biridir. Rastgele bir orman yapısı, üç ana aşamadan oluşan bir topluluk inşa etme sürecine uygundur.

1. Topluluk çeşitliliğini kazanmak - RO algoritmasında örnekleme yöntemi kullanılarak bir eğitim veri seti oluşturulur.

2. Temel klasörler oluşturma - RO, temel klasörler oluşturmak için önceki adımda oluşturulan farklı eğitim setlerinde rastgele bir ağaç olan aynı indükleyiciyi kullanır. Ayrıntılı olarak, her düğümde, küçük bir girdi öznitelik grubu rastgele seçilir. Grubun boyutu kullanıcılar tarafından önceden belirlenebilir.

3. Temel sınıfları birleştirmek - RO algoritmasında çoğunluk oylama yöntemi kullanılmaktadır.

Rastgele Orman'ın geliştiricisi olan Breiman (2001) [54], onu şu şekilde tanımlamıştır. Rastgele bir orman inşa etmek, ağaç topluluğu yetiştirmek ve ağaçların en popüler sınıf için oy kullanmasına izin vermek için rastgele vektörler üretme görevini içerir.

Bir ormanın hata oranı, bireysel karar ağacı sınıflarının gücüne ve ağaçlar arasındaki korelasyona bağlıdır [54]. Tek tek ağaçların gücünü arttırmak ormanın doğruluğunu artırırken, korelasyon arttıkça hata oranı artar.

Bu çalışmada RO algoritmasını uygulamak için R programlama dilinde “randomForest” kütüphanesinde bulunan “rf” algoritması kullanılmıştır.


RO'da doğruluğu en çok etkileyen iki parametre “*n*tree” (ağaç sayısı) ve “*m*try” (rastgele özellik seçimi) parametreleridir. Ağaç sayısı (*n*tree) kullanıcı tarafından belirlenebilir ve sayı artırıldıkça karar ormanı da büyür. Mtry parametresi de aynı şekilde kullanıcı tarafından belirlenebilir fakat genel olarak değişken sayısının toplamının karekökü alınarak işlem gerçekleştirilir.

Orman inşa sürecinde, her bir ağacın yerini alacak örnekleme ile eğitim veri seti oluşturulduğunda, verilerin yaklaşık 1/3'ü dışarıda bırakılır ve o ağacın yapımında kullanılmaz. Test için kullanılan bu veri setine genelleştirilmiş hata (OOB-Out of Bag) denir. OOB verisi doğruluğu belirlemek için kullanılır. Eğitim veri setinin geriye kalan 2/3'ü karar ağacını oluşturmak için kullanılır.

RO'nun en önemli özelliklerinden bir diğeri ise önemli deęişkenlerin ölçülebilir olmasıdır. Bu sayede sınıflandırma doğruluğunu en çok etkileyen özellikler belirlenebilir. Bu işlem, OOB verileri kullanılarak yapılır.

### 2.3.3. Destek Vektör Makineleri

Destek vektör makineleri (DVM) denetlenen parametrik olmayan istatistiksel bir öğrenme tekniğidir. Orijinal formülasyonunda yöntem, bir dizi etiketli veri örneği ile sunulur ve DVM eğitim algoritması, veri setini, eğitim örnekleriyle tutarlı bir şekilde, önceden belirlenmiş bir sayıda sınıflara ayıran bir hiper-yatay bulmayı amaçlar [55]. Optimal ayırma hiperdüzlemi terimi, eğitim aşamasında elde edilen yanlış sınıflamaları en aza indiren karar sınırını belirtmek için kullanılır. Öğrenme, eğitimi ayırmak için optimal karar sınırına sahip bir sınıflandırıcı bulmak için yinelemeli süreci ifade eder.



Şekil 2.20. Doğrusal destek vektör makineleri örneği [56].

En basit haliyle, DVM'ler doğrusal ikili (lineer binary) sınıflandırıcılardır. Uzaktan algılama sınıflandırmasında etiketlenecek bir veri örneğinin bir örneği, normalde çoklu spektral veya hiperspektral görüntüden türetilen bireysel pikseldir. Böyle bir piksel bir model vektörü olarak temsil edilir ve her bir görüntü bantı için bir dizi sayısal ölçümden oluşur. Özellik vektörünün elemanları, doku gibi piksel uzaysal ilişkilerine dayanan başka

ayırt edici deęişken ölçümleri de içerebilir. Şekil 2.20, iki boyutlu bir giriş alanında iki sınıf bir ayrılabilir sınıflandırma probleminin basit bir senaryosunu göstermektedir. SVM'lerin önemli bir genelleme yönü, sık sık kullanılan tüm eğitim örneklerinin, ayırma hiperdüzleminin açıklamasında ve özelliklerinde kullanılmamasıdır. Kenar boşluğunda yer alan noktaların alt kümesi destek vektörleri olarak adlandırılır.

Doğrusal bir DVM'nin uygulanması, özellik verilerinin girdi uzayda doğrusal olarak ayrılabilir olduğunu varsayar. Uygulamada, farklı sınıf kümelerinin veri noktaları birbiriyle çakışıyor ise bu lineer ayrılabilirliği zorlaştırır çünkü temel doğrusal karar sınırları kalıpları yüksek doğrulukla sınıflandırmak için yeterli değildir. Yumuşak marj yöntemi ve kernel numarası gibi teknikler ve çözümler, DVM optimizasyon ve haritalamada ek deęişkenler ekleyerek sınıfların ayrılama problemi çözmek için kullanılır [57].

DVM'ler genellikle geleneksel yöntemlerden daha yüksek sınıflandırma doğruluğu üretmektedir [58]. DVM'lere fayda sağlayan temel prensip, yapısal risk minimizasyonu olarak bilinen süreci izleyen öğrenme sürecidir. Bu şema altında, DVM'ler, verilerin olasılık dağılımı üzerinde önceden yapılmış varsayımlar olmaksızın, görünmeyen veriler üzerinde sınıflandırma hatasını en aza indirir.

DVM algoritmasından elde edilen faydaların yanı sıra çeşitli dezavantajları da bulunmaktadır. DVM'lerin uygulanabilirliği ile ilgili en büyük zorluk, kernellerin seçimidir. Birçok seçenek mevcut olsa da, kernel işlevlerinin bazıları uzaktan algılama uygulamaları için en uygun DVM yapılandırmasını sağlayamayabilir. Ampirik bulgular, uydu görüntü verilerinin DVM-tabanlı sınıflandırmasına uygulanan radyal temel fonksiyonu ve polinom çekirdeęi gibi kernellerin farklı sonuçlar verdiğini göstermektedir [59].

DVM algoritması, az sayıda eğitim örneęi ile sınıfları kolayca ayırabilen hiperspektral görüntü analizi için ilginç bir özellięe sahiptir [57]. DVM, iki sınıf arasındaki maksimum ayrılma marjını sağlayan, optimal hipotezi seçer [55]. Bu çalışmada, sık kullanılan DVM'lerden biri olan birden fazla sınıfı birbirinden ayırabilen bire karşı bir (one-against-one) (1A1) algoritması kullanılmıştır. Yöntem, her biri k adet sınıftan seçilen iki sınıftan


veri üzerinde eğitilen  $k(k - 1) / 2$  hiper düzlemi oluşturur. Bir  $k$  sınıfı problem için, 1A1 algoritması, tüm sınıfları birbirinden ayıran hiper düzlemler oluşturur, yani bir sınıfı diğerlerinden ayırmak için  $(k - 1)$  hiper düzlemler oluşturulur. Çalışmada DVM yöntemi R programlama dilinin e1071 kütüphanesinde bulunan svm fonksiyonu kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

#### **2.4. Görüntülerin İşlenmesi ve Sınıflandırılması**

Sınıflandırma işlemini gerçekleştirmek için öncelikle sınıflandırılacak tarım ürünleri belirlenmiştir. Eğitim ve test verileri ise çiftçi kayıt sisteminden gelen veriler ve Hacettepe Üniversitesi Geomatik Mühendisliği Anabilim Dalı'nda daha önce yapılmış bir çalışmadan alınan Arazi Gerçeği Verileri birlikte değerlendirilerek oluşturulmuştur [30].

Görüntülerin bant seçimlerinde daha önce yapılan çalışmalardan yola çıkılarak bant seçimleri gerçekleştirilmiştir. Sentinel-2 için 10 m konumsal çözünürlüğe sahip kırmızı, yeşil, mavi ve yakın kızıl ötesi bantları kullanılmıştır. Diğer bantların tarımsal ürünlerin tespitinde konumsal çözünürlüklerinin düşük olması sebebiyle (20 m ve 60 m) sınıflandırma doğruluğunu azaltabildiği daha önce yapılan çalışmalarda görülmüştür [28] [27]. Bu nedenle bu çalışmada Sentinel-2'nin 10 m konumsal çözünürlüğe sahip bantları dışındaki bantları kullanılmamıştır. Sentinel-1 SAR görüntüsünde seçilecek bantlarda ise Sentinel-1A ve 1B uydularından çift kutuplu (VV, VH) C-bant görüntüleri kullanılmıştır. Kullanılan SAR görüntüleri IW modunda ve Level 1 GRD formatındadır [26].

Sentinel-1 görüntüleri öncelikle ESA tarafından ücretsiz sağlanan SNAP (The Sentinel Application Platform) yazılımında ön işleme tabi tutulmuştur. Sonra, Sentinel-1 görüntüleri 10 m'lik konumsal çözünürlüğe sahip olan Sentinel-2 görüntüleriyle birlikte kullanılacağı için yeniden örnekleme işlemi yapılarak 10 m konumsal çözünürlüklü yeni görüntüler oluşturulmuştur. Çalışmada kullanılan işlem adımları Şekil 2.21' de gösterilmektedir.



Şekil 2.21. Çalışmada Kullanılan Akış Diagramı.

Görüntüler analizlere hazır hale getirildikten sonra, kullanılan tüm Sentinel-2 görüntüleri için normalize edilmiş bitki indeksi farkı (NDVI) değerleri hesaplanmıştır. Literatürde yaygın olarak kullanılan NDVI yöntemi, Eşitlik 3’de açıklandığı gibi bitkilerin yansıttığı yakın kızılötesi ve görünür bantlar arasındaki farka dayanır [60].

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

Eşitlikte 3’de NDVI normalize edilmiş bitki indeksi farkını, NIR Sentinel-2 Yakın Kızılötesi Bantını, Kırmızı ise Sentinel-2 kırmızı bantını ifade etmektedir.

Görüntülerin segmentasyon işlemi, bir nesne tabanlı görüntü işleme yazılımı olan e-Cognition programı ile yapılmıştır. Segmentasyon işlemi tamamlandıktan sonra oluşan her segment için yine e-Cognition programında her bir segment için özellikler hesaplanmıştır. Sınıflandırma işleminde kullanılmak üzere 2 adet Sentinel-1’e ait VV ve VH orijinal bantlarının yanı sıra, Sentinel-2’ye ait kırmızı,yeşil,mavi ve yakın kızıl ötesi bantları ve NDVI değerleri hesaplanmıştır. Böylelikle toplamda 48 orijinal bantın ortalama (mean) (Eşitlik 4) değerleriyle birlikte ((6 Bant (VH,VV,K,Y,M,YKÖ) x 8 Görüntü ), 8 adet NDVI bantının da ortalama değerleri hesaplanarak toplam 56 bant oluşturulmuştur. Bununla birlikte çalışmada elde edilen segmentlerin doku özellikleri de çalışmaya dahil edilmiştir. Yukarıda bahsedilen 56 bantın her biri için standart sapma (standart deviation) (Eşitlik 5), farklılık (dissimilarity) (Eşitlik 6), entropi (entropy) (Eşitlik 7), homojenlik (homogeneity) (Eşitlik 8), açısal ikinci moment (angular second moment) (Eşitlik 9), korelasyon (correlation) (Eşitlik 10) ve kontrast (contrast) (Eşitlik 11) değerleri de hesaplanarak toplamda 448 bant (8 özellik x 56 bant) hesaplanmıştır. Araştırmada tüm bu bantların çeşitli kombinasyonları kullanılarak sınıflandırma sonucuna etki dereceleri incelenmiştir.

$$Ortalama = \frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} C_k(x,y) \quad (2)$$



$$\text{Standart Sapma} = \sqrt{\frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} \left( C_k(x,y) - \frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} C_k(x,y) \right)^2} \quad (3)$$

$$\text{GLCM Farklılık} = \sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (4)$$

$$\text{GLCM Entropi} = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (5)$$

$$\text{GLCM Homojenlik} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (6)$$

$$\text{GLCM Açısıl 2. Moment} = \sum_{i,j=0}^{N-1} (P_{i,j})^2 \quad (7)$$

$$\text{GLCM Korelasyon} = \sum_{i,j=0}^{N-1} P_{i,j} \frac{(i - \mu)(j - \mu)}{\sigma^2} \quad (8)$$

$$\text{GLCM Kontrast} = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2 \quad (11)$$

Eşitlik 4–10’da  $\#P_{Seg}$  tek bir segmentteki toplam piksel sayısını,  $P_{Seg}$  tek bir segmenti,  $C_k(x,y)$ ,  $(x,y)$  görüntü katmanının piksel koordinatlarındaki değerini,  $i, j$  eşdizimlilik (co-occurrence) matrisinde satır ve sütun numaralarını,  $P_{i,j}$  normalize edilmiş satır ve sütun numaralarını (Eşitlik 12),  $\mu$  tüm piksellerin yoğunluğunun ortalamasını (Eşitlik 13),  $\sigma^2$  tüm piksellerin yoğunluğunun varyansını ifade etmektedir (Eşitlik 14).

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (12)$$

$$\mu = \sum_{i,j=0}^{N-1} iP_{i,j} \quad (13)$$

$$\sigma^2 = \sum_{i,j=0}^{N-1} iP_{i,j} (i - \mu)^2 \quad (14)$$

Doku (texture), spektral verilere ek olarak yeni bilgiler sağlar. Fakat, bu bilgi karmaşık hesaplamalar gerektirir. İşlem yükünün getirdiği dezavantajlara sahip olmasına rağmen, heterojen sınıfları ayırt etme gücünü artırabilir. Bu çalışmada, dokunun tarımsal ürünlerin sınıflandırması üzerindeki etkisini araştırmak için en yaygın kullanılan 6 doku özelliği çalışmaya dahil edilmiştir.

Kullanılacak özellikler hesaplandıktan sonra, daha önce belirlenen eğitim ve test verilerine değer aktarımı yapabilmek için öncelikle e-Cognition yazılımında elde edilen segmentler shape dosya formatında dışarıya aktarılmıştır. Aktarılan segment değerleri vektör formatındadır. Elde edilen özelliklerin eğitim ve test verilerine aktarılması için ArcGIS programı kullanılmıştır.

Elde edilen veriler R Studio programında yazılmış olan 3 farklı makine algoritmasında kullanılabilir hale getirilmesi için csv dosya formatına dönüştürülmüştür. Csv formatında kaydedilen veriler R programında okutulmuş ve sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmada 8 farklı veri kombinasyonu kullanılmıştır. Bu kombinasyonlar KA, RO, DVM algoritmalarında kullanılarak sınıflandırma işlemin uygulanmıştır. Ortaya çıkan sınıflandırma sonuçlarından elde edilen doğruluk analizleri değerlendirilerek çalışma sonuçlandırılmıştır.

Tablo 2.6. Çalışmada kullanılan özellik (bant) kombinasyonları.

	Özellik(bant) kombinasyonu	Açıklama
1	$Ort_{S1}$	S1 Orijinal Bantlar
2	$Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$	S1 Orijinal Bantlar +S1 Standart Sapma + S1 Doku
3	$Ort_{S2}$	S2 Orijinal Bantlar
4	$Ort_{NDVI}$	Yalnız NDVI Bantları
5	$Ort_{S2}, Ort_{NDVI}$	S2 Orijinal Bantlar + NDVI
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2}, Hmj_{S2}, Kont_{S2}, Frk_{S2}, Ent_{S2}, A2Mo_{S2}, Kor_{S2}$	S2 Orijinal Bantlar+S2 Standart Sapma+S2 Doku
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	S1 ve S2 Orijinal Bantlar+ NDVI
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Kont_{S1}, Kont_{S2}, Frk_{S1}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1}, A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	S1 ve S2 Orijinal Bantlar+ NDVI+S1 ve S2 Standart Sapma+S1 ve S2 Doku

Tablo 2.6 ve Tablo 3.1, 3.3, 3.4, 3.5, 3.6’da kullanılan özellik kombinasyonlarının kısaltmaları şu şekildedir:

### Özellik<sub>Band</sub>

Özellik : Ort (Ortalama), Std (Standart Sapma), Ent (Entropi), Hmj (Homojenlik), Kont (Kontrast), Frk (Farklılık), A2Mo (Açısal İkinci Moment), Kor (Korelasyon)

S1 : Sentinel-1 SAR görüntülerine ait orijinal bantlar (VV, VH)

S2: Sentinel-2 optik görüntülerine ait orijinal 10 m konumsal çözünürlüklü (Kırmızı, Yeşil, Mavi, Yakın Kızılötesi)

NDVI: Normalize edilmiş bitki indeksi farkı.

#### 2.4.1. Eğitim ve Test Verilerinin Oluşturulması

Eğitim ve Test Verilerinin oluşturulabilmesi için öncelikle çalışma alanındaki tarımsal ürünleri tespit edebilmek için arazi çalışmaları yapmak gerekmektedir. Bu çalışmada, Hacettepe Üniversitesi Geomatik Mühendisliği Anabilim Dalı'nda daha önce aynı alanda yapılan başka bir çalışmadan alınan Arazi Gerçeği Verileri kullanılmıştır [30]. Yapılan çalışmalara ek olarak ÇKS verileri de temin edilmiş ve arazi sınıfları belirlenmiştir. Elde edilen sonuçlara göre çalışma alanında yoğun olarak bulunan tarımsal yaz ürünleri biber, buğday, mısır, üzüm, patlıcan, domates, pamuk, yonca ve zeytin olarak sıralanabilir.

Ayrıca çalışma alanında tespit edilen bazı tarım parsellerinde birden fazla ürün hasat edildiği tespit edilmiştir. Bu parsellerde bir yıl içerisinde önce buğday daha sonra mısır hasatı yapılmıştır. Bu alanların sınıfı "Mısır2" olarak belirlenilerek sınıflandırmaya dahil edilmiştir.

Çalışmada, segmentasyon işlemi sonrasında ortaya çıkan segmentlerdeki özellikleri eğitim ve test verisine aktarabilmek için poligon veri formatındaki parseller nokta veri formatına dönüştürülmüştür. Bu işlem yapılırken öncelikle kullanılan her bir parselin ağırlık merkezine bir nokta atılmıştır. Segmentasyon işlemi sonrasında ise bazı büyük tarım parsellerin içerisine birden fazla segment düştüğü gözlemlenmiştir. Bu segmentlere ait özelliklerden de eğitim ve test verisi olarak yararlanabilmek için büyük parsellerin içerisine ekstra noktalar atılmıştır. Sonuç olarak 1660 adet yer gerçeği verisi elde edilmiştir. Bu konu segmentler başlığının altında daha detaylı anlatılmıştır. Çalışmada kullanılan eğitim ve test verileri dağılımı Tablo 2.7'de gösterilmektedir. Çalışma alanının bir kısmında bulunan yer gerçeği verileri Şekiller 2.22, 2.23, 2.24 ve 2.25'de gösterilmiştir.

Tablo 2.7. Çalışma alanında kullanılan eğitim ve test verileri.

	<b>Eğitim Verisi Sayısı</b>	<b>Test Verisi Sayısı</b>
Biber	18	18
Buğday	94	94
Domates	47	47
Mısır	123	123
Mısır2	92	92
Pamuk	49	49
Patlıcan	12	12
Üzüm	286	286
Yonca	15	15
Zeytin	94	94
<b>Toplam</b>	<b>830</b>	<b>830</b>
<b>Genel Toplam</b>	<b>1660</b>	




Şekil 2.22. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, YKÖ, K, Y bant kombinasyonu).



Şekil 2.23. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, NDVI bantı).



Şekil 2.24. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, Sentinel-1 VV Bantı).



Şekil 2.25. Çalışma alanının bir kısmında yer gerçekleri verilerinin dağılımı (Temmuz ayı görüntüsü, Sentinel-1 VH Bantı).

#### 2.4.2. Sentinel-1 SAR Uydu Görüntülerine Ön-İşlemelerin Uygulanması

Sınıflandırma işleminde kullanabilmek için Sentinel-1 uydu görüntülerine gerekli bazı ön işlemlerin uygulanması gerekmektedir. Görüntüler indirildikten sonra, Sentinel-1 görüntülerine radyometrik kalibrasyon, speckle filtresi (Lee Sigma Filtresi 5×5) ve arazi düzeltmesi ön işlemleri uygulanmıştır (Şekil 2.21). Arazi düzeltmesi için 30 m sayısal yükseklik modeline sahip Range Doppler Arazi Düzeltme yöntemi kullanılmıştır. Sonra, Sentinel-2 görüntüleri ile aynı konumsal çözünürlükte (10 m) olması için Sentinel-1 görüntülerinin 10 m'ye yeniden örnekleme yapılmıştır. Ön işlemler için, ESA tarafından ücretsiz olarak sunulan SNAP yazılımında yer alan Sentinel-1 araç kutusu kullanılmıştır. Bu işlemler sonrasında dijital sayı değerleri Eşitlik 15 ile, desibel ölçeğinde (dB) backscattering (geri saçılma) değerlerine dönüştürülmüştür.

$$\beta_{ab}^{\circ} = 10 * \log_{10}(\beta^{\circ}) \quad (15)$$

Eşitlik 15'te  $\beta^\circ$  görüntünün dijital sayı değerlerini ve  $\beta_{ab}^\circ$ , dB cinsinden geri saçılmış (backscatter) değeri göstermektedir.

Son olarak Sentinel-1 görüntüleri çalışmada kullanılan WGS1984 UTM Zone 35N projeksiyon sisteminde tanımlanmıştır.

### 2.4.3. Görüntü Segmentasyonu

Nesne tabanlı sınıflandırma fikri, görüntünün piksel tabanlı sınıflandırma yöntemlerinde bulunmayan karakteristik dokusal bilgilere sahip olması gerçeğinden ortaya çıkmıştır [61]. Nesne tabanlı sınıflandırma yöntemleri, nesnelere pikseller yerine bir sınıflandırma birimi olarak kullanır [62] [63]. Nesneye dayalı yöntemler, sınıflandırma yapmak için spektral bilginin yanı sıra diğer nesnelere topolojik ilişki hakkındaki şekil, doku, alan ve içerik bilgilerini kullanır [64].

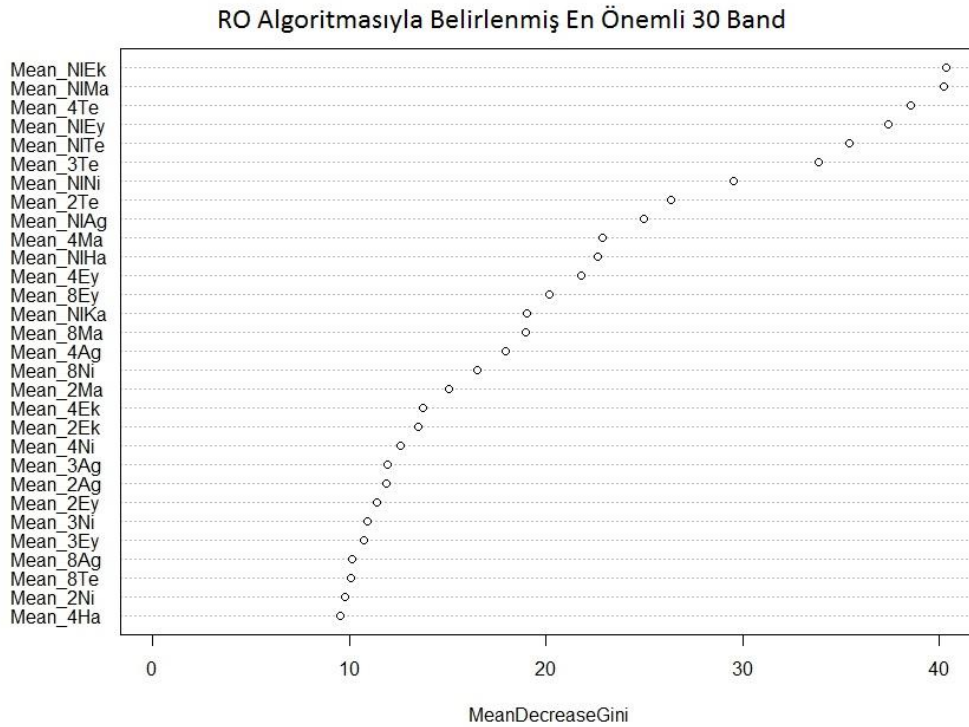
Bu çalışmada görüntü segmentasyonu için çoklu çözünürlük segmentasyon algoritması kullanılmış ve segmentasyon işlemi e-Cognition yazılımı ortamında yapılmıştır. Burada her piksel bir nesne olarak atanır ve daha sonra tekrarlamalı adımlarla birleştirilir [65]. Bu birleşme kriteri, boyutlarına göre tartılan nesnelere ortalama heterojenliğini en aza indirir [66] [67]. Çoklu çözünürlük segmentasyonunda ölçek, şekil ve kompaktlık olmak üzere üç önemli parametre bulunmaktadır. Başarılı bir segmentasyon elde edebilmek için en uygun parametre değerlerini seçmek gereklidir. Optimizasyon işlemi gerçekleştirilmek için ölçek parametresi gereklidir ve oluşturulan nesnelere boyutunu belirler.

Bu çalışmada optimum ölçek parametresi değerini belirleyebilmek için e-Cognition yazılımına ek bir araç olarak eklenebilen Tahmini Ölçek Parametresi-2 (Estimation Scale Parameter–ESP-2) algoritması kullanılmıştır. ESP-2 aracı L.Dragut (2014) tarafından geliştirilmiştir [68]. ESP-2 optimum ölçek parametresini belirlemede iyi bir araç olmasının yanında dezavantajları da vardır. Bu duruma örnek olarak ESP-2 aracının en fazla 30 katmanla çalışabildiği söylenebilir [68]. Bu çalışmada toplam 448 bant kullanılmıştır fakat tüm bantları ESP-2 algoritmasını kullanarak segmentasyon işlemi



gerçekleştirmek mümkün olmadığından konumsal çözünürlüğü en yüksek olan (10 m) Sentinel-2 ye ait orijinal bantlardan kırmızı, yeşil, mavi, yakın kızıl ötesi bantları ve NDVI değerleri arasından en önemli 30 bant seçilerek segmentasyon işlemi yapılmıştır.

En önemli 30 bantın tespiti için daha önce yapılmış olan bir başka çalışmada önerilen parametre değerleri kullanılmıştır [69]. Deneme segmentlerini oluşturmak amacıyla kullanılan segment parametreleri Peña-Barragán vd. (2011) tarafından yapılan çalışmadan uyarlanmıştır [69]. Bu çalışmada ölçek parametresi için 100 , şekil parametresi için 0,1 ve kompaktlık parametresi için 0,7 değerleri kullanılmıştır. Sonra, Sentinel-2 görüntüleri ve oluşturulan NDVI bantları R programı ortamında segment bazlı sınıflandırma işlemine tabii tutulmuştur. RO algoritmasının en önemli çıktılarından birisi önemli değişkenleri tespit etme olanağı sunan en önemli değişkenler tablosudur (Şekil 2.26). Bahsedilen çıktıdan alınan bilgiye göre en önemli bantlar belirlenmiştir. Belirlenen bantlar ve görüntü tarihleri Tablo 2.2’ de gösterilmektedir.



Şekil 2.26. Çalışmada kullanılan bantların önem dereceleri.


Şekil 2.26’da Mean ortalama değerleri 2, 3, 4 ve 8 Sentinel-2’nin sırasıyla mavi, yeşil ve kırmızı bantlarını; NI: NDVI bantını; Ni, Ma, Ha, Te, Ag, Ey, Ek ve Ka sırasıyla Nisan, Mayıs, Haziran, Temmuz, Eylül, Ekim ve Kasım aylarını ifade etmektedir.

Tablo 2.8’de görüldüğü gibi çalışmada kullanılan 8 tarihe ait NDVI bantlarının tümü en önemli 30 bantın içerisinde yer almaktadır. Bu bakımdan NDVI bantlarının tarım parsellerinin sınıflandırılmasında en önemli bantlar arasında olduğu şimdiden söylenebilir. Bunun yanı sıra diğer önemli bantlar olarak sırasıyla Kırmızı banta ait 7 görüntü, yakın kızılötesi banta ait 5 görüntü ve mavi ve yeşil bantlara ait 4’er görüntü kullanılmıştır.

Tablo 2.8. ESP-2 Algoritmasında Kullanılan Bantlar.

Uydu Adı	Bant Adı	Tarih
Sentinel-2	Mavi	Temmuz, Mayıs, Eylül, Nisan, Haziran, Ekim
	Yeşil	Temmuz, Ağustos, Nisan, Eylül
	Kırmızı	Temmuz, Mayıs, Eylül, Ağustos, Ekim, Nisan, Haziran
	Yakın Kızılötesi	Eylül, Mayıs, Nisan, Ağustos, Temmuz
	NDVI	Ekim, Mayıs, Eylül, Temmuz, Nisan, Ağustos, Haziran, Kasım


ESP-2 aracı sonuç çıktısı olarak 3 hiyerarşik ölçek verisi vermektedir. Bu çalışmada bunlardan en büyük ölçekli sonuç çıktısı olan 94 değeri kullanılmıştır. ESP-2 aracının sonuç çıktılarında bir değeri ise local varyans grafiğidir. Bu grafik, local varyans (LV) ve değişim oranını (ROC = local varyanstaki değişim oranı, ilgi düzeyi ölçeği ile önceki seviye arasındaki değişim oranı) ölçek seviyelerine göre çizer. Oluşturulan grafik, LV / ROC oranındaki ani değişim ölçek parametresini belirlemeye yardımcı olur. Şekil 2.27’de bu çalışmada elde edilen LV/ROC değişimine ait grafik gösterilmiştir.



Şekil 2.27. Tahmini ölçek parametresi LV grafiği.

Ölçek parametresi belirlendikten sonra şekil ve kompaktlık parametrelerini belirlemek için önceki çalışmalar incelenmiştir. İncelemeler sonucunda Peña-Barragán vd. (2011) 'ın çalışmasında kullanılan şekil ve kompaktlık parametreleri değerleri bu çalışmaya uyarlanmıştır [70]. Sonuç olarak bu çalışmada ölçek=94, şekil=0.1 ve kompaktlık=0.7 parametre değerleri ile segmentasyon gerçekleştirilmiştir. Segmentasyon işlemi sonucunda çalışma alanına ait toplam 14763 segment oluşmuştur.

Poligon formatındaki arazi gerçeği verileri, oluşturulan segment sınırları ile çakıştırıldığında birden çok segmentin sınırlarıyla kesişebilmektedir. Bu duruma örnek Şekil 2.28'de gösterilmiştir. Ayrıca Şekil 2.29, Şekil 2.30 ve Şekil 2.31'de çalışmanın seçili bir kısmına ait segmentler gösterilmiştir.




Şekil 2.28. Çalışma alanının seçili bir kısmına ait, arazi gerçeği verileriyle segmentlerin kesişimi.



Şekil 2.29. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Gerçek Renk).



Şekil 2.30. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Sentinel-1 VV).




Şekil 2.31. Çalışma alanının bir bölümüne ait segmentlerin gösterimi (Sentinel-1 VH).

Segmentasyon işleminin tamamlanmasından sonra elde edilen her segment için özellik değerleri e-Cognition programında hesaplanmıştır. Yukarıda da bahsedildiği gibi bu çalışmada ortalama (mean) (Eşitlik 4), standart sapma (standart deviation) (Eşitlik 5), farklılık (dissimilarity) (Eşitlik 6), entropi (entropy) (Eşitlik 7), homojenlik (homogeneity) (Eşitlik 8), açısal ikinci moment (angular second moment) (Eşitlik 9), korelasyon (correlation) (Eşitlik 10) ve kontrast (contrast) (Eşitlik 11) özellik değerleri kullanılmıştır. Hesaplanan özellik değerleri e-Cognition programında shape dosya formatına aktarılmıştır.


#### **2.4.4. Eğitim ve Test Alanlarına Özellik Değerlerinin Aktarılması**

Çalışmada kullanılan arazi gerçeği verileri poligon formatındadır. Poligon formatındaki verilere özellik değeri aktarımında parsellerin birden fazla segmentle çakışıp çakışmama durumu dikkate alınmıştır. Bu duruma örnek Şekil 2.32’de gösterilmiştir. Bu nedenle öncelikle tüm arazi gerçeği verileri nokta formatına dönüştürülmüştür. Nokta formatına dönüştürülürken arazi gerçeği verilerinin orta noktalarına bir nokta atılmıştır. Şekil 2.33’de çalışma alanının bir kısmına ait arazi gerçeği parsellerinin orta noktalarına atılan nokta verisi görülmektedir. Sonra, yapılan incelemeler sonucunda büyük parsellerin içerisine düşen segmentlerin özellik bilgilerinden de yararlanabileceği görülmüştür. Ekili tarım ürününü temsil etmeyen segmentlerin de eğitim ve test verilerine dahil edilmesini önlemek için ArcGIS ortamında 100 dekardan büyük parseller seçilmiş ve 30 m içeriye doğru tampon (*buffer*) oluşturularak poligon sınırları küçültülmüştür (Şekil 2.34). Böylece tarım parselini temsil etmeyen segmentlere nokta atılması önlemiştir. Daha sonra, her 100 dekara 1 nokta düşecek şekilde yeniden noktalar oluşturularak eğitim ve test verileri elde edilmiştir ( Şekil 2.35).


Elde edilen noktalara özellik bilgilerini aktarmak için ArcGIS programında bulunan *spatial join* fonksiyonu kullanılmıştır. Böylece eğitim ve test verilerine ait tüm özellik değerleri elde edilen noktalara aktarılmıştır.




Şekil 2.32. Çalışma alanından segmentler ile arazi gerçeği verilerinin çakışmasına bir örnek.



Şekil 2.33. Çalışma alanının bir bölümüne ait arazi gerçeği verilerinin orta noktaları.



Şekil 2.34. Çalışma alanının bir bölümüne ait 30 m genişliğinde tampon oluşturulmuş büyük parsellerdeki arazi gerçeği verileri.



Şekil 2.35. Büyük parsellerde oluşturulan ek noktalara çalışma alanından bir örnek.



#### 2.4.5. Sınıflandırma

Bu çalışmada sınıflandırma işlemi için 3 farklı algoritma ve 8 farklı veri seti kullanılmıştır. Sınıflandırma işlemi gerçekleştirilmek için R programı kullanılmıştır. R, açık kaynaklı ücretsiz bir programdır. Kullanılan özellik kombinasyonları Tablo 6'da gösterilmiştir. Kullanılan 3 algoritma sırasıyla Karar Ağacı (KA), Rastgele Orman (RO) ve Destek Vektör Makineleri (DVM) dir.

Kullanılan sınıflandırma algoritmalarından ilki olan Karar Ağacı (KA) algoritmasının uygulaması R programının Rweka kütüphanesinde bulunan *J48* algoritmasıyla gerçekleştirilmiştir. Bu algorithmada her düğümde alınan karar için kullanılan eşik değerleri minimum entropi miktarına dayanarak gerçekleştirilir. Bu çalışmada Quinlan (1993) tarafından oluşturulan C4.5 algoritmasında bulunan parametreler kullanılmıştır [51]. KA algoritmasının uygulanmasında kullanılan entropi ve bilgi kazancı parametreleri, "2.2.1 Karar Ağacı" bölümünde açıklanmıştır.

Çalışmada kullanılan bir diğer algoritma olan RO algoritmasının uygulaması da diğer algoritmalar gibi R ortamında gerçekleştirilmiş ve bunun için *randomForest* kütüphanesi kullanılmıştır. *randomForest*, sınıflandırma ve regresyon için Breiman'ın (2011) RO algoritması için geliştirdiği orijinal Fortran kodunu temel alarak uygular. Bu çalışmada Breiman'ın Fortran kodunu temel alarak oluşturduğu RO parametreleri kullanılmıştır [54].

RO algoritmasının doğruluğunu etkileyen iki temel parametre bulunmaktadır. Bunlardan ilki ağaç sayısı (*ntree*) diğeri ise rastgele özellik sayısıdır (*mtry*).

Daha büyük *ntree* daha istikrarlı modeller ve değişken önem tahminleri üretir, ancak daha fazla bellek ve daha uzun çalışma süresi gerektirir.

*Mtry* *randomForest* kütüphanesinde kullanılıyor ise sınıflandırma modelleri için varsayılan, belirleyici değişkenlerinin sayısının kareköküdür (Eşitlik 16). Bu sayı tam sayı olarak aşağıya yuvarlanır.

$$mtry = \sqrt{p} \quad (16)$$

Eşitlik 16'da  $mtry$  rastgele özellik sayısını,  $p$  ise belirleyici değişkenlerin sayısını ifade etmektedir. Burada bahsedilen belirleyici değişken sınıflandırmada kullanılan bant sayısıdır. Çalışmada farklı veri kombinasyonları kullanıldığından bant sayıları her kombinasyonda değişmektedir.

Bu çalışmada Breiman'ın kodu baz alınarak oluşturulan RO algoritmasının parametreleri kullanılmıştır [54]. Bu algoritmaya göre  $nree$ : 500 ve  $mtry$ : belirleyici değişkenlerinin sayısının karekökü (Sınıflandırmada kullanılan bant sayısının karekökü) olarak alınmıştır.

Çalışmada kullanılan sınıflandırma algoritmalarından üçüncüsü DVM algoritmasıdır. Bu algoritma, nesne algılama ve metin kategorizasyonu dahil olmak üzere farklı uygulama alanlarında kullanılmıştır ve genelleme kapasitesi bakımından geleneksel sinir ağı tekniğinden daha iyi performans göstermiştir [71]. Bu çalışmada kullanılan DVM, Radyal temel fonksiyon (RTF) tarafından verilen Gauss çekirdeğidir [72]. Tahmini çıktılar, maksimum marjin hiper düzlemi hesaplanarak doğrusal olarak birleştirilmiştir [73]. WEKA yazılımında sıralı minimal optimizasyon için kullanılan DVM fonksiyonu R programında E1071 kütüphanesinin altında bulunmaktadır [74]. Bu çalışmada kullanılan Rweka kütüphanesinde bulunan DVM algoritmasının parametreleri şu şekildedir.

DVM-Tipi: C-Sınıflandırma

DVM-Kerneli: Radyal

Gamma (1/ Bant sayısı): Bu parametre tek bir eğitim örneğinin etkisinin ne olduğunu test eder. Düşük değerler uzak anlamına gelir ve yüksek değerler yakın anlamına gelir.

Gamma parametresi destek vektörleri olarak modele göre seçilen örneklerin etkisi yarıçapının tersi olarak görülebilir. Dolayısıyla her bir modelde değişkenlik gösteren bir parametre değeridir. Bu çalışmada kullanılan parametreler Chang vd. (2011) tarafından oluşturulan SVM kütüphanesindeki varsayılan değerlerden uyarlanmıştır [74].

#### 2.4.6. Doğruluk Analizleri

Hata matrisleri doğruluk analizleri için sıklıkla kullanılan yöntemlerden bir tanesidir. Bu çalışmada sınıflandırma için kullanılan üç makine öğrenme algoritmasının ortak çıktılarından bir tanesi hata matrisleridir. Doğruluk analizleri için R programından alınan hata matrisleri kullanılmıştır ve doğruluk analizleri parsel tabanlı mantıkla yapılmıştır. Hata matrisinde kullanılan sınıf sayısına bağlı olarak sütun ve satır sayısı oluşur. Buna göre sınıf sayısı  $a$  olan bir sınıflandırmada  $a \times a$  boyutunda bir hata matrisi oluşur. Bu matrisin köşegenleri arasında bulunan çapraz değerler doğru sınıflandırılmış değerleri dışında kalanlar ise yanlış sınıflandırılmış değerleri temsil eder.

Hata matrisinde üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kapa ( $\hat{K}$ ) değeri olmak üzere dört farklı doğruluk değeri hesaplanabilir.

Üretici doğruluğu sınıflandırma için üretilen test verilerinin doğruluğunu belirlemek için kullanılır. Üretici Doğruluğunu hesaplamak için her bir sınıfın doğru sınıflandırılmış parselleri, aynı sınıfa ait eğitim verisinde ki toplam parsel sayısına bölünür.

Kullanıcı Doğruluğunu hesaplamak için her bir sınıfın doğru sınıflandırılmış parselleri, aynı sınıfa atanmış toplam parsel sayısına bölünür.

Bu çalışmada sınıflara ait bağımsız doğruluk değerlerini hesaplamak için kullanılan yöntemlerden biri olan dengelenmiş doğruluk değeri kullanılmıştır [75]. Dengelenmiş doğruluk (Balanced Accuracy) her bir sınıf için ortalama geri çağırmadır. Dengelenmiş doğruluk, tüm bilgilerini çapraz öğelerden ve satır toplamlarından alır. Dengelenmiş doğruluğun formülü Eşitlik 17, 18 ve 19' da gösterilmektedir. Ayrıca Tablo 2.9'da dengelenmiş doğruluğu bulmak için kullanılan 2x2 hata matrisi örneği gösterilmektedir.

Tablo 2.9. Dengelenmiş Doğruluğu Bulmak İçin Kullanılan 2x2 Hata Matrisi Örneği [76]

Referans Veri		
<b>Tahmin</b>	<b>Sınıf</b>	<b>Yanlış Sınıf</b>
<b>Sınıf</b>	A	B
<b>Yanlış Sınıf</b>	C	D

$$Hassasiyet (\text{Üretici Doğruluğu}) = A/(A + C) \quad (17)$$

$$\text{Özgüllük (Specificity)} = D/(B + D) \quad (17)$$

$$Dengelenmiş Doğruluk = (Hassasiyet + Özgüllük)/2 \quad (19)$$

Genel Doğruluğu hesaplamak için ise doğru sınıflandırılmış parsel sayısı, eğitim verisinde bulunan toplam parsel sayısına bölünür.

$\hat{K}$  değeri ise referans veri ile sınıflandırılmış veri arasındaki korelasyonu gösterir (Eşitlik 20).

$$Kappa (\hat{K}) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} X x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} X x_{+i})} \quad (20)$$

Eşitlik 20’de N hata matrisinde örnek sayılarının bütünü, r hata matrisindeki satır sayılarının toplamını (sınıf sayısını),  $x_{ii}$  doğru sınıflandırılmış örnekleri,  $x_{+i}$  i satırının toplam sayısını,  $x_{i+}$  i sütununun toplam sayısını temsil etmektedir.

Tablo 2.10. Çalışmadan alınan bir hata matrisi örneği.

Confusion Matrix and Statistics											
		Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin	
biber	6	0	0	0	0	1	1	0	0	0	
bugday	0	90	0	0	1	0	0	0	0	0	
domates	0	0	41	4	0	0	0	0	0	0	
misir	0	0	1	108	0	0	0	0	4	1	
misir2	0	1	1	5	89	1	0	0	1	0	
pamuk	1	0	0	0	0	47	0	0	0	0	
patlican	2	0	0	0	0	0	8	0	0	0	
uzum	10	1	3	6	0	0	3	287	0	5	
yonca	0	0	0	0	0	0	0	0	10	0	
zeytin	0	1	0	0	1	0	0	0	0	89	

overall statistics

Accuracy : 0.9337  
95% CI : (0.9146, 0.9497)  
No Information Rate : 0.3458  
P-value [Acc > NIR] : < 2.2e-16

kappa : 0.9175

Tablo 2.10' da gösterilen hata matrisinde örnek olarak buğdaya ait doğruluk değerlerinin hesaplanması istenirse kullanıcı doğruluğu için hata matrisinde yatay düzlemdeki doğru sınıflandırılmış buğday parselleri, toplam buğday parsellerine bölünür  $(90/90+1)$  ve %98,90 olarak bulunur. Üretici doğruluğu için ise, hata matrisinde düşey düzlemdeki doğru sınıflandırılmış buğday parselleri, toplam buğday parsellerine bölünür  $(90/90+1+1+1)$  ve %96,77 olarak bulunur. Genel doğruluğu hesaplamak içinse doğru sınıflandırılan tüm parseller, toplam parsel sayısına bölünür. Tablo 2.10' da görülen matris için genel doğruluk  $(6+90+41+108+89+47+8+287+10+89)/830 = 0.9337$  şeklindedir. Tablo 2.10' da bulunan *Accuracy* değeri genel doğruluğu *Kappa* değeri ise  $\hat{K}$ 'yı temsil etmektedir.

### 3. BULGULAR ve KARŞILAŞTIRMALAR

Sınıflandırma işlemi KA, RO ve DVM makine öğrenme algoritmaları ile ve 8 farklı özellik kombinasyonu kullanılarak yapılmıştır. Sınıflandırma sonucunda elde edilen bulgular Tablo 3.1’de gösterilmiştir.

Bu çalışmada sınıflandırma için kullanılan makine öğrenme algoritmaları çıktılarının doğruluk değerlendirmeleri yapılırken, hata matrisinin bütün elemanlarını işleme katarak hesaplama yaptığı için, sonuçlar arasındaki karşılaştırmalarda  $\hat{K}$  değeri kullanılmıştır.

Ayrıca bu tez çalışmasında sınıflandırılan tüm sınıfların doğruluk değerleri de incelenmiştir. Bu değerler incelenirken her bir algortmada elde edilen sonuçlar değerlendirilmiştir. Bununla birlikte Tablo 3.3’de KA, Tablo 3.4’de RO ve Tablo 3.5’te DVM algoritmaları için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri gösterilmektedir. KA, DVM ve RO algoritmalarıyla elde edilen sınıflandırma sonuçlarının ürün bazında karşılaştırılması ise Tablo 3.6’da gösterilmektedir. Dengelenmiş doğruluk her sınıf için bağımsız olarak ölçülmüş ve toplanmıştır. Bununla birlikte dengelenmiş doğruluk, tüm bilgilerini hata matrisindeki bütün öğelerden ve satır toplamlarından almaktadır. Bundan dolayı, hata matrisindeki değerlendirmelerde dengelenmiş doğruluk değerleri dikkate alınacaktır.

Çalışmada sınıflandırma işlemi için kullanılan ilk özellik kombinasyonu  $Ort_{S1}$  ‘dir. Bu kombinasyonda Sentinel-1 uydu görüntülerine ait VV ve VH bantları kullanılmıştır. Sınıflandırma sonucunda en yüksek  $\hat{K}$  değerini RO algoritması sağlamıştır. Sınıflandırma sonucunda  $\hat{K}$  değeri %88,1 olarak hesaplanmıştır (Tablo 3.1). Sınıflandırma sonucunda elde edilen sonuç haritası Şekil 3.1’de gösterilmiştir.

Tablo 3.11. Çalışmada kullanılan özellik kombinasyonları ve KA, RO ve DVM makine öğrenme algoritmaları için hesaplanan  $\hat{R}$  ve genel doğruluk değerlerinin karşılaştırması.


	Özellik Kombinasyonu	KA		RO		DVM	
		$\hat{R}$	Genel Doğruluk	$\hat{R}$	Genel Doğruluk	$\hat{R}$	Genel Doğruluk
1	$Ort_{S1}$	<b>0,778</b>	0,821	<u><b>0,881</b></u>	0,905	<b>0,8660</b>	0,893
2	$Ort_{S1}, Std_{S1}, Hmj_{S1},$ $Kont_{S1}, Frk_{S1}, Ent_{S1},$ $A2Mo_{S1}, Kor_{S1}$	<b>0,756</b>	0,804	<b>0,864</b>	0,892	<u><b>0,866</b></u>	0,893
3	$Ort_{S2}$	<b>0,795</b>	0,835	<u><b>0,888</b></u>	0,910	<b>0,841</b>	0,872
4	$Ort_{NDVI}$	<b>0,850</b>	0,880	<u><b>0,909</b></u>	0,927	<b>0,870</b>	0,895
5	$Ort_{S2}, Ort_{NDVI}$	<b>0,871</b>	0,896	<b>0,898</b>	0,918	<u><b>0,901</b></u>	0,921
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2},$ $Hmj_{S2}, Kont_{S2},$ $Frk_{S2}, Ent_{S2}, A2Mo_{S2},$ $Kor_{S2}$	<b>0,870</b>	0,895	<u><b>0,890</b></u>	0,912	<b>0,846</b>	0,877
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	<b>0,875</b>	0,899	<b>0,911</b>	0,929	<u><b>0,918</b></u>	0,934
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI},$ $Std_{S1}, Std_{S2}, Hmj_{S1},$ $Hmj_{S2}, Kont_{S1},$ $Kont_{S2}, Frk_{S1}, Frk_{S2},$ $Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ $A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	<b>0,864</b>	0,890	<u><b>0,902</b></u>	0,922	<b>0,827</b>	0,863

\*Kırmızı renkli değerler sütundaki en büyük  $\hat{R}$  değerini ifade etmektedir.

\* Altı çizili değerler satırdaki en büyük  $\hat{R}$  değerini ifade etmektedir.


\*NDVI; Sentinel-2 Uydularının Kırmızı ve Yakın Kızılötesi bantlarından elde edilen Normalize Edilmiş Bitki İndeksi Farkı'nı ifade etmektedir.

Çalışmada kullanılan ikinci veri özellik kombinasyonu  $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$  'dir. Bu kombinasyonda Tablo 3.1' de verilen 1. Özellik kombinasyonuna ek olarak doku özellikleri de kullanılmıştır. Bu sınıflandırmada da en yüksek  $\hat{K}$  değerini (%86,4) yine RO algoritması sağlamıştır. Sınıflandırma sonucuna göre doku özelliklerinin kullanılmasıyla  $\hat{K}$  değeri yaklaşık %2 oranında düşmüştür ve %88,1 olarak hesaplanmıştır. Sınıflandırma sonucunda elde edilen harita Şekil 3.2'de gösterilmiştir.




Şekil 3.1. S1 orijinal bantlar ( $Ort_{S1}$ ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.





Şekil 3.2. S1 orijinal bantlar+standart sapma+S1 doku özellikleri ( $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$ ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.


Çalışmada kullanılan 3. veri kombinasyonunda ( $Ort_{S2}$ ) Sentinel-2 uydu görüntülerine ait orijinal bantlar (K, Y, M, NIR) kullanılmıştır (Tablo 3.1). Sadece Sentinel-1 bantlarının kullanıldığı 1. veri kombinasyonu ile kıyaslandığında  $\hat{K}$  doğruluğunda yaklaşık %2 oranında artış olmuştur. 3. veri kombinasyonu ile hesaplanan en yüksek  $\hat{K}$  doğruluğuna (%88,8) yine RO algoritmasıyla ulaşılmıştır. Üretilen sonuç haritası Şekil 3.3'de gösterilmiştir.




Şekil 3.3. S2 orijinal bantlar ( $Ort_{S2}$ ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.

Sadece NDVI bantlarının ortalama değerleri 4. özellik kombinasyonu olarak ( $Ort_{NDVI}$ ) kullanılmıştır. Bu sınıflandırma sonucunda  $\hat{K}$  değerinin %90,87 değerine ulaştığı görülmektedir (Tablo 3.1). Bu sınıflandırmadan elde edilen sonuçlara göre sadece NDVI bantları kullanılarak yüksek doğruluk değerlerine ulaşılabildiği görülmüştür. Bu veri kombinasyonunda da yine en yüksek doğruluk değerine ulaşılan algoritma RO algoritması olmuştur. RO algoritmasıyla üretilen sonuç haritası Şekil 3.4’ de gösterilmiştir.

Çalışmada kullanılan 5. özellik kombinasyonunda ise NDVI değerleriyle birlikte Sentinel-2 orijinal bantları da eklenmiştir ( $Ort_{S2}, Ort_{NDVI}$ ) (Tablo 3.1). Bu özellik kombinasyonu ile yapılan sınıflandırma sonucunda  $\hat{K}$  değerinde çok az bir değişim olmuştur. Bu kombinasyonda dikkat çeken nokta ise diğer sınıflandırmalardan farklı olarak en yüksek  $\hat{K}$  değerinin (%90,1) DVM algoritmasıyla elde edilmiş olmasıdır. Sınıflandırma sonucunda elde edilen sonuç haritası Şekil 3.5’ de gösterilmiştir.



Şekil 3.4. Yalnız NDVI bantları ( $Ort_{NDVI}$ ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.




Şekil 3.5. S2 Orijinal bantlar+NDVI ( $Ort_{S2}, Ort_{NDVI}$ ) kullanılarak DVM algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.

Çalışmada kullanılan 6. veri özelliği kombinasyonunda ise 5. veri kombinasyonunda kullanılan özelliklerle birlikte doku özellikleri de kullanılmıştır ( $Ort_{S2}, Ort_{NDVI}, Std_{S2}, Hmj_{S2}, Kont_{S2}, Frk_{S2}, Ent_{S2}, AZMo_{S2}, Kor_{S2}$ ). Sentinel-2 uydusunun orijinal bantları ve NDVI bantlarından elde edilen özellik değerleri ve doku değerlerinin birlikte sınıflandırılmasının sınıflandırma doğruluğunu arttırmadığı ve hatta yaklaşık %1 oranında azalttığı (%89,3) görülmüştür. Veri özellikleri kombinasyonlarının çoğunda olduğu gibi bu kombinasyonda da en yüksek doğruluk değerine ulaşılan algoritma RO algoritması olmuştur. Sınıflandırma sonucuna ait harita Şekil 3.6'da gösterilmektedir.

Çalışmada kullanılan 7. veri özelliği kombinasyonunda ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ), 5. veri özelliği kombinasyonuna ek olarak Sentinel-1 uydu görüntülerinin orijinal bantları da eklenmiştir. Bu çalışmada denenen tüm veri özellikleri kombinasyonları arasında en yüksek doğruluk oranını 7. veri özelliği kombinasyonu sağlamıştır. Bu veri setinde ise en yüksek sınıflandırma doğruluğu  $\hat{K} = \%91,8$  olarak hesaplanmış ve sınıflandırma DVM algoritması ile gerçekleştirilmiştir. Fakat, bu değer RO algoritmasıyla elde edilen  $\hat{K}$  doğruluğuna çok yakın bir değerdir (%91,1). Sınıflandırma sonucunda elde edilen sonuç haritası Şekil 3.7'de gösterilmektedir. Elde edilen bu sınıflandırma haritası bu çalışmada gerçekleştirilen denemelerde elde edilen en yüksek doğruluk oranına sahip haritadır. Ayrıca Tablo 3.2'de bu haritadan elde edilen sınıflandırma sonucunda hesaplanan ürünlerin alansal dağılımı gösterilmiştir.

Tablo 3.12. En yüksek doğruluk oranının elde edildiği S1+S2 orijinal bantlar+NDVI kullanarak ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) DVM algoritması ile yapılan nesne-tabanlı sınıflandırma sonucunda hesaplanan ürünlerin alansal dağılımı.

Sınıflandırılan Ürünlerin Alansal Dağılımı (Dekar)	
Biber	4920.9
Buğday	43745.9
Domates	15259.5
Mısır	83303.3
Mısır2	23970.7
Pamuk	9933.3
Patlıcan	1067.4
Üzüm	150766.4
Yonca	10049.5
Zeytin	178943.5




Şekil 3.6. S2 orijinal bantlar+NDVI+S2 doku değerleri kullanılarak ( $Ort_{S2}, Ort_{NDVI}, Std_{S2}, Hmj_{S2}, Kont_{S2}, Frk_{S2}, Ent_{S2}, A2Mo_{S2}, Kor_{S2}$ ) RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.


Çalışmada kullanılan 8. veri özelliği kombinasyonunda, oluşturulan bantların tamamı birlikte kullanılmıştır ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Kont_{S1}, Frk_{S1}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1}$ ). Bu veri özelliği kombinasyonunda da en yüksek  $\hat{K}$  değerine %90,24 ile RA algoritması ile ulaşılmıştır. Doku bantlarının kullanılmadığı 7. veri özelliği kombinasyonu ile karşılaştırıldığında, doku özelliklerinin sınıflandırma doğruluk değerini yaklaşık %1 oranında azalttığı görülmektedir. 8 no'lu veri özelliği kombinasyonun RO algoritması kullanılarak üretilen sonuç haritası Şekil 3.8'de gösterilmiştir.

Hesaplanan tüm sınıflandırma doğruluk değerleri değerlendirildiğinde doku ölçümleri ihmal edilerek Sentinel-1 ve Sentinel-1 bantlarının NDVI bantlarıyla birlikte kullanılması

ile en yüksek sınıflandırma doğruluğuna ulaşıldığı görülmektedir. Bu çalışmada elde edilen sonuçlara göre, kullanılacak algoritma seçilirken DVM veya RO algoritmasına öncelik verilebilir. DVM algoritması bu çalışmada %1 oranında daha iyi sınıflandırma sonucu vermiştir. Ancak, RO algoritmasının sahip olduğu özellik önem derecesi (variable importance) fonksiyonu bu algoritmayı daha kullanışlı hale getirmektedir. Özellik önem derecesi fonksiyonu sayesinde sınıflandırmada kullanılan en önemli bantlar tespit edilebilmektedir. Ayrıca RO her çalıştırıldığında düğümünde kullanılan değişkenlerde değişiklik meydana geldiği için doğruluk değerlerinde küçük değişiklikler meydana gelecektir.



Şekil 3.7. S1+S2 orijinal bantlar+NDVI ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) kullanılarak DVM algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.



Şekil 3.8. S1 ve S2 orijinal bantlar+S1 ve S2 doku+NDVI ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Kont_{S1}, Kont_{S2}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1}$ ) kullanılarak RO algoritması ile yapılan nesne-tabanlı sınıflandırma sonucu.

### 3.1. Karar Ağacı Algoritması İle Elde Edilen Sonuçlar

KA algoritmasıyla yapılan sınıflandırma sonuçları değerlendirildiğinde biberin sadece S2 orijinal bantlarının kullanıldığı ve S1, S2 ve NDVI değerlerinin birlikte kullanıldığı veri özelliği kombinasyonunda %65,42 dengelenmiş doğruluğa ulaştığı görülmektedir (Tablo 3.3). Biberin diğer ürünlere nazaran daha düşük doğruluk değerine sahip olması incelenmiştir. Bu inceleme sonucunda biberin büyük oranda mısırla karıştığı tespit edilmiştir. Tablo 2.1’de verilen fenolojik değerler incelendiğinde biber ve mısırın aynı tarih aralıklarında ekim, gelişim ve hasat sürecini yaşadığı görülmektedir. Buğday ve üzüm ise tüm veri kombinasyonlarında %90 üzerinde dengelenmiş doğruluk değerine sahiptir. Bu çalışmada, KA algoritmasında en yüksek sınıflandırma doğruluğu hesaplanan ürünler buğday ve üzüm olmuştur.

Tablo 3.13. KA algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri.

		Karar Ağacı Algoritmasında Ürünler Bazında Kullanıcı Doğruluğu \ Üretici Doğruluğu (%)									
		Dengelenmiş Doğruluk									
	Özellik Kombinasyonu	Biber	Buğday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin
1	$Ort_{S1}$	23.53/	95.24/	85.71/	83.19/	77.78/	81.13/	20.00/	85.11/	18.18/	92.86/
		21.05	86.02	78.26	80.49	76.92	87.76	25.00	97.56	13.33	68.42
		<b>59.72</b>	<b>92.74</b>	<b>88.75</b>	<b>88.83</b>	<b>87.11</b>	<b>93.24</b>	<b>61.77</b>	<b>94.27</b>	<b>56.12</b>	<b>83.87</b>
2	$Ort_{S1}, Std_{S1}, Hmj_{S1},$ $Kont_{S1}, Frk_{S1}, Ent_{S1},$ $A2Mo_{S1}, Kor_{S1}$	11.11/	95.35/	88.89/	77.27/	76.34/	68.52/	7.69/	87.15/	27.27/	86.77/
		10.53	88.17	69.57	82.93	78.02	75.51	8.33	96.86	20.00	62.11
		<b>54.28</b>	<b>93.81</b>	<b>84.53</b>	<b>89.34</b>	<b>87.52</b>	<b>86.67</b>	<b>53.43</b>	<b>94.66</b>	<b>59.51</b>	<b>80.44</b>
3	$Ort_{S2}$	50.00/	95.60/	66.67/	97.20/	89.58/	95.24/	80.00/	89.34/	88.89/	92.47/
		31.58	93.55	73.91	84.55	94.51	81.63	66.67	99.30	53.33	90.53
		<b>65.42</b>	<b>96.50</b>	<b>85.87</b>	<b>92.06</b>	<b>96.58</b>	<b>90.69</b>	<b>83.21</b>	<b>96.52</b>	<b>76.61</b>	<b>94.79</b>
4	$Ort_{NDVI}$	15.39/	95.60/	56.52/	88.29/	89.58/	90.91/	81.82/	91.35/	100.00/	90.72/
		10.53	93.55	56.52	79.67	94.51	81.63	75.00	99.30	60.00	92.63
		<b>54.59</b>	<b>96.50</b>	<b>76.99</b>	<b>88.92</b>	<b>96.58</b>	<b>90.56</b>	<b>87.38</b>	<b>97.17</b>	<b>80.00</b>	<b>95.70</b>
5	$Ort_{S2}, Ort_{NDVI}$	50.00/	95.60/	66.67/	97.20/	89.58/	95.24/	80.00/	89.34/	88.89/	92.47/
		31.58	93.55	73.91	84.55	94.51	81.63	66.67	99.30	53.33	90.53
		<b>57.65</b>	<b>94.95</b>	<b>83.25</b>	<b>84.87</b>	<b>92.87</b>	<b>93.37</b>	<b>83.15</b>	<b>93.95</b>	<b>62.78</b>	<b>88.57</b>
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2},$ $Hmj_{S2}, Kont_{S2},$ $Frk_{S2}, Ent_{S2}, A2Mo_{S2},$ $Kor_{S2}$	8.33/	92.71/	63.64/	90.52/	91.49/	97.67/	92.43/	97.80/	100.00/	95.56/
		5.26	95.70	76.09	85.37	94.51	85.71	97.91	95.69	40.00	90.53
		<b>65.36</b>	<b>96.50</b>	<b>86.96</b>	<b>92.13</b>	<b>96.58</b>	<b>88.52</b>	<b>83.21</b>	<b>96.52</b>	<b>76.67</b>	<b>94.79</b>
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	50.00/	92.71/	58.73/	92.92/	85.37/	100.00/	57.14/	93.96/	88.89/	95.56/
		31.58	95.70	80.44	91.49	94.51	83.67	66.67	97.56	53.33	90.53
		<b>65.42</b>	<b>97.37</b>	<b>88.56</b>	<b>92.12</b>	<b>96.71</b>	<b>91.84</b>	<b>82.97</b>	<b>97.12</b>	<b>76.61</b>	<b>94.99</b>
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI},$ $Std_{S1}, Std_{S2}, Hmj_{S1},$ $Hmj_{S2}, Kont_{S1},$ $Kont_{S2}, Frk_{S1}, Frk_{S2},$ $Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ $A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	8.33/	92.71/	90.52/	91.57/	91.49/	97.67/	57.14/	92.43/	100.00/	95.56/
		5.26	95.70	85.37	92.68	94.51	85.71	66.67	97.91	40.00	90.53
		<b>51.95</b>	<b>97.37</b>	<b>86.77</b>	<b>91.90</b>	<b>96.71</b>	<b>92.79</b>	<b>82.97</b>	<b>96.84</b>	<b>70.00</b>	<b>94.99</b>

\*Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

\* Tablonun üst satırında üretici/kullanıcı doğruluğu, alt satırında ise dengelenmiş doğruluk değerleri gösterilmektedir.




Bunun yanı sıra patlıcan ve yoncanın sadece S1 bantlarının ( $Ort_{S1}$ ) veya S1 doku özelliklerinin ( $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$ ) kullanıldığı veri kombinasyonlarında sınıflandırma doğruluğunda yaklaşık %20'ye varan düşüşlerinin olduğu gözlemlenmiştir (Şekil 3.9). Bu çalışmaya göre, S1 orijinal ve doku bantlarının patlıcan ve yoncanın sınıflandırılmasında KA algoritması için önemli olmadığı aksine sınıflandırma doğruluğunu azalttığı tespit edilmiştir.

$Ort_{NDVI}$  bantlarının tek başına kullanıldığı veri kombinasyonu en fazla ürünün en yüksek doğruluğa ulaştığı veri özelliği kombinasyonu olarak dikkat çekmektedir. Patlıcan, üzüm, zeytin ve yonca en yüksek doğruluk değerlerine, yalnız NDVI bantlarının kullanıldığı kombinasyonda ulaşmıştır. Bu çalışmaya göre, KA algoritmasıyla yapılan sınıflandırmada NDVI bantlarının en önemli bantlar arasında olduğu sonucu ortaya çıkmaktadır.

Tablo 3.3'de görülen 2. veri özellik kombinasyonunda S1+Doku bantları kullanılmıştır. Diğer kombinasyonlarla kıyaslandığında, S1+Doku kombinasyonu hiçbir ürün için en iyi dengelenmiş doğruluk değerini vermemiştir.

Bu çalışmada dikkat çekici bir başka ürün de domatestir. Diğer tüm ürünlerde yüksek doğruluk değerlerini veren, yalnız NDVI değerlerinin kullanıldığı veri kombinasyonu, domates için en düşük doğruluk değerini vermiştir. Diğer taraftan, domates S1 orijinal bantlarının kullanıldığı ilk kombinasyonda en yüksek dengelenmiş doğruluk değerini vermiştir. Domatesin bu iki algoritma arasındaki sınıflandırma doğruluğu farkı yaklaşık %12'dir. Bu çalışmada domatesi tespit etmek için S1 bantlarının çok önemli olduğu fakat NDVI bantlarının şaşırtıcı bir şekilde doğruluğu azalttığı tespit edilmiştir.

Üzüm ve buğday farklı veri kombinasyonlarından en az etkilenen ürünler olmuşlardır. Bu ürünlerde sınıflandırmada hangi kombinasyon kullanılmış olursa olsun doğruluk değerlerinde en fazla %5 kadar değişim olmuştur.



Şekil 3.9. KA algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri.

\*Şekilde görülen rakamlar Tablo 3.3’de gösterilen veri özelliği kombinasyonlarını ifade etmektedir.

### 3.2. Rastgele Orman Algoritması İle Elde Edilen Sonuçlar

RO algoritması ile elde edilen sonuçlar değerlendirildiğinde biberin KA algoritmasında olduğu gibi S1, S2 ve NDVI değerlerinin birlikte kullanıldığı veri özelliği kombinasyonunda en yüksek doğruluk değerine ulaştığı görülmüştür. KA algoritması sonucuna göre RO algoritmasında doğruluk değeri yaklaşık %5 artmış ve %70,93 değerine ulaşmıştır (Tablo 3.4). Biberin diğer ürünlere nazaran daha düşük doğruluk oranına sahip olması incelenmiştir. Bu inceleme sonucunda biberin KA algoritmasında mısırla karışmasına rağmen RO algoritmasında patlıcanla karıştığı tespit edilmiştir. Tablo 2.1’de verilen fenolojik değerler incelendiğinde patlıcanın, biberle bire bir aynı gelişim dönemlerine rastladığı görülmektedir. Ayrıca, biberde olduğu gibi çalışma alanında patlıcanın da popülasyonu azdır. Dolayısıyla, az sayıda eğitim ve test verisine sahiptir. Bu durumda KA algoritmasının, RO algoritmasına göre düşük sayıda eğitim verisinden daha fazla etkilendiği tespit edilmiştir.

Tablo 3.14. RO algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri.

		Rastgele Orman Algoritmasında Ürünler Bazında Kullanıcı Doğruluğu \ Üretici Doğruluğu (%)									
		Dengelenmiş Doğruluk									
	Özellik Kombinasyonu	Biber	Buğday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin
1	$Ort_{S1}$	100.00/ 26.32	90.00/ 96.77	93.02/ 86.96	96.33/ 85.37	85.86/ 93.41	86.79/ 93.88	100.00/ 33.33	89.38/ 99.65	100.00/ 33.33	92.39/ 89.47
		<b>63.16</b>	<b>97.71</b>	<b>93.29</b>	<b>92.40</b>	<b>95.76</b>	<b>96.49</b>	<b>66.67</b>	<b>96.70</b>	<b>66.67</b>	<b>94.26</b>
2	$Ort_{S1}, Std_{S1}, Hmj_{S1},$ $Kont_{S1}, Frk_{S1}, Ent_{S1},$ $A2Mo_{S1}, Kor_{S1}$	100.00/ 5.26	89.11/ 96.77	92.86/ 84.78	97.22/ 85.37	81.13/ 94.51	86.79/ 93.88	100.00/ 25.00	87.23/ 100.00	100.00/ 20.00	95.24/ 84.21
		<b>52.63</b>	<b>97.64</b>	<b>92.20</b>	<b>92.47</b>	<b>95.90</b>	<b>96.49</b>	<b>62.50</b>	<b>96.13</b>	<b>60.00</b>	<b>91.83</b>
3	$Ort_{S2}$	47.06/ 42.11	97.85/ 97.85	87.23/ 89.13	98.15/ 86.18	91.58/ 95.60	95.92/ 95.92	100.00/ 25.00	90.25/ 100.00	55.56/ 33.33	95.60/ 91.58
		<b>70.50</b>	<b>98.79</b>	<b>94.18</b>	<b>92.95</b>	<b>97.26</b>	<b>97.83</b>	<b>62.50</b>	<b>97.15</b>	<b>66.42</b>	<b>95.52</b>
4	$Ort_{NDVI}$	55.56/ 26.32	98.91/ 97.85	83.33/ 76.09	93.75/ 85.37	95.74/ 98.90	95.92/ 95.92	84.62/ 91.67	91.40/ 100.00	61.54/ 53.33	97.83/ 94.74
		<b>62.91</b>	<b>98.86</b>	<b>87.60</b>	<b>92.19</b>	<b>99.18</b>	<b>97.83</b>	<b>95.71</b>	<b>97.51</b>	<b>76.36</b>	<b>97.23</b>
5	$Ort_{S2}, Ort_{NDVI}$	50.00/ 42.11	94.74/ 96.77	85.11/ 86.96	95.50/ 86.18	92.63/ 96.70	95.75/ 91.84	60.00/ 25.00	90.82/ 100.00	42.86/ 20.00	93.41/ 89.47
		<b>70.56</b>	<b>98.05</b>	<b>93.03</b>	<b>92.74</b>	<b>97.88</b>	<b>95.79</b>	<b>62.38</b>	<b>97.33</b>	<b>59.75</b>	<b>94.33</b>
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2},$ $Hmj_{S2}, Kont_{S2},$ $Frk_{S2}, Ent_{S2}, A2Mo_{S2},$ $Kor_{S2}$	83.33/ 26.32	96.81/ 97.85	85.42/ 89.13	98.15/ 86.18	88.00/ 96.70	81.36/ 97.96	100.00/ 25.00	89.69/ 100.00	33.33/ 13.33	100.00/ 90.53
		<b>63.10</b>	<b>98.72</b>	<b>94.12</b>	<b>92.95</b>	<b>97.54</b>	<b>98.28</b>	<b>62.50</b>	<b>96.96</b>	<b>56.42</b>	<b>95.26</b>
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	80.00/ 42.11	98.91/ 97.85	89.13/ 89.13	98.15/ 86.18	92.78/ 98.90	87.27/ 97.96	100.00/ 25.00	89.97/ 100.00	100.00/ 40.00	96.81/ 95.79
		<b>70.93</b>	<b>98.86</b>	<b>94.25</b>	<b>92.95</b>	<b>98.98</b>	<b>98.53</b>	<b>62.50</b>	<b>97.05</b>	<b>70.00</b>	<b>97.69</b>
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI},$ $Std_{S1}, Std_{S2}, Hmj_{S1},$ $Hmj_{S2}, Kont_{S1},$ $Kont_{S2}, Frk_{S1}, Frk_{S2},$ $Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ $A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	83.33/ 26.32	94.79/ 97.85	91.11/ 89.13	95.58/ 87.80	88.00/ 96.70	84.21/ 97.96	100.00/ 25.00	90.82/ 100.00	100.00/ 20.00	100.00/ 95.79
		<b>63.10</b>	<b>98.59</b>	<b>94.31</b>	<b>93.55</b>	<b>97.54</b>	<b>98.40</b>	<b>62.50</b>	<b>97.33</b>	<b>60.00</b>	<b>97.89</b>

\*Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

\* Tablonun üst satırında üretici/kullanıcı doğruluğu, alt satırında ise dengelenmiş doğruluk değerleri gösterilmektedir.

Buğday, mısır, mısır2, zeytin ve üzüm sınıfları ise tüm veri kombinasyonlarında %90 üzerinde dengelenmiş doğruluk değerine sahiptir. KA algoritması sadece buğday ve üzüm sınıfını tüm veri özelliği kombinasyonlarında %90 doğruluk değerinin üzerine çıkarırken, RO algoritmasında %90 doğruluk değerinin üzerine çıkan ürün sayısının daha fazla olması, ürünler bazında RO algoritmasının daha iyi ayırım özelliğine sahip olduğunu göstermektedir.

KA algoritmasının aksine, RO algoritması ile yapılan sınıflandırmada S1 bantlarından üretilen doku bantlarının sınıflandırma doğruluğuna olumsuz etkisinin ciddi oranda olmamıştır. Bu durumdan dikkate değer şekilde olumsuz yönde etkilenen tek ürün biber olmuştur. Fakat biberin dengelenmiş sınıflandırma doğruluğu RO algoritmasında, KA algoritmasına göre daha az düşüş göstermiştir. RO algoritması için sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri Şekil 3.10'da gösterilmiştir.


KA algoritmasına benzer şekilde, RO'da da en fazla ürünün yüksek doğruluk oranına sahip olduğu kombinasyon  $Ort_{NDVI}$  bantlarının tek başına kullanıldığı 4 nolu veri kombinasyonu olmuştur. Buğday, mısır2, patlıcan, üzüm, zeytin ve yonca sınıfları en yüksek doğruluk oranlarına yalnız NDVI bantlarının kullanıldığı 4 nolu veri kombinasyonunda ulaşmıştır. Tüm değerler arasında en yüksek dengelenmiş doğruluk mısır2 ürünü için %99,18 olarak hesaplanmıştır.

Çalışmada RO algoritmasıyla sınıflandırılan ürünlerden hiçbirisi 1., 2., 3., 5. ve 6. veri kombinasyonlarında bu çalışmada elde edilen en yüksek dengelenmiş doğruluk değerlerine ulaşamamıştır. Fakat kombinasyonlar arasındaki sınıflandırma doğrulukları genel olarak %1 ile %5 arasında değişmektedir. Bu çalışmada elde edilen sonuçlara göre doku özelliklerinin sınıflandırma sonucuna olumsuz etkisinin en yüksek olduğu algoritmanın RO algoritması olduğu görülmüştür.

Domates, KA algoritmasında olduğu gibi, yalnız NDVI bantlarının kullanıldığı 4 numaralı kombinasyonda, doğruluk değerlerinde düşüş göstermiştir. Ancak düşme miktarı yaklaşık %1-2 arasında kalmıştır.

Patlıcan ve yonca sınıfları sadece NDVI bantlarının kullanıldığı veri özelliği kombinasyonunda (4 nolu kombinasyon) dengelenmiş doğruluklarda önemli oranda artış göstermiştir. Patlıcan bu kombinasyonda diğer veri kombinasyonlarına göre dengelenmiş doğrulukta yaklaşık %30 artış göstermiş ve doğruluk değeri %95,71 olarak hesaplanmıştır. Yonca sınıfında patlıcan sınıfında olduğu kadar önemli oranda bir değişim olmamıştır. Ancak, sadece NDVI bantları kullanılarak sınıflandırma yapıldığında doğruluk oranlarında yaklaşık %5 ila %20 arasında bir artış olduğu görülmektedir.

Üzüm ve buğday, KA'da olduğu gibi, RO'da da farklı veri kombinasyonlarında benzer doğruluk değerlerini veren ürünler olmuşlardır. Fakat, RO algoritmasında farklı veri kombinasyonlarında elde edilen doğruluk değerlerindeki değişim daha az miktarda olmuştur. Tüm sınıflandırma algoritmalarında üzüm ve buğday için oluşan dengelenmiş doğruluk değeri farklı sadece %1 kadardır.



Şekil3.10. RO algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri.

\*Şekilde görülen rakamlar veri Tablo 3.4'de gösterilen veri özelliği kombinasyonlarını ifade etmektedir.

### 3.3. Destek Vektör Makineleri İle Elde Edilen Sonuçlar

DVM sınıflandırma algoritması ile elde edilen sonuçlar Tablo 3.5'te verilmiştir. Sınıflandırma sonuçları incelendiklerinde biberin diğer iki makine öğrenme algoritmasından farklı olarak, 3 nolu veri özelliği kombinasyonunda ( $Ort_{S2}$ ) en yüksek sınıflandırma doğruluğuna (%70,93) ulaştığı görülmüştür. RO algoritmasında biber en yüksek doğruluğa, DVM'den farklı olarak, S1, S2 ve NDVI değerlerinin birlikte kullanıldığı 7 nolu veri özelliği kombinasyonunda ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) ulaşmıştır. Fakat her iki makine öğrenme algoritmasında da biberin doğruluk değeri %70,93 olarak hesaplanmıştır.

Tüm veri kombinasyonlarında buğday, mısır2, pamuk, zeytin ve üzüm sınıfları %90 üzerinde dengelenmiş doğruluk oranına ulaşmıştır. Farklı kombinasyonlar kullanılarak yapılan hesaplamalarda DVM'nin KA algoritmasına göre doğruluk değerlerindeki değişim daha az olurken, RO algoritmasına göre daha fazla olmuştur.

Diğer iki makine öğrenme algoritmasında olduğu gibi DVM algoritmasında da doku özelliklerinin sınıflandırma doğruluğuna olumlu etkisi olmamış aksine bir miktar olumsuz etkisi olmuştur. DVM'de en fazla ürünün yüksek doğruluk oranına sahip olan kombinasyon 7 nolu veri özelliği kombinasyonu ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) olmuştur. Bu veri kombinasyonunda en yüksek dengelenmiş doğruluk değerine ulaşan ürünler buğday, domates, mısır, pamuk, üzüm ve zeytindir. Tüm dengelenmiş değerler arasında en yüksek sınıflandırma doğruluğuna 3 nolu veri kombinasyonunda ( $Ort_{S2}$ ) %98,98 doğruluk değeriyle mısır2 ürünü ulaşmıştır.

Tablo 3.5'te görüldüğü üzere 1, 2, 6 ve 8 no'lu veri kombinasyonları hiçbir ürün için en yüksek dengelenmiş doğruluk oranını sağlamamıştır. RO algoritmasından farklı olarak, DVM algoritmasında veri kombinasyonları değiştikçe dengeli doğruluk değerleri arasındaki farklar %20 oranına kadar çıkmıştır. DVM algoritması ile elde edilen sınıflandırma sonuçlarının ürün bazında doğruluk oranları Şekil 3.11'de gösterilmiştir.


Tablo 15. DVM algoritması kullanılarak yapılan sınıflandırma sonucunda ürünler için hesaplanan üretici doğruluğu, kullanıcı doğruluğu ve dengelenmiş doğruluk değerleri.

		Destek Vektör Makineleri Algoritmasında Ürünler Bazında Kullanıcı Doğruluğu \ Üretici Doğruluğu (%)									
		Dengelenmiş Doğruluk									
Özellik Kombinasyonu		Biber	Buğday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin
1	$Ort_{S1}$	75.00/	92.47/	88.10/	94.59/	87.37/	86.54/	100.00/	88.82/	100.00/	86.14/
		31.58	92.47	80.44	85.37	91.21	91.84	8.33	99.65	33.33	91.58
		<b>65.67</b>	<b>95.76</b>	<b>89.90</b>	<b>92.26</b>	<b>94.79</b>	<b>95.47</b>	<b>54.17</b>	<b>96.51</b>	<b>66.67</b>	<b>94.84</b>
2	$Ort_{S1}, Std_{S1}, Hmj_{S1},$ $Kont_{S1}, Frk_{S1}, Ent_{S1},$ $A2Mo_{S1}, Kor_{S1}$	100.00/	87.38/	93.02/	96.33/	82.52/	86.00/	100.00/	87.50/	100.00/	96.43/
		5.26	96.77	86.96	85.37	93.41	93.88	25.00	100.00	20.00	85.26
		<b>52.63</b>	<b>97.51</b>	<b>93.29</b>	<b>92.40</b>	<b>95.49</b>	<b>96.49</b>	<b>62.50</b>	<b>96.22</b>	<b>60.00</b>	<b>92.43</b>
3	$Ort_{S2}$	80.00/	97.83/	77.36/	92.66/	92.78/	95.83/	100.00/	91.11/	60.00/	98.88/
		42.11	96.77	89.13	82.11	98.90	93.88	58.33	100.00	40.00	92.63
		<b>70.93</b>	<b>98.25</b>	<b>93.80</b>	<b>90.49</b>	<b>98.98</b>	<b>96.81</b>	<b>79.17</b>	<b>97.42</b>	<b>69.75</b>	<b>96.25</b>
4	$Ort_{NDVI}$	60.00/	97.83/	66.67/	82.76/	94.68/	86.79/	100.00/	90.82/	55.56/	97.75/
		15.79	96.77	69.57	78.05	97.80	93.88	66.67	100.00	33.33	91.58
		<b>57.77</b>	<b>98.25</b>	<b>83.76</b>	<b>87.61</b>	<b>98.56</b>	<b>96.49</b>	<b>83.33</b>	<b>97.33</b>	<b>66.42</b>	<b>95.65</b>
5	$Ort_{S2}, Ort_{NDVI}$	77.78/	80.73/	86.05/	95.28/	82.98/	91.84/	100.00/	87.82/	100.00/	85.57/
		36.84	94.62	80.44	82.11	85.71	91.84	66.67	95.47	20.00	87.37
		<b>68.30</b>	<b>95.89</b>	<b>89.84</b>	<b>90.70</b>	<b>91.78</b>	<b>95.66</b>	<b>83.33</b>	<b>94.24</b>	<b>60.00</b>	<b>92.73</b>
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2},$ $Hmj_{S2}, Kont_{S2},$ $Frk_{S2}, Ent_{S2}, A2Mo_{S2},$ $Kor_{S2}$	50.00/	95.56/	88.89/	100.00/	68.75/	90.39/	100.00/	85.67/	100.00/	100.00/
		5.26	92.47	69.57	79.67	96.70	95.92	16.67	100.00	13.33	89.47
		<b>52.57</b>	<b>95.97</b>	<b>84.53</b>	<b>89.84</b>	<b>95.65</b>	<b>97.64</b>	<b>58.33</b>	<b>95.58</b>	<b>56.67</b>	<b>94.74</b>
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	75.00/	98.90/	91.11/	94.74/	90.82/	97.92/	80.00/	91.11/	100.00/	97.80/
		31.58	96.77	89.13	87.80	97.80	95.92	66.67	100.00	66.67	93.68
		<b>65.67</b>	<b>98.32</b>	<b>94.31</b>	<b>93.48</b>	<b>98.29</b>	<b>97.90</b>	<b>83.21</b>	<b>97.42</b>	<b>83.33</b>	<b>96.71</b>
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI},$ $Std_{S1}, Std_{S2}, Hmj_{S1},$ $Hmj_{S2}, Kont_{S1},$ $Kont_{S2}, Frk_{S1}, Frk_{S2},$ $Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ $A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	100.00/	95.29/	93.75/	100.00/	63.31/	95.75/	100.00/	83.92/	100.00/	100.00/
		5.26	87.10	65.22	77.24	96.70	91.84	16.67	100.00	13.33	89.47
		<b>52.63</b>	<b>93.28</b>	<b>82.48</b>	<b>88.62</b>	<b>94.90</b>	<b>95.79</b>	<b>58.33</b>	<b>94.94</b>	<b>56.67</b>	<b>94.74</b>

\* Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

\* Tablonun üst satırında üretici/kullanıcı doğruluğu, alt satırında ise dengelenmiş doğruluk değerleri gösterilmektedir.

Yonca için en yüksek dengelenmiş doğruluk oranı (%83,3) 7 nolu veri kombinasyonunda ( $Ort_{S_1}, Ort_{S_2}, Ort_{NDVI}$ ) elde edilmiştir. Bu değer, diğer veri kombinasyonlarıyla kıyaslandığında, dikkat çekicidir. Diğer veri kombinasyonlarıyla karşılaştırıldığında bu veri kombinasyonunda yoncanın doğruluk oranındaki artış en az %15 olmuştur.



Şekil 3.11. DVM algoritması ile sınıflandırılan ürünlerin dengelenmiş doğruluk değerleri.

\*Şekilde görülen rakamlar veri Tablo 3.5’de gösterilen veri özelliği kombinasyonlarını ifade etmektedir.

### 3.4. KA, DVM ve RO Algoritmalarıyla Elde Edilen Sınıflandırma Sonuçlarının Ürün Bazında Karşılaştırılması

KA, RO ve DVM makine öğrenme algoritmaları ile sınıflandırılmış ürünlere ait dengelenmiş doğruluk değerleri Tablo 3.6’da gösterilmiştir. Tablo 3.6 incelediğinde biber için en yüksek dengelenmiş doğruluğa 3 no’lu özellik kombinasyonu ( $Ort_{S_2}$ ) DVM algoritmasıyla ve 5 no’lu özellik kombinasyonu ( $Ort_{S_2}, Ort_{NDVI}$ ) RO algoritmasıyla ulaşıldığı görülmektedir (%70,93). Elde edilen sonuçlara göre en düşük sınıflandırma



doğruluğu biber sınıfına aittir. Biberin doğruluk oranının düşük olmasının nedeni incelenmiştir. Tablo 2.1’de verilen bitkilerin gelişim süreçlerine bakıldığında biber, mısır ve patlıcanın aynı tarihlerde ekildiği, geliştiği ve hasat edildiği görülmektedir. Ayrıca çok yıllık bir bitki olmasına rağmen yapraklarını döken üzüm de biberle benzer gelişim süreci göstermektedir. Bu nedenle biber, mısır, patlıcan ve üzüm ürünleri arasında geçişler olmuştur.

Buğday incelendiğinde 4 ( $Ort_{NDVI}$ ) ve 7 ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) no’lu özellik kombinasyonlarıyla ve RO algoritmasıyla en yüksek doğruluk değerinin hesaplandığı görülmektedir (98,86). Buğdayın en düşük doğruluk değerine sahip olduğu sınıflandırma 1 no’lu veri kombinasyonu ( $Ort_{S1}$ ) ve KA algoritmasıyla yapılan sınıflandırmadır (%92,74). Bu bağlamda buğdayın çalışmada denenen tüm veri özelliği kombinasyonları ve algoritalarda tatmin edici doğruluk değerlerine ulaştığı görülmektedir (Tablo 3.6).

Domates 7 no’lu özellik kombinasyonunda ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) DVM algoritmasıyla ve 8 no’lu özellik kombinasyonunda ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Hmj_{S2}, Kont_{S1}, Kont_{S2}, Frk_{S1}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ ) RO algoritmasıyla çalışmada elde edilen en yüksek sınıflandırma doğruluğuna ulaşmıştır (%91,31). 4 no’lu özellik kombinasyonu ( $Ort_{NDVI}$ ) ve KA algoritmasının kullanıldığı sınıflandırmada ise domates için en düşük sınıflandırma değeri hesaplanmıştır (%76,99). Bu verilerden elde edilen sonuçlara göre domatesin sınıflandırılmasında sadece NDVI bantlarının kullanımıyla yüksek doğruluk değerleri elde edilememiştir.

Mısır çalışmada kullanılan tüm bant değerlerinin bulunduğu 8 no’lu özellik kombinasyonunda ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Kont_{S1}, Kont_{S2}, Frk_{S1}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ ) RO algoritmasıyla en yüksek sınıflandırma doğruluğuna (%93,55) ulaşmıştır. Mısır yine 5 no’lu özellik kombinasyonu ( $Ort_{S2}, Ort_{NDVI}$ ) ve KA algoritmasında en düşük sınıflandırma doğruluğu (%84,87) vermiştir. Elde edilen sonuçlara göre S1 orijinal bantları ve doku bantları kullanıldığında mısırın sınıflandırma doğruluğunun arttığı görülmektedir. Ayrıca yalnız S2 ve NDVI

bantlarının KA algoritmasıyla kullanılması mısırın sınıflandırma doğruluğunu düşürmüştür.

Mısır2 yalnız NDVI bantlarının kullanıldığı 4 no'lu özellik kombinasyonunda ( $Ort_{NDVI}$ ) RO algoritmasıyla en yüksek doğruluk değerine (%99,18) ulaşmıştır. Mısır2 ayrıca tüm ürünler arasında en yüksek sınıflandırma doğruluğuna sahip üründür. 1 no'lu özellik kombinasyonunda ( $Ort_{S1}$ ) KA algoritmasıyla sınıflandırma yapıldığında ise %87,11 dengelenmiş doğruluk değeriyle en düşük sınıflandırma doğruluğu hesaplanmıştır. Bu sonuca göre mısır2 için sınıflandırma yaparken sadece NDVI bantlarının kullanımının yeterli olduğu görülmektedir.

Pamuk için hesaplanan en yüksek sınıflandırma doğruluğu (%98,53) 7 no'lu özellik kombinasyonu ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) ve RO algoritmasıyla elde edilmiştir. En düşük sınıflandırma doğruluğunu ise 2 no'lu özellik kombinasyonu ( $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$ ) ve KA algoritması vermiştir. Ayrıca S1 bantlarına doku bantlarının eklenmesi pamuk için sınıflandırma doğruluğunu düşürmüştür (Tablo 3.6).

Patlıcan için en yüksek sınıflandırma doğruluğu (%95,71) yalnız NDVI bantlarının kullanıldığı 4 no'lu veri kombinasyonu ( $Ort_{NDVI}$ ) ve RO algoritmasıyla elde edilmiştir. Patlıcanın en düşük sınıflandırma doğruluğuna (%53,43) sahip olduğu özellik kombinasyonu ve algoritma ise 2 no'lu kombinasyon ( $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$ ) ve KA algoritmasıdır. Ayrıca patlıcan 2 no'lu özellik kombinasyonu ve KA algoritmasıyla sınıflandırılan ürünler arasında en düşük doğruluk değerine sahip üründür. Tablo 3.6 incelendiğinde S1 doku bantlarının sınıflandırma doğruluğunu en olumsuz şekilde etkilediği ürünün patlıcan olduğu görülmektedir.

Tablo 16. Ürünlerin KA, RO ve DVM algoritmalarındaki dengelenmiş doğruluk değerleri.

KA, RO ve DVM Algoritmalarında Dengelenmiş Doğruluk												
	Özellik Kombinasyonu		Biber	Buğday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin
1	$Ort_{S1}$	KA	59.72	92.74	88.75	88.83	87.11	93.24	61.77	<u>94.27</u>	56.12	83.87
		RO	63.16	<u>97.71</u>	93.29	92.40	95.76	96.49	66.67	96.70	66.67	94.26
		DVM	65.67	<u>95.76</u>	89.90	92.26	94.79	95.47	54.17	96.51	66.67	94.84
2	$Ort_{S1}, Std_{S1}, Hmj_{S1},$ $Kont_{S1}, Frk_{S1}, Ent_{S1},$ $A2Mo_{S1}, Kor_{S1}$	KA	54.28	93.81	84.53	89.34	87.52	86.67	53.43	<u>94.66</u>	59.51	80.44
		RO	52.63	<u>97.64</u>	92.20	92.47	95.90	96.49	62.50	96.13	60.00	91.83
		DVM	52.63	<u>97.51</u>	93.29	92.40	95.49	96.49	62.50	96.22	60.00	92.43
3	$Ort_{S2}$	KA	65.42	96.50	85.87	92.06	<u>96.58</u>	90.69	83.21	96.52	76.61	94.79
		RO	70.50	<u>98.79</u>	94.18	92.95	97.26	97.83	62.50	97.15	66.42	95.52
		DVM	70.93	98.25	93.80	90.49	<u>98.98</u>	96.81	79.17	97.42	69.75	96.25
4	$Ort_{NDVI}$	KA	54.59	96.50	76.99	88.92	96.58	90.56	87.38	<u>97.17</u>	80.00	95.70
		RO	62.91	98.86	87.60	92.19	<u>99.18</u>	97.83	95.71	<u>97.51</u>	76.36	97.23
		DVM	57.77	98.25	83.76	87.61	<u>98.56</u>	96.49	83.33	97.33	66.42	95.65
5	$Ort_{S2}, Ort_{NDVI}$	KA	57.65	94.95	83.25	84.87	92.87	93.37	83.15	<u>93.95</u>	62.78	88.57
		RO	70.56	<u>98.05</u>	93.03	92.74	97.88	95.79	62.38	97.33	59.75	94.33
		DVM	68.30	<u>95.89</u>	89.84	90.70	91.78	95.66	83.33	94.24	60.00	92.73
6	$Ort_{S2}, Ort_{NDVI}, Std_{S2},$ $Hmj_{S2}, Kont_{S2},$ $Frk_{S2}, Ent_{S2}, A2Mo_{S2},$ $Kor_{S2}$	KA	65.36	96.50	86.96	92.13	<u>96.58</u>	88.52	83.21	96.52	76.67	94.79
		RO	63.10	<u>98.72</u>	94.12	92.95	97.54	98.28	62.50	96.96	56.42	95.26
		DVM	52.57	<u>95.97</u>	84.53	89.84	95.65	97.64	58.33	95.58	56.67	94.74
7	$Ort_{S1}, Ort_{S2}, Ort_{NDVI}$	KA	65.42	<u>97.37</u>	88.56	92.12	96.71	91.84	82.97	97.12	76.61	94.99
		RO	70.93	98.86	94.25	92.95	<u>98.98</u>	98.53	62.50	97.05	70.00	97.69
		DVM	65.67	<u>98.32</u>	94.31	93.48	98.29	97.90	83.21	97.42	83.33	96.71
8	$Ort_{S1}, Ort_{S2}, Ort_{NDVI},$ $Std_{S1}, Std_{S2}, Hmj_{S1},$ $Hmj_{S2}, Kont_{S1},$ $Kont_{S2}, Frk_{S1}, Frk_{S2},$ $Ent_{S1}, Ent_{S2}, A2Mo_{S1},$ $A2Mo_{S2}, Kor_{S1}, Kor_{S2}$	KA	51.95	97.37	86.77	91.90	96.71	92.79	82.97	96.84	70.00	94.99
		RO	63.10	<u>98.59</u>	94.31	93.55	97.54	98.40	62.50	97.33	60.00	97.89
		DVM	52.63	93.28	82.48	88.62	94.90	<u>95.79</u>	58.33	94.94	56.67	94.74

\* Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

\* Altı çizili değerler satırdaki en büyük değeri ifade etmektedir.

Üzüm de patlıcan gibi en yüksek sınıflandırma doğruluğuna (%97,51) yalnız NDVI bantlarının kullanıldığı 4 no'lu veri kombinasyonu ( $Ort_{NDVI}$ ) ve RO algoritmasıyla ulaşmıştır. Ancak üzüm diğer ürünlerden farklı olarak çalışmada denenen tüm sınıflandırmalarda %90'ın üzerinde doğruluk değerine sahiptir. Üzüm için en düşük sınıflandırma doğruluğunu (%94,27) 1 no'lu özellik kombinasyonu ( $Ort_{S1}$ ) ve KA algoritması vermiştir. Üzümün kullanılan tüm veri özelliği kombinasyonlarında sınıflandırma doğruluğundaki değişim miktarı en fazla %3 olmuştur.

Yonca en yüksek sınıflandırma doğruluğuna (%83,33) 7 no'lu özellik kombinasyonu ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}$ ) ve RO algoritmasıyla ulaşmıştır. Yonca biberden sonra bu çalışmada en düşük sınıflandırma doğruluğuna (%56,12) sahip ürün olmuştur. Bunun nedeni yoncanın yaklaşık 2-3 haftada bir hasat edilen bir ürün olmasıdır (Tablo 2.1). Dolayısıyla, görüntü çekim tarihlerinde yoncanın hasat edilmiş olması, yoncanın diğer ürünlerle karışmasını sağlamıştır. Yonca için en düşük sınıflandırma doğruluğunu veren veri özelliği kombinasyonu ve algoritma 1 no'lu kombinasyon ( $Ort_{S1}$ ) ve KA algoritmasıdır .

Zeytin 8 no'lu özellik kombinasyonu ( $Ort_{S1}, Ort_{S2}, Ort_{NDVI}, Std_{S1}, Std_{S2}, Hmj_{S1}, Hmj_{S2}, Kont_{S1}, Kont_{S2}, Frk_{S1}, Frk_{S2}, Ent_{S1}, Ent_{S2}, A2Mo_{S1}$ ) ve RO algoritmasıyla en yüksek sınıflandırma doğruluğuna (%97,89) ulaşmıştır. Zeytin için en düşük sınıflandırma doğruluğu (%80,44) ise 2 no'lu özellik kombinasyonu ( $Ort_{S1}, Std_{S1}, Hmj_{S1}, Kont_{S1}, Frk_{S1}, Ent_{S1}, A2Mo_{S1}, Kor_{S1}$ ) ve KA algoritmasıyla elde edilmiştir. Tablo 3.6 incelendiğinde S1 doku bantlarının zeytinin sınıflandırma doğruluğunu azalttığını, S2 doku bantlarının ise zeytinin sınıflandırma doğruluğunu artırdığı görülmektedir.

Çalışmada en çok ürün çeşidinin en yüksek dengelenmiş doğruluğa ulaştığı veri kombinasyonu 7 no'lu kombinasyon olmuştur. Bu kombinasyonda biber, buğday ve pamuk RO algoritmasıyla, domates ve üzüm ise DVM algoritmasıyla en yüksek dengelenmiş doğruluk değerine ulaşmıştır. Diğer taraftan, 1, 2, 5 ve 6 no'lu veri özelliği kombinasyonları hiçbir ürün için en yüksek dengelenmiş doğruluk değerini vermemiştir (Tablo 3.6).

Ayrıca en yüksek dengelenmiş doğruluğa sahip ürün, 4 no'lu veri kombinasyonunda RO algoritmasıyla hesaplanan mısır2 (%99,18) olmuştur. İkinci yüksek doğruluğa sahip ürün, 4 ve 7 no'lu veri kombinasyonunda RO algoritmasıyla hesaplanan buğday (%98,86) ve üçüncü yüksek doğruluğa sahip ürün ise 7 no'lu kombinasyonda RO algoritmasıyla hesaplanan pamuk (%98,53) ürünü olmuştur (Tablo 3.6).

## 4. SONUÇLAR

- Bu çalışmada en yüksek doğruluk oranına ( $\hat{K}$  : %91,8 ve Genel Doğruluk: %93,4) DVM algoritmasıyla ulaşılmıştır. Ancak, RO algoritmasının *Mtry* ve *Ntree* parametrelerini değiştirerek kullanıcının farklı doğruluk değerlerine ulaşabilmesini sağlayan esnekliği ve en önemli bantların tespit edilmesini sağlayan özelliği de değerlendirilirse RO algoritmasının da tarımsal ürünlerin sınıflandırılmasında kullanılabilecek etkili bir yöntem olduğu aşıkardır.
- Çalışmadan elde edilen sonuçlara göre, KA algoritmasının sınıflandırma doğruluğu RO ve DVM algoritmalarına göre daha düşüktür. Bu fark yaklaşık %4 civarında olmuştur.
- Çalışmada 8 farklı özellik kombinasyonu ve toplam 448 bant kullanılmıştır. Elde edilen sonuçlara göre, sınıflandırmada kullanılan standart sapma ve doku özellikleri değerlerinin sınıflandırma doğruluğuna olumlu katkısı olmamıştır.
- En yüksek sınıflandırma doğruluğu sonucuna, Sentinel-1 ve Sentinel-2 orijinal bantlarının NVDI indeksiyle birlikte kullandığı veri özelliği kombinasyonunda (7 nolu kombinasyon) ( $\hat{K}$  : %91,8 ve Genel Doğruluk: %93,4) ulaşılmıştır.
- Sadece Sentinel-1 SAR uydu görüntülerinin kullanıldığı sınıflandırmalarda %88,12  $\hat{K}$  ve %90,48 genel doğruluk değerlerine ulaşılmıştır. Elde edilen sonuçlar, yalnız Sentinel-1 SAR görüntülerinin kullanılmasıyla yapılacak çalışmalarda oldukça tatmin edici doğruluk değerlerine ulaşabileceğini göstermiştir. Sentinel-1 SAR görüntülerinin gece ve gündüz görüntü alabilmesi ve bulutluluktan etkilenmemesi gibi avantajları göz önüne alındığında özellikle bulutluluğun yüksek olduğu bölgelerde bu uydu görüntüleriyle tarımsal ürün deseni tespiti çalışmaları yapılabilir.

- Ayrıca, Sentinel-1 ve Sentinel-2 uydu görüntülerinin birlikte kullanıldığı 7 ve 8 no'lu veri özelliği kombinasyonlarında sınıflandırma doğruluğunda yaklaşık %2 oranında artış olmuştur.
- Elde edilen sonuçlara göre, yalnız Sentinel-2 uydu görüntülerinin 10 m konumsal çözünürlüklü bantlarıyla (mavi, yeşil, kırmızı, yakın kızıl ötesi – Tablo 2.5) tarımsal ürün tespitinde %90 doğruluk oranına, en azından bu çalışma bölgesindeki ürünler için, ulaşılabilmektedir.
- Sadece NDVI bantları kullanılarak yapılan 4 nolu veri özelliği kombinasyonunda %90,87  $\hat{K}$  ve %92,65 genel doğruluk oranları elde edilmiştir. Dolayısıyla, sadece NDVI bantları kullanılarak yüksek sınıflandırma doğruluğuna ulaşılabilmesi, sınıflandırma işlemlerinin çok daha hızlı bir şekilde yapılmasını mümkün kılmaktadır.
- Çok zamanlı uydu görüntülerinin kullanıldığı bu çalışmada, tarımsal alanların dinamik yapılarından dolayı, görüntü tarihleri seçimlerinin dikkatli yapılması gerekmektedir. Çok zamanlı görüntü sınıflandırmasında uydu görüntüleri tarihlerinin sınıflandırma doğruluğuna önemli etkisi vardır. Bu nedenle, tarımsal ürünlere ait fenolojik özellikler özenle incelenmeli ve uygun tarihler fenolojik özellikler dikkate alınarak belirlenmelidir.
- RO algoritmasının en önemli bant belirleme özelliğinden faydalanılarak çalışmada kullanılan tüm bantlar arasından en önemli bantlar belirlenmiştir. Dolayısıyla, RO algoritmasının bu özelliği ile önem derecesi düşük bantlar sınıflandırmadan çıkarılıp sınıflandırma işlemi hızlandırılabilir. Ayrıca, sınıflandırmada fazla bant kullanılmasının her zaman doğruluğu artırmayacağı da bu çalışmada tespit edilmiş olduğundan daha yüksek doğruluk değerlerine ulaşabilmek için önemsiz bantlar sınıflandırma işleminden çıkarılarak daha yüksek sınıflandırma doğruluğuna ulaşılabılır.

- Bu çalışmada en uygun segmentasyon ölçek parametre değerini belirlemek için ESP-2 yazılımı kullanılmıştır. ESP-2'nin en uygun ölçek parametresinin belirlenmesinde güvenilir sonuçlar verdiği kanaatine oluşturulan segmentler görsel olarak incelenmek suretiyle varılmıştır. Ayrıca, deneme yanılma yöntemine göre, farklı değerleri denemeye gerek bırakmadığından daha hızlıdır.
- Çalışmada arazi gerçeği verileri belirlenirken, ÇKS verilerinden de yararlanılmıştır. Elde edilen sınıflandırma sonuçlarına göre, öz nitelik bilgisi eksik veya hatalı olan ÇKS parsel verilerinin tespiti yapılabilir.



## KAYNAKLAR

- [1] FAO, How to Feed the World in 2050, *Insights from an expert meeting at FAO*, cilt 2050, **2009**.
- [2] J. Townshend, C. Justice, W. G. Li ve J. McManus, Global land cover classification by remote sensing: present capabilities and future possibilities, *Remote Sensing of Environment*, cilt 35(2-3), p. 243-255., **1991**.
- [3] J. G. Wesseling ve R. A. Fedes, Assessing crop water productivity from field to regional scale, *Agricultural Water Management*, cilt 86, no. 1, pp. 30-39, **2006**.
- [4] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo ve J. P. & Rigol-Sanchez, An assessment of the effectiveness of a random forest classifier for land-cover classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, cilt 67, p. 93-104, **2012**.
- [5] E. W. Chappelle, M. S. Kim ve J. E. McMurtrey, Ratio analysis of reflectance spectra (RARS): An algorithm for the remote estimation of the concentrations of chlorophyll A, chlorophyll B, and carotenoids in soybean leaves., *Remote Sensing of Environment*, cilt 39, p. 239-247, **1991**.
- [6] D. J. Mulla, Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps., *Biosystems Engineering*, cilt 114, pp. 358-371, **2013**.
- [7] W. Rouse, R. H. Haas, J. A. Schell ve D. W. Deering, Monitoring vegetation systems in the Great Plains with ERTS, *Proceedings of the Third Earth Resources Technology Satellite- 1 Symposium*, **1974**.
- [8] A. Bannari, D. Morin, F. Bonn ve R. A. Huete, A review of vegetation indices, *Remote Sensing Reviews*, cilt 13, pp. 95-120, **1995**.
- [9] M. Mróz ve A. Sobieraj, Comparison of several vegetation indices calculated on the basis of a seasonal SPOT XS time series, and their suitability for land cover and agricultural crop identification., *Technical Sciences*, cilt 7, pp. 39-66, **2004**.

- [10] J. Dash, A. Mathur, G. M. Foody, P. J. Curran, J. W. Chipman ve T. M. & Lillesand, Land cover classification using multi-temporal MERIS vegetation indices, *International Journal of Remote Sensing*, cilt 28, pp. 1137-1159, **2007**.
- [11] Y. Cohen, A. V, B. Campus, I. Hermann, A. Karnieli ve D. J. Bonfil, SWIR-based spectral indices for assessing nitrogen content in potato fields., *International Journal of Remote Sensing*, cilt 31, pp. 5127-5143, **2010**.
- [12] C. Ohl ve J. L. P. Van Genderen, Review article Multisensor image fusion in remote sensing: Concepts, methods and applications, *International Journal of Remote Sensing*, cilt 19, p. 823–854, **1998**.
- [13] Y. Ban, Synergy of multitemporal ERS-1 SAR and Landsat TM data for classification of agricultural crops, *Canadian Journal of Remote Sensing*, cilt 29, pp. 518-526, **2003**.
- [14] B. Brisco ve R. J. Brown, Multidate SAR/TM synergism for crop classification in western Canada, *Photogrammetric Engineering and Remote Sensing*, cilt 61, no. 8, pp. 1009-1014, **1995**.
- [15] B. Haack ve M. Bechdol, Integrating multisensor data and RADAR texture measures for land cover mapping., *Computers and Geosciences*, cilt 26, no. 4, pp. 411-421, **2000**.
- [16] J. Inglada, A. Vincent, M. Arias ve C. & Marais-Sicre, Improved early crop type identification by joint use of high temporal resolution sar and optical image time series., *Remote Sensing*, cilt 8, no. 5, **2016**.
- [17] A. H. S. Solberg, A. K. Jain ve T. Taxt, Multisource classification of remotely sensed data: fusion of Landsat TM and SAR images, *IEEE Transactions on Geoscience and Remote Sensing*, **1994**.
- [18] D. O. Fuller, Trends in NDVI time series and their relation to rangeland and crop production in Senegal, *International Journal of Remote Sensing*, cilt 19, pp. 2013-2018, **1998**.

- [19] T. Sakamoto, M. Yokozawa, H. Toritani ve M. Shibayama, A crop phenology detection method using time-series MODIS data, *Remote Sensing of Environment*, cilt 96, pp. 366-374, **2005**.
- [20] S. Karnchanasutham ve D. A. Pongsihadldchai, Assessment of ERS-1 SAR Data for Rice Crop Mapping and Monitoring. *The 16th Asian Conference Proceeding Agriculture Soil Proceeding of Agriculture*, Suranaree University of Technology, Nakhon Ratchasima, Thailand, **1995**.
- [21] S. Kaojareern, J. P. Delsol, T. L. Toan ve S. P. KAM, Assessment of Multi-temporal Radar Imagery in Mapping Land System for Rainfed Lowland Rice in Northeast Thailand., *The Asian Conference on Remote Sensing Conference*, Bangkok, Tayland, **2002**.
- [22] C. S. Murthy, P. V. Raju ve K. V. S. Badrinath, Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks, *International Journal of Remote Sensing*, cilt 24, no. 23, p. 4871–4890, **2003**.
- [23] A. Yüksel, A. E. Akay ve R. Gündoğan, Using ASTER Imagery in Land Use/cover Classification of Eastern Mediterranean Landscapes According to CORINE Land Cover Project, *Sensors*, cilt 8, no. 2, pp. 1237-1251, **2008**.
- [24] C. Yang, J. H. Everitt ve D. Murden, Evaluating high resolution SPOT 5 satellite imagery for crop identification, *Computers and Electronics in Agriculture*, no. 75, p. 347–354, **2011**.
- [25] M. Turker ve A. Ozdarici, Field-based crop classification using SPOT4, SPOT5, IKONOS and QuickBird imagery for agricultural areas: a comparison study, *International Journal of Remote Sensing*, cilt 32, no. 24, p. 9735–9768, **2011**.
- [26] P. Siqueira, Time-series classification of Sentinel-1 agricultural data over North Dakota, *Remote Sensing Letters* , cilt 9, no. 5, p. 411–420, **2018**.
- [27] O. Csillik ve M. Belgiu, Cropland Mapping from Sentinel-2 time series data using object-based image analysis, *The 20th AGILE International Conference on*

*Geographic Information Science Societal Geo-innovation Celebrating 20 years of GIS research*, Wageningen, **2017**.

- [28] X. Song, C. Yang, M. Wu, C. Zhao, G. Yang, W. C. Hoffmann ve W. Huang, Evaluation of Sentinel-2A Satellite Imagery for Mapping Cotton Root Rot, *MDPI/Remote Sensing*, **2017**.
- [29] M. Drusch, U. Del Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, C. Isola, P. Laberinti ve P. Martimort, Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services, *Remote Sensing Environment*, no. 120, p. 25–36, **2012**.
- [30] M. Yılmaz, Tarımsal Yaz Ürünlerinin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritmasıyla Nesne-Tabanlı Sınıflandırılması, Hacettepe Üniversitesi Yüksek Lisans Tezi, Ankara, **2018**.
- [31] R. Sonobe, Y. Yamaya, H. Tani, X. Wang, N. Kobayashi ve K.-i. Mochizuki, Assessing the suitability of data from Sentinel-1A and 2A for crop classification, *GIScience & Remote Sensing*, cilt 54, no. 6, pp. 918-938, **2017**.
- [32] F. Vuolo, M. N. M. Immitzer, C. Atzberger ve W.-T. Ng, How much does multi-temporal Sentinel-2 data improve crop type classification?, *International Journal Of Applied Earth Observation And Geoinformation*, cilt 72, pp. 122-130, **2018**.
- [33] T. Whelen ve a. P. Siqueira, Time-series classification of Sentinel-1 agricultural data over North Dakota, *Remote Sensing Letters*, cilt 9, no. 5, p. 411–420, **2018**.
- [34] P. Mayaux, E. Bartholomé, S. Fritz ve A. Belward, A new land cover map of Africa for the year 2000, *Journal of Biogeography*, cilt 31, pp. 861-877, **2004**.
- [35] M. Turker ve M. Arıkan, Sequential masking classification of multi-temporal Landsat7 ETM+ images for field-based crop mapping in Karacabey, Turkey, *International Journal of Remote Sensing*, cilt 26, no. 17, p. 3813–3830, **2005**.
- [36] C. Gómez, J. C. White ve M. A. Wulder, Optical remotely sensed time series data for land cover classification: a review,» *ISPRS Journal of Photogrammetry and Remote Sensing.*, no. 116, pp. 55-72, **2016**.

- [37] M. Pal, Random forest classifier for remote sensing classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, cilt 26, no. 1, pp. 217-222, **2007**.
- [38] P. Du, J. Xia, J. Chanussot ve X. He, Hyperspectral Remote Sensing Image Classification based on the Integration of Support Vector Machine and Random Forest, *International Geoscience and Remote Sensing Symposium*, pp. 174-177, **2012**.
- [39] Ö. Akar ve O. Güngör , Rastgele Orman Sınıflandırıcısına Doku Özellikleri Entegre Edilerek Benzer Spektral Özellikteki Tarımsal Ürünlerin Sınıflandırılması, Trabzon: Karadeniz Teknik Üniversitesi Doktora Tezi, **2013**.
- [40] N. Kussul , G. Lemoine, F. J. Gallego, S. V. Skakun, M. Lavreniuk ve A. Shelestov, Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, cilt 9, no. 6, pp. 2500 - 2508, **2016**.
- [41] Copernicus Open Access Hub, ESA, <https://scihub.copernicus.eu>. (Ekim, **2018**)
- [42] O. Şimsek, Y. Nadaroğlu, G.Yücel, Ö. Dokuyucu ve Ş. Gökdağ, Türkiye Fenoloji Atlası, pp. 18-103, **2014**.
- [43] ESA, [Çevrimiçi]. Available: <https://sentinel.esa.int/web/sentinel/user-guides>. (Ocak, **2019**)
- [44] ESA, <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes>. (Ocak, **2019**)
- [45] R. Safavian ve D. Landgrebe, A survey of Decision Tree Classifier Methodology, *IEEE Transactions on Systems*, cilt 21, no. Man and Cybernetics, pp. 660-674, **1991**.
- [46] S. Drazin ve M. Montag, Decision Tree analysis using WEKA, *Machine Learning-Project II*, University of Miami, **2012**.
- [47] M. M. Paul ve P. Mahesh, Decision Tree Based Classification of Remotely Sensed Data, *22nd Asian Conference on Remote Sensing*, Nottingham, **2001**.

- [48] Centre For Ecological Sciences Indian Institute of Science, <http://wgbis.ces.iisc.ernet.in/>. ( Aralık,2018)
- [49] J. R. Quinlan, Decision trees and decision making, *IEEE transactions on Systems, Man and Cybernetics*, cilt 20, pp. 339-346, **1990**.
- [50] F. Esposito, D. Malerba ve G. Semeraro, A Comparitive Analysis of Methods for Pruning Decision Trees, *EEE Transactions on Pattern Analysis and Machine Intelligence*, cilt 19, pp. 476-491, **1997**.
- [51] R. Quinlan, *C4.5: Programs for Machine Learning*, Morgan Kaufmann.,California, **1993**.
- [52] O. Maimon ve L. Rokach, Top Down Induction of Decision Trees Classifiers- A Survey, *IEEE Transactions on systems, Man and Cybernetics-Part C: Applications and Cybernetics-Part C: Applications and Reviews*, cilt 35, pp. 476-487, **2005**.
- [53] Frank, H. I. Witten ve Eibe, Data Mining: Practical machine learning tools and techniques, *Elsevier, 2nd edition*, **2005**.
- [54] L. Breiman, Random Forest, *Machine learning*, **2001**.
- [55] V. Vapnik, Estimation of Dependences Based on Empirical Data, Moscow, **1982**.
- [56] C. J. C. Burges, A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery 2*, pp. 121-167, **1998**.
- [57] C. Cortes ve V. Vapnik, Support-vector networks, *Machine Learning*, cilt 20, no. 3, p. 273–297, **1995**.
- [58] P. Mantero, G. Moser ve S. Serpico, Partially supervised classification of remote sensing images through SVM-based probability density estimation, *IEEE Transactions on Geoscience and Remote Sensing*, cilt 3, no. 43, pp. 559-570, **2005**.
- [59] G. Zhu ve D. G. Blumberg, Classification using ASTER data and SVM algorithms, The case study of Beer Sheva, Israel, *Remote Sensing of Environment*, cilt 2, no. 80, pp. 233-240, **2002**.

- [60] Z. Jiang, A. R. Huete, J. Chen, J. Li ve G. Yan, Analysis of NDVI and scaled difference vegetation index retrivals of vegetation fraction, *Remote Sensing of Environment*, pp. 366-378, **2006**.
- [61] T. Blaschke ve J. Strobl, What's wrong with pixels? Some recent development interfacing remote sensing and GIS, *GeoBIT/GIS*, no. 14, pp. 12-17, **2001**.
- [62] A. P. Carleer ve E. Wolff, Region-based classification potential for land-cover classification with very high spatial resolution satellite data, *Proceedings of 1st International Conference on Object-based Image Analysis*, Salzburg University, Austria, **2006**.
- [63] T. Blaschke, Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, no. 65, pp. 2-16, **2010**.
- [64] A. K. Shackelford ve C. H. Davis, A combined fuzzy pixel-based and object-based approach for classification of high resolution multispectral data over urban areas., *IEEE Xplore: IEEE Transactions on Geoscience and Remote Sensing*, no. 41, pp. 2354-2364., **2003**.
- [65] M. Baatz, U. Benz, S. Dehghani, M. Heynen, A. Holtje, P. Hofmann, I. Lingenfelder, M. Mimler, M. Sohlbach ve W. M., e-Cognition Professional User Guide, Munich: Definiens Imaging Gmbh, **2004**.
- [66] M. Baatz ve A. Schape, Multiresolution segmentation: an optimization approach for high quality multi-scale image seg-mentation, *Angewandte Geographische Informations- VerarbeitungXII.*, Karlsruhe, Germany, **2000**.
- [67] C. Benz, P. Hofmann, G. Willhauck, I. Lingenfelder ve M. Heynen, Multi-resolution, object oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS J Photogram*, no. 58, pp. 239-258, **2004**.
- [68] L. Dragut, O. Csillik, C. Eisank ve D. Tiede, Automated parameterisation for multi-scale image segmentation on multiple layers, *ISPRS Journal of Photogrammetry and Remote Sensing*, **2014**.

- [69] J. M. Peña-Barragán, M. K. Ngugi, R. E. Plant ve J. Six, Object-based crop identification using multiple vegetation indices, textural features and crop phenology, *Remote Sensing of Environment*, **2011**.
- [70] J. M. Peña, P. A. Gutiérrez, C. Hervás-Martínez, J. Six, R. E. Plant ve F. López-Granados, Object-Based Image Classification of Summer Crops with Machine Learning Methods, *Remote Sensing*, no. 6, pp. 5019-5041, **2014**.
- [71] C. Tarantino, A. D'Addabbo, L. Castellana, P. Blonda, G. Pasquariello, N. Ancona ve G. Satalino, Neural network ensemble and support vector machine classifiers: an Application to remote sensed data, *Fuzzy Logic and Applications Lecture Notes in Artificial Intelligence*, no. 2955, pp. 317-323, **2006**.
- [72] R. V. Platt ve A. F. H. Goetz, A comparison of AVIRIS and synthetic Landsat data for land use classification at the urban fringe, *Photogrammetric Engineering and Remote Sensing*, no. 70, pp. 813-819, **2004**.
- [73] I. H. Witten ve E. and Frank, Data Mining: Practical machine learning tools and techniques 2nd Edition, San Francisco: Morgan Kaufmann, **2005**.
- [74] C.-C. Chang ve C.-J. and Lin, LIBSVM: “A Library for Support Vector Machines”, <http://www.csie.ntu.edu.tw/~cjlin/libsvm>., **2011**.
- [75] D. R. Velez, B. C. W. White, A. A. Motsinger, W. S. Bush, M. D. Ritchie, S. M. Williams ve J. H. Moore, A balanced accuracy function for epistasis modeling in imbalanced datasets using multifactor dimensionality reduction, *Genetic Epidemiology*, cilt 31, no. 4, pp. 306-315, **2007**
- [76] I. Howson, R Package Documentation, <https://rdr.io/cran/caret> (Temmuz, **2019**)
- [77] K. Jia, S. Liang, N. Zhang, X. Wei, X. Gu, X. Zhao, Y. Yao ve X. Xie, Land cover classification of finer remote sensing data integrating temporal features from time series coarser resolution data, *ISPRS Journal of Photogrammetry and Remote Sensing*, cilt 93, pp. 49-55, **2014**.



- [78] S. Foerster, K. Kaden, M. Foerster ve S. Itzerott, Crop type mapping using spectral–temporal profiles and phenological information, *Computers and Electronics in Agriculture*, cilt 89, pp. 30-40, **2012**.
- [79] N. Matton, G. S. Canto, F. Waldner, S. Valero, J. Morin, D. Í. Inglada, M. Arias, S. Bontemps, B. Koetz ve P. Defourny, An Automated Method for Annual Cropland Mapping along the Season for Various Globally-Distributed Agrosystems Using High Spatial, **2015**.
- [80] J. Xiong, P. S. Thenkabail, M. K. Gumma, P. Teluguntla, J. Poehnelt, R. G. Congalton, K. Yadav ve D. Thau, Automated cropland mapping of continental Africa using Google Earth Engine cloud computing, *ISPRS Journal of Photogrammetry and Remote Sensing*, cilt 126, **2017**.
- [81] J. Radoux, C. Lamarche, E. Van Bogaert, S. Bontemps, B. C ve P. Defourny, Automated training sample extraction for global land cover mapping, *Remote Sensing*, cilt 6, p. 3965–3987., **2014**.
- [82] L. Breiman, Random forests—random features, Technical Report 567, Statistics Department, University of California, Berkeley., **1999**.

## 5. EKLER


Ek Tablo 1. S1 orijinal bantlar , KA algoritması kullanılarak elde edilen doğruluk analizi  
(Toplam : 16 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	4	0	0	1	2	2	7	1	0	0
buğday	0	80	0	1	3	0	0	0	0	0
domates	0	0	36	5	0	1	0	0	0	0
mısır	1	4	2	99	6	0	0	0	7	0
mısır2	0	1	1	9	70	1	0	0	1	7
pamuk	0	1	0	0	6	43	1	1	1	0
patlıcan	5	0	0	1	0	1	3	4	1	0
üzüm	9	1	6	6	3	1	1	280	2	20
yonca	0	4	0	1	1	0	0	0	2	3
zeytin	0	2	1	0	0	0	0	1	1	65
Genel Doğruluk: %82,17										
Kappa: %77,75										

Ek Tablo 2. S1 orijinal bantlar, RO algoritması kullanılarak elde edilen doğruluk analizi  
(Toplam : 16 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	5	0	0	0	0	0	0	0	0	0
buğday	0	90	0	1	3	0	0	0	5	1
domates	0	0	40	1	0	2	0	0	0	0
mısır	0	0	2	105	1	0	0	0	1	0
mısır2	1	0	1	9	85	1	0	0	1	1
pamuk	0	0	0	0	0	46	7	0	0	0
patlıcan	0	0	0	0	0	0	4	0	0	0
üzüm	13	2	3	5	1	0	1	286	1	8
yonca	0	0	0	0	0	0	0	0	5	0
zeytin	0	1	0	2	1	0	0	1	2	85
Genel Doğruluk : %90,48										
Kappa: %88,12										

Ek Tablo 3. S1 orijinal bantlar, RO algoritması kullanılarak elde edilen en önemli bantlar  
(Toplam : 16 Bant).



Ek Tablo 4. S1 orijinal bantlar, DVM algoritması kullanılarak elde edilen doğruluk analizi  
(Toplam : 16 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	6	0	0	0	0	2	0	0	0	0
buğday	0	86	0	0	5	0	0	0	1	1
domates	0	0	37	3	0	2	0	0	0	0
mısır	0	0	5	105	0	0	0	0	1	0
mısır2	0	2	1	8	83	0	0	0	1	0
pamuk	0	0	0	0	0	45	7	0	0	0
patlıcan	0	0	0	0	0	0	1	0	0	0
üzüm	13	1	3	6	2	0	4	286	0	7
yonca	0	0	0	0	0	0	0	0	5	0
zeytin	0	4	0	1	1	0	0	1	7	87
Genel Doğruluk : %89,28										
Kappa: %86,60										


Ek Tablo 5. S1 orijinal bantlar + standart sapma + S1 doku, KA algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 128 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	2	2	0	2	1	4	0	5	0	2
buğday	0	82	0	1	3	0	0	0	0	0
domates	0	0	32	2	0	1	0	0	0	1
mısır	5	4	5	102	7	1	1	0	7	0
mısır2	0	1	1	6	71	1	0	4	1	8
pamuk	2	0	0	0	7	37	7	0	1	0
patlıcan	2	0	2	1	0	5	1	0	1	1
üzüm	8	1	2	6	0	0	3	278	0	21
yonca	0	3	0	1	1	0	0	0	3	3
zeytin	0	0	4	2	1	0	0	0	2	59
Genel Doğruluk : %80,36										
Kappa: %75,55										

Ek Tablo 6. S1 orijinal bantlar + standart sapma + S1 doku, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 128 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	1	0	0	0	0	0	0	0	0	0
buğday	0	90	0	0	5	0	0	0	5	1
domates	0	0	39	1	0	2	0	0	0	0
mısır	0	0	1	105	0	0	0	0	2	0
mısır2	0	2	2	11	86	1	0	0	3	1
pamuk	0	0	0	0	0	46	7	0	0	0
patlıcan	0	0	0	0	0	0	3	0	0	0
üzüm	18	1	3	4	0	0	2	287	1	13
yonca	0	0	0	0	0	0	0	0	3	0
zeytin	0	0	1	2	0	0	0	0	1	80
Genel Doğruluk : %89,16										
Kappa: %86,41										

Ek Tablo 7. S1 orijinal bantlar + standart sapma + S1 doku, RO algoritması kullanılarak elde edilen en önemli 30 bant (Toplam : 128 Bant).



Ek Tablo 8. S1 orijinal bantlar + standart sapma + S1 doku, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 128 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	1	0	0	0	0	0	0	0	0	0
buğday	0	90	0	0	6	0	0	0	6	1
domates	0	0	40	1	0	2	0	0	0	0
mısır	0	0	2	105	0	0	0	0	2	0
mısır2	0	2	1	11	85	1	0	0	2	1
pamuk	0	0	0	0	0	46	7	0	0	0
patlıcan	0	0	0	0	0	0	3	0	0	0
üzüm	18	1	3	4	0	0	2	287	1	12
yonca	0	0	0	0	0	0	0	0	3	0
zeytin	0	0	0	2	0	0	0	0	1	81
Genel Doğruluk : %89,28										
Kappa: %86,56										


Ek Tablo 9. S2 orijinal bantlar, KA algoritması kullanılarak elde edilen doğruluk analizi  
(Toplam : 32 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	6	0	0	3	0	1	1	0	1	0
buğday	0	87	0	0	3	0	0	0	0	1
domates	3	0	34	9	0	2	0	0	0	3
mısır	0	0	1	104	0	0	0	0	2	0
mısır2	0	2	0	0	86	2	0	0	4	2
pamuk	1	0	1	0	0	40	0	0	0	0
patlıcan	0	0	0	0	0	2	8	0	0	0
üzüm	9	2	10	5	0	2	3	285	0	3
yonca	0	0	0	1	0	0	0	0	8	0
zeytin	0	2	0	1	2	0	0	2	0	86
Genel Doğruluk : %89,64										
Kappa: %87,10										

Ek Tablo 10. S2 orijinal bantlar, RO algoritması kullanılarak elde edilen doğruluk analizi  
(Toplam : 32 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	12	0	0	0	0	2	1	3	0	0
buğday	0	91	0	0	1	0	0	1	0	1
domates	0	0	47	0	0	0	0	0	0	0
mısır	0	0	2	119	0	0	0	2	0	0
mısır2	0	0	0	0	91	0	0	0	1	0
pamuk	0	0	0	0	1	46	1	0	0	1
patlıcan	0	0	0	0	0	1	9	2	0	0
üzüm	1	1	0	1	0	0	0	281	0	2
yonca	0	0	0	0	1	0	0	0	13	1
zeytin	0	1	0	0	1	0	0	2	0	90
Genel Doğruluk : %91,81										
Kappa: %89,80										

Ek Tablo 11. S2 orijinal bantlar, RO algoritması kullanılarak elde edilen en önemli 30 bant  
(Toplam : 32 bant).




Ek Tablo 12. Yalnız NDVI Bantları, KA algoritması kullanılarak elde edilen doğruluk  
analizi (Toplam : 8 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	2	0	2	3	0	4	1	0	1	0
buğday	0	87	0	0	3	0	0	0	0	1
domates	3	0	26	15	0	2	0	0	0	0
mısır	0	0	13	98	0	0	0	0	0	0
mısır2	0	1	0	1	86	2	0	0	4	2
pamuk	4	0	0	0	0	40	0	0	0	0
patlıcan	1	0	0	0	0	1	9	0	0	0
üzüm	9	2	4	5	0	0	2	285	1	4
yonca	0	0	0	0	0	0	0	0	9	0
zeytin	0	3	1	1	2	0	0	2	0	88
Genel Doğruluk : %87,95										
Kappa: %85,03										

Ek Tablo 13. Yalnız NDVI Bantları, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 8 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	12	0	0	0	0	3	1	2	0	0
buğday	0	92	0	0	1	0	0	1	0	0
domates	0	0	44	3	0	0	0	0	0	0
mısır	0	0	6	116	0	0	0	1	0	0
mısır2	0	1	0	0	89	0	0	0	2	0
pamuk	1	0	0	0	1	45	1	0	0	1
patlıcan	2	0	0	0	0	0	9	1	0	0
üzüm	1	1	0	2	0	0	0	280	0	2
yonca	0	0	0	1	1	0	0	1	11	1
zeytin	0	2	1	0	0	0	0	2	0	89
Genel Doğruluk : %92,65										
Kappa: %90,87										

Ek Tablo 14. S2 Orijinal Bantlar, RO algoritması kullanılarak elde edilen en önemli 8 bant (Toplam : 8 bant).





Ek Tablo 15. Yalnız NDVI Bantları, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 8 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	3	0	0	0	0	1	1	0	0	0
buğday	0	90	0	0	1	0	0	0	0	1
domates	0	0	32	16	0	0	0	0	0	0
mısır	0	0	11	96	0	0	1	0	8	0
mısır2	0	1	0	1	89	2	0	0	1	0
pamuk	6	0	0	0	0	46	1	0	0	0
patlıcan	0	0	0	0	0	0	8	0	0	0
üzüm	6	1	3	10	0	0	1	287	1	7
yonca	4	0	0	0	0	0	0	0	5	0
zeytin	0	1	0	0	1	0	0	0	0	87
Genel Doğruluk : %89,52										
Kappa: %86,95										


Ek Tablo 16. S2 orijinal bantlar+NDVI bantları, KA algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 40 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	3	0	2	0	0	1	1	0	0	0
buğday	0	86	0	1	8	0	0	0	1	9
domates	1	0	31	2	0	0	0	1	3	0
mısır	0	0	7	87	0	0	0	0	0	0
mısır2	4	4	1	3	80	2	0	0	2	0
pamuk	4	0	1	2	0	43	1	0	0	0
patlıcan	0	0	0	0	0	1	8	0	2	0
üzüm	7	1	4	17	0	2	2	275	1	9
yonca	0	0	0	6	2	0	0	0	4	1
zeytin	0	2	0	5	1	0	0	11	2	76
Genel Doğruluk : %83,49										
Kappa: %79,46										

Ek Tablo 17. S2 orijinal bantlar+NDVI bantları, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 40 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	8	0	0	0	0	1	7	0	0	0
buğday	0	90	0	0	3	0	0	0	2	0
domates	0	0	40	7	0	0	0	0	0	0
mısır	0	0	0	106	0	0	0	0	5	0
mısır2	0	0	1	3	88	1	0	0	1	1
pamuk	1	0	1	0	0	45	0	0	0	0
patlıcan	0	0	0	0	0	2	3	0	0	0
üzüm	6	1	3	7	0	0	2	287	1	9
yonca	4	0	0	0	0	0	0	0	3	0
zeytin	0	2	1	0	0	0	0	0	3	85
Genel Doğruluk : %90,96										
Kappa: %88,75										

Ek Tablo 18. S2 orijinal bantlar+NDVI bantları, RO algoritması kullanılarak elde edilen En Önemli 30 Bant (Toplam : 40 bant).



Ek Tablo 19. S2 orijinal bantlar+NDVI bantları, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 40 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	7	0	0	0	0	0	2	0	0	0
buğday	0	88	0	5	13	0	0	0	1	2
domates	0	0	37	5	0	0	0	1	0	0
mısır	0	0	2	101	0	0	0	0	3	0
mısır2	4	2	1	0	78	2	0	0	7	0
pamuk	2	0	1	1	0	45	0	0	0	0
patlıcan	0	0	0	0	0	0	8	0	0	0
üzüm	6	2	5	11	0	2	1	274	1	10
yonca	0	0	0	0	0	0	0	0	3	0
zeytin	0	1	0	0	0	0	1	12	0	83
Genel Doğruluk : %87,23										
Kappa: %84,11										


Ek Tablo 20. S2 orijinal bantlar+S2 standart sapma+S2 doku, KA algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 256 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	6	0	0	5	0	0	1	0	1	0
buğday	0	87	0	0	3	0	0	0	0	1
domates	1	0	35	7	0	5	1	0	0	3
mısır	0	0	0	104	0	0	0	0	2	0
mısır2	0	3	0	0	86	2	0	0	3	2
pamuk	3	0	1	0	0	38	0	0	0	0
patlıcan	0	0	0	0	0	2	8	0	0	0
üzüm	9	2	10	6	0	2	2	285	0	3
yonca	0	0	0	0	0	0	0	0	8	0
zeytin	0	1	0	1	2	0	0	2	1	86
Genel Doğruluk : %89,52										
Kappa: %86,95										

Ek Tablo 21. S2 orijinal bantlar+S2 standart sapma+S2 doku, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 256 bant).

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	5	0	0	0	0	0	1	0	0	0
buğday	0	91	0	0	3	0	0	0	0	0
domates	0	0	41	7	0	0	0	0	0	0
mısır	0	0	0	106	0	0	0	0	2	0
mısır2	0	0	1	4	88	1	0	0	6	0
pamuk	4	0	1	0	0	48	6	0	0	0
patlıcan	0	0	0	0	0	0	3	0	0	0
üzüm	6	2	3	6	0	0	2	287	5	9
yonca	4	0	0	0	0	0	0	0	2	0
zeytin	0	0	0	0	0	0	0	0	0	86
Genel Doğruluk : %91,20										
Kappa: %89,03										

Ek Tablo 22. S2 orijinal bantlar+S2 standart sapma+S2 doku, RO algoritması kullanılarak elde edilen en önemli 30 bant (Toplam : 256 bant).



Ek Tablo 23. S2 orijinal bantlar+S2 standart sapma+S2 doku, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 256 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	1	0	0	0	0	0	1	0	0	0
buğday	0	86	0	0	3	0	0	0	0	1
domates	0	0	32	4	0	0	0	0	0	0
mısır	0	0	0	98	0	0	0	0	0	0
mısır2	7	5	5	12	88	2	1	0	7	1
pamuk	3	0	2	0	0	47	0	0	0	0
patlıcan	0	0	0	0	0	0	2	0	0	0
üzüm	8	2	7	9	0	0	8	287	6	8
yonca	0	0	0	0	0	0	0	0	2	0
zeytin	0	0	0	0	0	0	0	0	0	85
Genel Doğruluk : %87,71										
Kappa: %84,56										


Ek Tablo 24. S1 ve S2 orijinal bantlar+ NDVI, KA algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 56 bant).

Tahmin	biber	buğday	domates	mısır	mısır2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	6	0	0	0	0	2	2	1	1	0
buğday	0	89	0	0	5	0	0	0	1	1
domates	3	0	37	14	0	2	1	4	0	2
mısır	2	0	4	105	0	0	0	0	2	0
mısır2	0	2	0	0	86	2	0	0	2	2
pamuk	0	0	0	0	0	41	0	0	0	0
patlıcan	3	0	1	0	0	2	8	0	0	0
üzüm	5	2	4	2	0	0	1	280	0	4
yonca	0	0	0	1	0	0	0	0	8	0
zeytin	0	0	0	1	0	0	0	2	1	86
Genel Doğruluk : %89,88										
Kappa: %87,51										

Ek Tablo 25. S1 ve S2 orijinal bantlar+ NDVI, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 56 bant).

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	8	0	0	1	0	0	1	0	0	0
buğday	0	91	0	0	1	0	0	0	0	0
domates	0	0	41	5	0	0	0	0	0	0
mısır	0	0	0	106	0	0	0	0	2	0
mısır2	0	0	1	3	90	1	0	0	2	0
pamuk	1	0	0	0	0	48	6	0	0	0
patlıcan	0	0	0	0	0	0	3	0	0	0
üzüm	10	2	4	8	0	0	2	287	2	4
yonca	0	0	0	0	0	0	0	0	6	0
zeytin	0	0	0	0	0	0	0	0	3	91
Genel Doğruluk : %92,89										
Kappa: %91,14										

Ek Tablo 26. S1 ve S2 orijinal bantlar+NDVI, RO algoritması kullanılarak elde edilen en önemli 30 bant (Toplam : 56 bant).



Ek Tablo 27. S1 ve S2 orijinal bantlar+NDVI, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 56 bant).

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	6	0	0	0	0	1	1	0	0	0
buğday	0	90	0	0	1	0	0	0	0	0
domates	0	0	41	4	0	0	0	0	0	0
mısır	0	0	1	108	0	0	0	0	4	1
mısır2	0	1	1	5	89	1	0	0	1	0
pamuk	1	0	0	0	0	47	0	0	0	0
patlıcan	2	0	0	0	0	0	8	0	0	0
üzüm	10	1	3	6	0	0	3	287	0	5
yonca	0	0	0	0	0	0	0	0	10	0
zeytin	0	1	0	0	1	0	0	0	0	89
Genel Doğruluk : %93,37										
Kappa: %91,75										


Ek Tablo 28. S1 ve S2 orijinal bantlar+NDVI+S1 ve S2 standart sapma+S1 ve S2 doku, KA algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 448 bant).

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	1	0	2	3	0	2	2	1	1	0
buğday	0	89	0	0	5	0	0	0	1	1
domates	2	0	35	11	0	1	1	3	0	2
mısır	2	0	4	105	0	0	1	0	2	2
mısır2	0	1	0	0	86	2	0	0	3	2
pamuk	1	0	0	0	0	42	0	0	0	0
patlıcan	3	0	1	0	0	2	8	0	0	0
üzüm	10	2	4	3	0	0	0	281	2	2
yonca	0	0	0	0	0	0	0	0	6	0
zeytin	0	1	0	1	0	0	0	2	0	86
Genel Doğruluk : %89,04										
Kappa: %86,42										

Ek Tablo 29. S1 ve S2 orijinal bantlar+NDVI+S1 ve S2 standart sapma+S1 ve S2 doku, RO algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 448 bant)

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	5	0	0	0	0	0	1	0	0	0
buğday	0	91	0	0	3	0	0	0	1	1
domates	0	0	41	4	0	0	0	0	0	0
mısır	0	0	0	108	0	0	0	0	5	0
mısır2	0	0	1	6	88	1	0	0	4	0
pamuk	3	0	0	0	0	48	6	0	0	0
patlıcan	0	0	0	0	0	0	3	0	0	0
üzüm	11	2	4	5	0	0	2	287	2	3
yonca	0	0	0	0	0	0	0	0	3	0
zeytin	0	0	0	0	0	0	0	0	0	91
Genel Doğruluk : %92,17										
Kappa: %90,24										

Ek Tablo 30. S1 ve S2 orijinal bantlar+NDVI+S1 ve S2 Standart Sapma+S1 ve S2 doku, RO algoritması kullanılarak elde edilen en önemli 30 bant (Toplam : 432 bant)





Ek Tablo 31. S1 ve S2 orijinal bantlar+ NDVI+S1 ve S2 standart sapma+S1 ve S2 doku, DVM algoritması kullanılarak elde edilen doğruluk analizi (Toplam : 448 bant)

Tahmin	biber	buğday	domates	mısır	mısır 2	pamuk	patlıcan	üzüm	yonca	zeytin
biber	1	0	0	0	0	0	0	0	0	0
buğday	0	81	0	0	3	0	0	0	0	1
domates	0	0	30	2	0	0	0	0	0	0
mısır	0	0	0	95	0	0	0	0	0	0
mısır2	8	10	4	17	88	1	1	0	8	2
pamuk	2	0	0	0	0	45	0	0	0	0
patlıcan	0	0	0	0	0	0	2	0	0	0
üzüm	8	2	12	9	0	3	9	287	5	7
yonca	0	0	0	0	0	0	0	0	2	0
zeytin	0	0	0	0	0	0	0	0	0	85
Genel Doğruluk : %86,27										
Kappa: %82,69										



HACETTEPE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
YÜKSEK LİSANS/~~DOKTORA~~ TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ  
GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 08/02/2019

Tez Başlığı: SENTİNEL-1 VE SENTİNEL-2 VERİLERİNDEN TARIMSAL ÜRÜN SINIFLANDIRMASI İÇİN MAKİNE ÖĞRENME ALGORİTMALARININ KARŞILAŞTIRILMASI

Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam 88 sayfalık kısmına ilişkin, 08/02/2019 tarihinde tez danışmanım tarafından *Turnitin* adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 2 'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

08/02/2019

Adı Soyadı: TİMUÇİN DİZDAROĞLU

Öğrenci No: N16127645

Anabilim Dalı: GEOMATİK MÜHENDİSLİĞİ

Programı: GEOMATİK

Statüsü:  Y.Lisans  Doktora  Bütünleşik Dr.

**DANIŞMAN ONAYI**

UYGUNDUR.

Prof. Dr. Mustafa TÜRKER

## ÖZGEÇMİŞ

### Kimlik Bilgileri

Adı Soyadı : Timuçin DİZDAROĞLU  
Doğum Yeri : ANTALYA  
Medeni Hali : EVLİ  
E-Posta : timucindizdaroglu@gmail.com

### Eğitim Bilgileri

Lisans : Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği  
Bölümü

Yabancı Dil ve Düzeyi

İngilizce (İyi), Almanca (Orta)

İş Deneyimi

2010-2011 : Akropol Mühendislik/ Proje Mühendisi  
2011-2012 : Çeşitli Firmalarda / Gayrimenkul Değerleme Uzm. Yrd.  
2012 -2018 : Orman ve Su İşleri Bakanlığı / Orman ve Su İşleri Uzmanı  
2018-.... : Tarım ve Orman Bakanlığı / Tarım ve Orman Uzmanı

### Deneyim Alanları

İleri düzeyde CAD (Netcad, Autocad, Microstation)  
İleri düzeyde GIS uygulamaları (Qgis, ArcGIS)  
İleri Düzeyde Uzaktan Algılama Yazılımları ( ERDAS, e-Cognition, ENVI)  
Proje Yönetimi (Ms Office yazılımları)  
Orta düzeyinde programlama (R, MATLAB)