

**TARIMSAL YAZ ÜRÜNLERİN SENTİNEL-2 UYDU
GÖRÜNTÜLERİNDEN RASTGELE ORMAN
ALGORİTMASI İLE NESNE-TABANLI
SINIFLANDIRILMASI**

**OBJECT-BASED CLASSIFICATION OF SUMMER CROPS
FROM SENTINEL-2 SATELLITE IMAGES USING
RANDOM FOREST ALGORITHM**

MESUT YILMAZ

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.

2018

MESUT YILMAZ' in hazırladığı “**Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması ile Nesne-Tabanlı Sınıflandırılması**” adlı bu çalışma aşağıdaki jüri tarafından **GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI'** nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Utku KANOĞLU
Başkan

.....*U. Kanoğlu*.....

Prof. Dr. Mustafa TÜRKER
Danışman

.....*M. Türker*.....

Doç. Dr. Selim L. SANİN
Üye

.....*S. Sanin*.....

Dr. Öğretim Üyesi Metin NOHUTCU
Üye

.....*M. Nohutcu*.....

Dr. Öğretim Üyesi Gonca OKAY AHI
Üye

.....*G. Okay Ahi*.....

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

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU
Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin / raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma ama 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 kullanılması zorunlu metinlerin yazılı izin alınarak 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 haricinde YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- o Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. ⁽¹⁾
- o Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren Ay ertelenmiştir. ⁽²⁾
- o Tezimle ilgili gizlilik kararı verilmiştir. ⁽³⁾

06 /08 /2018

Mesut YILMAZ

“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

- (1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. Şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü ve fakülte yönetim kurulunun gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, tezin yapıldığı kurum tarafından verilir*. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, ilgili kurum ve kuruluşun önerisi ile enstitü veya fakültenin uygun görüşü üzerine üniversite yönetim kurulu tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.
Madde 7. 2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

* Tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu tarafından karar verilir.

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 tahrifat yapmadığımı,
 - ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı
- beyan ederim.

28/07/2018

MESUT YILMAZ

ÖZET

TARIMSAL YAZ ÜRÜNLERİN SENTİNEL-2 UYDU GÖRÜNTÜLERİNDEN RASTGELE ORMAN ALGORİTMASI İLE NESNE-TABANLI SINIFLANDIRILMASI

Mesut YILMAZ

Yüksek Lisans, Geomatik Mühendisliği Bölümü

Tez Danışmanı: Prof. Dr. Mustafa TÜRKER

Temmuz 2018, 94 Sayfa

Bu tez çalışmasında, Gediz ovasında tarımsal yaz ürünleri, 2017 yılına ait çok zamanlı Sentinel-2 uydu görüntülerinden Rastgele Orman (RO) algoritması ile nesne-tabanlı sınıflandırma yapılarak tespit edilmiştir. Tespit edilen ürünler Gediz ovasında yoğun biçimde bulunan biber, buğday, domates, mısır, patlıcan, pamuk, üzüm, yonca ve zeytindir. Arazi gerçeği verileri yapılan arazi çalışmalarından ve çiftçi kayıt sistemi (ÇKS) verisi kullanılarak oluşturulmuştur. ÇKS verileri parsel parsel incelenmiş ve arazi çalışmaları ile doğrulanmıştır. Sınıflandırma işlemi RO algoritması ile segment tabanlı yapılmıştır.

Çalışma alanını kapsayan 8 uydu görüntüsü (10 Nisan, 3 Mayıs, 2 Haziran, 2 Temmuz, 1 Ağustos, 7 Eylül, 10 Ekim ve 16 Kasım) seçilmiştir. Seçilen her uydu görüntüsünden NDVI (Normalized Difference Vegetation Index–Normalleştirilmiş Fark Bitki İndeksi) bantları üretilmiştir. Sınıflandırma işleminden önce, orijinal bantlar (Mavi, Yeşil, Kırmızı ve Yakın Kızılötesi) ve NDVI bantları kullanılarak çoklu çözünürlük görüntü segmentasyonu yapılmıştır. Sonra, her görüntü segmenti için spektral özellikler olan ortalama ve standart sapma ile doku ölçümü özellikleri olan homojenlik, farklılık ve entropi değerleri hesaplanarak bu özellikleri gösteren bantlar oluşturulmuştur. Orijinal bantlar, NDVI bantları ve özellik bantları kullanılarak nesne-tabanlı RO sınıflandırma işlemi yapılmıştır. Çalışmada ayrıca, en önemli dört özellik (bant), RO algoritmasının en önemli özellik fonksiyonu ile

Mayıs, Temmuz, Eylül ve Ekim NDVI görüntüleri olarak tespit edilmiş olup sınıflandırma işlemleri söz konusu dört özelliğin farklı kombinasyonları ile de gerçekleştirilmiştir.

Elde edilen sonuçlara göre, doku ve standart sapma bantları sınıflandırma doğruluğunu artırmamış, aksine, az miktarda da olsa, düşürmüştür. En yüksek doğruluğa sahip olan özellik kombinasyonu, 0,9365 $\hat{K}$ (Khat-Kappa) değeri ile Orijinal bantlar + NDVI bantlarıdır. En önemli 4 özellik ile yapılan sınıflandırma sonucunda 0,9156 $\hat{K}$ değerine ulaşılmıştır. Tek tarihle yapılan sınıflandırmalarda, en önemli üç özellik olan Mayıs, Temmuz ve Eylül NDVI bantları kullanılmıştır. Bu tarihler için $\hat{K}$ değerleri sırasıyla 0,5865, 0,6349, 0,5738 olarak hesaplanmıştır. En önemli üç özelliğin ikili kombinasyonları ile yapılan sınıflandırmalar neticesinde $\hat{K}$ değerleri, Mayıs - NDVI ile Temmuz - NDVI için 0,7678, Mayıs - NDVI ile Eylül - NDVI için 0,8628 ve Temmuz - NDVI ile Eylül - NDVI için 0,8452 olarak hesaplanmıştır. RO algoritmasında doğrulama için kullanılan Genelleştirilmiş Hatalar (Out of Bag – OOB) verisi rastgele seçildiği için diğer parametreler aynı bile olsa, yapılan her sınıflandırma işleminde doğruluk değişebilmektedir. Ayrıca, RO algoritmasının iki parametresi olan ağaç sayısı (*ntree*) ve rastgele özellik sayısı (*mtry*) sınıflandırma doğruluğunu etkilemektedir. Tüm bu değişkenler içinde en yüksek doğruluğu elde etmek için R programında bir uygulama (En Yüksek Doğruluklu Rastgele Orman–EYDRO) hazırlanarak RO algoritmasının doğruluğu artırılmıştır. Doğruluk artış oranı bant kombinasyonuna göre değişmekle birlikte yaklaşık %3 oranına kadar çıkmıştır.

Anahtar Kelimeler: Rastgele Orman, Tarımsal Ürün, Doku Çıkarımı, Görüntü Sınıflandırma, Nesne-Tabanlı

ABSTRACT

OBJECT-BASED CLASSIFICATION OF SUMMER CROPS FROM SENTINEL-2 SATALLITE IMAGES USING RANDOM FOREST ALGORITHM

Mesut YILMAZ

Master of Science, Department of Geomatics Engineering

Supervisor: Prof. Dr. Mustafa TÜRKER

July 2018, 94 Pages

In this thesis, the summer crops of the Gediz Plain have been detected using object-based classification with random forest (RF) algorithm from the multi-date Sentinel-2 satellite images of the year 2017. The detected crops are pepper, corn, eggplant, wheat, tomato, cotton, grapes, clover and olive that heavily exist in Gediz Plain. The ground truth data were collected through field works as well as using the farmer registration system (FRS). The FRS data have been checked parcel by parcel and confirmed with the fieldworks. The classification process using RF algorithm was carried out as segment based.

8 satellite images (April 10th, May 3rd, June 2nd, July 2nd, August 1st, September 7th, October 10th and November 16th), covering the study area were selected. Normalized Difference Vegetation Index (NDVI) bands were generated from each of the selected satellite images. Before the classification process, multi resolution image segmentation was carried out using the original bands (Blue, Green, Red and Near Infrared) and the NDVI bands. Then, for each image segment, the spectral features mean and standard deviation and texture measurements homogeneity, difference, and entropy were generated. Object based RF classification was carried out using the original bands, NDVI bands and feature bands. Furthermore, the NDVI images of May, July, September, and October were determined as the most important four features by using the variable importance function of the RF

algorithm and the classification processes were carried out with different combinations of these four features.

Based on the achieved results, texture and standard deviation bands did not increase the accuracy of classification, on the contrary, it decreased in small quantities. The combination of features, which has the highest $\hat{K}$ (Khat-Kappa) value of 0.9365 were the original bands + NDVI bands. The $\hat{K}$ value of 0.9156 was calculated as a result of the classification with the most important four features. The most important three features May, July, and September NDVI bands were used in the single-date classifications. For these dates, the $\hat{K}$ values were computed as 0.5865, 0.6349 and 0.5738, respectively. As a result of the classification of the most important three features with their binary combinations, the $\hat{K}$ values were computed as 0.7678 for the May-NDVI and July-NDVI combination, 0.8628 for the May-NDVI and September-NDVI combination, and 0.8452 for the July-NDVI and September-NDVI combination. Since the out of bag (OOB) data, which are used for the verification in RF algorithm are selected randomly, even if other parameters are the same, the accuracy would change in each classification process. Furthermore, number of trees (*ntree*) and number of random features (*mtry*), which are the parameters of RF algorithm, affect the classification accuracy. In order to obtain the highest accuracy within all these variables, an application (Random Forest with the Highest Accuracy-RFHA) was written in R program to increase the accuracy of the RF algorithm. Depending on band combination, the rate of increase in accuracy was up to 3%.

Key Words: Random Forest, Crops, Texture, Image Classification, Object-Based

TEŞEKKÜR

Tezimin hazırlanmasında engin bilgi birikimiyle yardımlarını hiç esirgemeyen danışman hocam Prof. Dr. Mustafa TÜRKER'e,

Manevi desteğini hiç esirgemeyen eşim Advıye YILMAZ'a,

Son olarak tez hazırlama sürecinde manevi destek amacıyla kucağımdan hiç inmeyen kızım Elif YILMAZ'a

En samimi teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
TABLolar	viii
ŞEKİLLER	ix
KISALTMALAR	xii
1. GİRİŞ	1
1.1. Geçmiş Çalışmalar	2
1.2. Tezin Amacı	5
1.3. Kullanılan Yazılımlar	6
1.4. Tezin Organizasyonu	6
2. AĞAÇ TİPİ SINIFLANDIRICILAR	7
2.1. Karar Ağacı	7
2.1.1. GINI.....	7
2.2. Rastgele Orman	8
2.2.1. Rastgele Orman Algoritması Girdileri.....	9
3. YÖNTEM	10
3.1. Çalışma Alanı ve Veriler	10
3.1.1. Çalışma Alanı	10
3.1.2. Veriler	11
3.2. Yöntem	20
3.2.1. Sınıflandırılacak Ürünler	22
3.2.2. Görüntü Segmentasyonu	44
3.2.3. Segmentlerden Eğitim ve Test Alanlarına Değer Aktarılması.....	46
3.2.4. Rastgele Orman Algoritması ile Sınıflandırma	49
3.2.5. Doğruluk Analizleri	53
4. BULGULAR VE DEĞERLENDİRMELER	55
5. SONUÇLAR.....	62
6. ÖNERİLER.....	64

KAYNAKLAR	65
7. EKLER.....	69
ÖZGEÇMİŞ	78



TABLÖLAR

Tablo 1. Çiftçi kayıt sistemi verileri örneği.....	12
Tablo 2. Sentinel 2 uydusu özellikleri.....	14
Tablo 3. Sentinel 2 spektral bantları.....	14
Tablo 4. Çalışmada kullanılan uydu görüntüleri	14
Tablo 5. Ürün bazında eğitim ve test verisi dağılımı	23
Tablo 6. Çalışma alanındaki tarımsal ürünlerin zamansal değişimi.....	25
Tablo 7. Elde edilen segmentlerin özellik değerleri.....	45
Tablo 8. ArcGIS spatial join fonksiyonu ile yapılan işlem sonrası oluşan eğitim verisi özellik tablosu.....	48
Tablo 9. ArcGIS spatial join fonksiyonu ile yapılan işlem sonrası oluşan test verisi özellik tablosu.....	48
Tablo 10. En önemli 3 bant (<i>OrtNDVIMay, Tem, Eyl</i>) <i>ntree</i> ve <i>mtry</i> kombinasyonu <i>K</i> ve <i>OOB</i> değerleri.....	51
Tablo 11. Çalışmada kullanılan özellik (bant) kombinasyonları.....	53
Tablo 12. Örnek Hata Matrisi.....	54
Tablo 13. Farklı özellik kombinasyonları için varsayılan RO ve EYDRO ile elde edilen <i>K</i> ve genel doğruluk değerlerinin karşılaştırması*.....	55
Tablo 14. Her ürün için tüm özellik kombinasyonlarında hesaplanmış <i>üretici doğruluğu</i> ve <i>kullanıcı doğruluğu</i> değerleri	56

ŞEKİLLER

Şekil 1. Örnek karar ağacı yapısı [41]	7
Şekil 2. Çalışma alanı	10
Şekil 3. Arazi çalışmaları esnasında çekilmiş üzüm bağı fotoğrafı.....	11
Şekil 4. Arazi çalışmaları esnasında çekilmiş biber tarlası fotoğrafı	12
Şekil 5. Arazi gerçeği verilerinin (mavi renkli alanlar) çalışma alanındaki dağılımı.....	13
Şekil 6. 10 Nisan 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)	15
Şekil 7. 3 Mayıs 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y).....	15
Şekil 8. 2 Haziran 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)	16
Şekil 9. 2 Temmuz 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y).....	16
Şekil 10. 1 Ağustos 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y).....	17
Şekil 11. 7 Eylül 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)	17
Şekil 12. 10 Ekim 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)	18
Şekil 13. 16 Kasım 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)	18
Şekil 14. Yöntemin akış diyagramı	20
Şekil 15. Ürünlerin Ağustos sonu-Eylül başı fotoğrafları	24
Şekil 16. Buğday parsellerinin ortalama NDVI değerlerinin aylara göre değişimi.....	25
Şekil 17. Mayıs ayında buğday (yalancı renk - YKÖ, K, Y)	26
Şekil 18. Haziran ayında buğday (yalancı renk - YKÖ, K, Y).....	26
Şekil 19. Temmuz ayında buğday (yalancı renk - YKÖ, K, Y)	27
Şekil 20. Üzüm parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	28
Şekil 21. Mayıs ayında üzüm (yalancı renk - YKÖ, K, Y)	28
Şekil 22. Haziran ayında üzüm (yalancı renk - YKÖ, K, Y).....	29
Şekil 23. Kasım ayında üzüm (yalancı renk - YKÖ, K, Y).....	29
Şekil 24. Zeytin parsellerinin ortalama NDVI değerlerinin aylara göre değişimi.....	30

Şekil 25. Mayıs ayında zeytin (yalancı renk - YKÖ, K, Y)	30
Şekil 26. Ağustos ayında zeytin (yalancı renk - YKÖ, K, Y)	31
Şekil 27. Kasım ayında zeytin (yalancı renk - YKÖ, K, Y)	31
Şekil 28. Mısır parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	32
Şekil 29. Mısır2 parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	32
Şekil 30. Mayıs ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)	33
Şekil 31. Temmuz ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)	33
Şekil 32. Eylül ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)	34
Şekil 33. Kasım ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)	34
Şekil 34. Domates parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	35
Şekil 35. Mayıs ayında domates (yalancı renk - YKÖ, K, Y)	35
Şekil 36. Temmuz ayında domates (yalancı renk - YKÖ, K, Y)	36
Şekil 37. Eylül ayında domates (yalancı renk - YKÖ, K, Y)	36
Şekil 38. Biber parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	37
Şekil 39. Patlıcan parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	37
Şekil 40. Mayıs ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)	38
Şekil 41. Eylül ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)	38
Şekil 42. Kasım ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)	39
Şekil 43. Pamuk parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	39
Şekil 44. Mayıs ayında pamuk (yalancı renk - YKÖ, K, Y)	40
Şekil 45. Ağustos ayında pamuk (yalancı renk - YKÖ, K, Y)	40
Şekil 46. Kasım ayında pamuk (yalancı renk - YKÖ, K, Y)	41
Şekil 47. Yonca parsellerinin ortalama NDVI değerlerinin aylara göre değişimi	41
Şekil 48. Nisan ayında yonca (yalancı renk - YKÖ, K, Y)	42
Şekil 49. Haziran ayında yonca (yalancı renk - YKÖ, K, Y)	42
Şekil 50. Ağustos ayında yonca (yalancı renk - YKÖ, K, Y)	43

Şekil 51. Ekim ayında yonca (yalancı renk - YKÖ, K, Y)	43
Şekil 52. Kasım ayında yonca (yalancı renk - YKÖ, K, Y)	44
Şekil 53. Çoklu çözünürlük segmentasyon sonucu elde edilen segmentler	45
Şekil 54. Parsel (kırmızı) ve segment (siyah) kesişimi	47
Şekil 55. Çalışma alanının bir bölümünde yer alan parsellerin orta noktaları	47
Şekil 56. Çalışmada kullanılan bantlara ait özellik önem derecesi (variable importance) (200 bant içerisinde)	50
Şekil 57. Nesne-tabanlı sınıflandırma sonucu	57



KISALTMALAR

RO : Rastgele Orman

EYDRO: En Yüksek Doğruluklu Rastgele Orman

ÇKS: Çiftçi Kayıt Sistemi

Ntree: Rastgele Orman Algoritması Ağaç Sayısı

Mtree: Rastgele Orman Algoritması Rastgele Özellik (Değişken) Sayısı

NIR: Near Infrared (Yakın Kızıl Ötesi)

OOB: Out of Bag (Genelleştirilmiş Hatalar)

$\text{Özellik}_{\text{Bant}}^{\text{Tarih}}$:

Özellik: Ortalama, standart sapma, homojenlik, farklılık ve entropi

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

Tarih: Nisan ve Kasım arasındaki aylar

M: Mavi Bant

Y: Yeşil Bant

K: Kırmızı Bant

YKÖ: Yakın Kızılötesi Bant

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

Ort: Segmentlerin Ortalaması

Std: Segmentlerin Standart Sapması

Hmj: Segmentlerin Homojenliği

Frk: Segmentlerin Farklılığı

Ent: Segmentlerin Entropisi

1. GİRİŞ

Dünya nüfusu her geçen gün artmaktadır. Dünya nüfusunun 2030, 2050 ve 2100 e kadar sırasıyla 8,7, 9,7 ve 11,2 milyara ulaşması beklenmektedir [1]. Hızlı büyüme beraberinde şehirleşme ve sanayileşmeyi getirmektedir. Bu da kaçınılmaz olarak besin ve su tedarigi üzerindeki baskıyı artıracaktır. Buna ilave olarak, iklim değişikliği modelleri şiddetli kuraklık gibi olağanüstü olayların daha sık olacağını öngörmektedir. Bu da su kıtlığı ve besin üretimi konusunda daha yüksek risklerle karşılaşılmasına neden olacaktır. Bu sebeple tarımın ve su tüketiminin profesyonel şekilde yönlendirilmesi ve izlenmesi büyük önem taşımaktadır.

Uzaktan algılama dünyamız yüzeyindeki objelere ait bilgilerin fiziksel temas olmadan bir aygıtla toplanması bilimidir [2]. Uzaktan algılama ile yeryüzündeki cisimler hakkında bilgi elde etme, elektromanyetik enerji ile yeryüzündeki cisimlerin etkileşiminin incelenmesi ile gerçekleştirilir. Tarımsal ürün deseni tespitinde günümüzde en yaygın kullanılan yöntemlerin başında uzaktan algılama gelmektedir. Uydu görüntüleri ile tarım alanlarının haritalanması ile ilgili çeşitli ölçeklerde ve farklı yöntemlerle yapılmış çalışmalar mevcuttur [3] [4] [5] [6] [7] [8] [9] [10] [11]. Uydu görüntüleri ile tarımsal ürün deseni tespitinde en yaygın kullanılan yöntem otomatik görüntü sınıflandırmadır.

Tarımsal ürün deseni tespitinde çok zamanlı uydu görüntüleri ile yapılan çalışmaların tek zamanlı uydu görüntüleri ile yapılan çalışmalara göre daha yüksek doğruluk verdiği bilinmektedir [12] [13]. Örneğin, Arvor vd. (2011) [14] tarafından yapılan çalışmada 250m çözünürlüklü MODIS-Terra/Geliştirilmiş Bitki İndeksi (Enhanced Vegetation Index - EVI) zaman serileri Brezilya'da soya fasulyesi, mısır, pamuk ve ticari olmayan ürünleri başarılı bir şekilde sınıflandırmıştır. MODIS EVI verilerinden tanımlanmış vejetasyon dinamiği deseni Maus vd. (2016) [15] tarafından kullanılarak çift ürün, tek ürün, orman ve meralar sınıflandırılmıştır. Senf vd. (2015) [16] bozkırlardan tarımsal ürünleri ayırt etmek için çok sezonlu MODIS ve Landsat görüntülerini kullanmıştır. Müller vd. (2015) [17] Landsat zaman serilerini kullanarak tarım alanlarını ve meraları başarılı bir şekilde sınıflandırmıştır. Türker, vd. (2005) [18] tarafından yapılan çalışmada Mayıs, Temmuz ve Ağustos aylarına ait Landsat 7 ETM+ görüntüleri kullanılarak parsel tabanlı tarımsal ürün deseni tespiti yapılmıştır. Serra ve Pons (2008) [19] tarafından yapılan çalışmada altı adet Akdeniz bitkisinin (tahıl, pirinç, mısır, meyve ağaçları, yonca ve diğer ürünler) zamansal değişimini izleyen ve haritalamasını yapan bir yaklaşım ortaya konmuştur. Çalışmada 2002-2005 yılları arasına ait 36 adet Landsat görüntüsü kullanılmıştır. Murthy, vd. (2003) [20] yaptığı

çalışmada En Yüksek Olasılık Sınıflandırıcısı ile Sinir Ağları Sınıflandırıcısını karşılaştırmıştır. Bu sınıflandırıcılar çok zamanlı IRS-1B (Indian Remote Sensing) uydu görüntüleri ile test edilmiştir. Çalışmada tarımsal ürünler sınıflandırılmıştır. Simonneaux, vd. (2008) [21] yaptığı çalışmada 4 ana sınıfı (çıplak toprak, yıllık bitkiler, çıplak toprak üstündeki ağaçlar ve alt bitki örtüsü üstündeki ağaçlar) 8 zaman serili Landsat görüntüleri ile tespit etmiştir. Pena-Barragan, vd. (2011) [22] tarafından yapılan çalışmada farklı tarihlerde alınan 3 adet ASTER uydu görüntüsü ile karar ağacı modeli kullanılarak tarımsal ürün tespiti yapılmıştır. Akar ve Güngör'ün (2013) [23] yaptığı çalışmada Trabzon Sürmene'de yetiştirilen iki ana ürün fındık ve çay WorldView-II görüntüsü kullanılarak tespit edilmiştir. Çalışmada hem yaz hem de kış mevsimlerine ait uydu görüntüleri kullanılmıştır.

Görüntüleri ücretsiz olarak paylaşılan Sentinel 2 [24] uydularının ilki Haziran 2015, ikincisi Temmuz 2016'da yörüngeye yerleştirilmiştir. İki Sentinel uydusunun eş zamanlı ikiz uydular olarak çalışması zamansal çözünürlüğü 5 güne kadar indirmiştir ve bu sebeple görüntü sınıflandırma işleminde çok zamanlı görüntülerin kullanılabilmesi için çok kıymetli bir veri haline gelmiştir. Diğer taraftan yapılan çalışmalarda bu verilerin sıklıkla kullanılmaya başlandığı görülmektedir [25] [26] [27] [28] [29] [30]. Örneğin, Sonobe vd. (2017) [31] tarafından yapılan çalışmada Sentinel-1A ve Sentinel-2A uydu görüntüleri kullanılarak tarımsal ürün tipleri belirlenmiştir. Belgiu ve Csillik (2018) [29] tarafından yapılan çalışmada Sentinel 2 uydu görüntüleri kullanılarak 3 farklı alanda (Romanya, İtalya ve ABD) tarımsal ürün tespiti yapılmıştır.

Birçok araştırmacı ürünlerin zamansal değişimi, ürün deseni, parsel büyüklüğü vb. ürün ile ilgili bilgilerin başarılı bir sınıflandırma sonucu için kullanılması gerektiğini vurgulamaktadır [19] [21]. Bu bilgiler dokusal, bağlamsal ve morfolojik olabilmektedir [32] [33] [22].

1.1. Geçmiş Çalışmalar

Literatürde, uzaktan algılama yöntemleri ile tarımsal ürün tespiti alanında birçok çalışma bulunmaktadır.

Murthy vd. (2003) yaptığı çalışmada, En Yüksek Olasılık Sınıflandırıcısı ile Sinir Ağları Sınıflandırıcısını karşılaştırmıştır. Bu sınıflandırıcılar çok zamanlı IRS-1B (Indian Remote Sensing) uydu görüntüleri ile test edilmiştir. Çalışmada tarımsal ürünler sınıflandırılmıştır. Sinir Ağları algoritmasının diğer sınıflandırma algoritmalarına göre daha iyi sonuçlar verdiği görülmüştür [20].

Türker vd. (2005) tarafından yapılan çalışmada, Mayıs, Temmuz ve Ağustos aylarına ait Landsat 7 ETM+ görüntüleri kullanılarak parsel tabanlı tarımsal ürün deseni tespiti yapılmıştır. Çalışmada sıralı maskeleme yöntemi kullanılmıştır. Çalışmanın genel doğruluğu %81,03 olarak hesaplanmıştır [18].

Wardlow vd. (2007) yaptığı çalışmada, bölgesel olarak farklı ekim tarihlerine sahip olan sınıfları sınıf-içi gruplara ayırmıştır. Yazar büyük alanlarda yapılan çalışmalarda yöntemin kullanılması gerektiği sonucuna varmıştır [34].

Serra ve Pons (2008) tarafından yapılan çalışmada, altı adet Akdeniz bitkisinin (tahıl, pirinç, mısır, meyve ağaçları, yonca ve diğer ürünler) zamansal değişimini izleyen ve haritalamasını yapan bir yaklaşım ortaya konmuştur. Çalışmada 2002-2005 yılları arasına ait 36 adet Landsat görüntüsü kullanılmıştır. Çalışma sonucunda yazar, çok zamanlı görüntülerin yüksek sınıflandırma hassasiyeti ve ürünlerin zamansal değişiminin izlenmesi için gerekli olduğu sonucuna varmıştır [19].

Simonneaux vd. (2008) yaptığı çalışmada, 4 ana sınıfı (çıplak toprak, yıllık bitkiler, çıplak toprak üstündeki ağaçlar ve alt bitki örtüsü üstündeki ağaçlar) 8 zaman serili Landsat görüntülerini sınıflandırarak tespit etmiştir. Sınıflandırma işlemini karar ağacı metodu ile gerçekleştirmiştir. Çalışma sonucunda detaylı ürün tipolojisinin sadece NDVI ile elde edilemeyeceği belirtilmiştir [21].

Wardlow ve Egbert (2008) yaptığı çalışmada, orta çözünürlüklü MODIS (Moderate Resolution Imaging Spectroradiometer-Orta Çözünürlüklü Görüntüleme Spektrometresi) uydu görüntülerini kullanmıştır. Konumsal çözünürlüğü sadece 32 ha üstü parsellerin tespit edilmesine uygundur. Çok tarihli uydu görüntüleri ile büyük alanlarda ürünlerin zamansal değişiminin analizi ve genel ürün tiplerinin tespiti yapılmıştır [35].

Yang vd. (2010) yaptığı çalışmada, SPOT-5 uydu görüntülerini kullanarak eğitimli sınıflandırma metodlarından olan En Yakın Mesafe, Mahalonobis Mesafe, En Yüksek Olasılık, Spektral Açık Haritalayıcı (Spectral Angular Mapping - SAM) ve Destek Vektör Makineleri karşılaştırılmıştır. Ayrıca, bazı bant kombinasyonlarının ve piksel çözünürlüğünün (10, 20, 30 m) sınıflandırmaya etkisi incelenmiştir. Sonuç olarak, En Büyük Olasılık ve Destek Vektör Makinaları diğer algoritmalarından daha yüksek doğruluklu sonuç vermiştir ve piksel çözünürlüğünün 10-20-30 metre olması tarımsal ürün sınıflandırması doğruluğunu ciddi oranlarda etkilememiştir [36].

Pena-Barragan vd. (2011) tarafından yapılan çalışmada, farklı tarihlerde alınan 3 adet ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer-Gelişmiş Uzay Termal Emisyon ve Yansıma Radyometresi) uydu görüntüsü ile karar ağacı modeli kullanılarak tarımsal ürün tespiti yapılmıştır. Ayrıca, ASTER uydu görüntülerinde elde edilen doku bantları sınıflandırmada kullanılmıştır. Karar ağacı modeli ile yapılan sınıflandırmanın genel doğruluk oranı %79 olarak tespit edilmiştir [22].

Türker vd. (2011) tarafından yapılan çalışmada, SPOT4, SPOT5, IKONOS, QuickBird XS ve QuickBird PS (pansharpened) uydu görüntüleri kullanılarak tarımsal ürün deseni tespiti yapılmıştır. Genel doğruluklar SPOT4, SPOT5, IKONOS, QuickBird XS ve QuickBird PS uyduları için sırasıyla %76,3, %77,9, %88,9, %85,0 ve %85,5 olarak hesaplanmıştır [37].

Du vd. (2012) yaptığı çalışmada, HRS (High Resolution Stereoscopic-Yüksek Çözünürlüklü Stereoskopik) görüntülerini sınıflandırmak için Destek Vektör Makinesi ve Rastgele Orman (RO) algoritmasını birleştirerek DWDCS (Distance-Weighted Dynamic Classifier Selection-Mesafe Ağırlıklı Dinamik Sınıflandırıcı Seçimi) algoritmasını oluşturmuşlardır. AVIRIS uydu görüntüleri kullanılarak tarımsal alanlar sınıflandırılmıştır. Destek Vektör Makinesi ve RO algoritmalarının sırasıyla genel doğruluğu %94,3, %95,1 iken DWDCS algoritmasının %98,1 genel doğruluğa ulaştığı görülmüştür [38].

Akar ve Güngör'ün (2013) yaptığı çalışmada, Trabzon Sürmene'de yetiştirilen iki ana ürün fındık ve çay WorldView-II görüntüsü kullanılarak tespit edilmiştir. Çalışmada hem yaz hem de kış mevsimlerine ait uydu görüntüleri kullanılmış olup bu görüntüler RO, Destek Vektör Makineleri ve Gentle Adaboost gibi makine öğrenme tabanlı yöntemler yanında klasik istatistik tabanlı En Çok Benzerlik yöntemiyle de sınıflandırılmıştır. Yaz ve kış dönemi için RO algoritmasının genel doğruluğu sırasıyla %79,05 ve %71,84 olarak elde edilmiştir. Bu çalışmada RO algoritmasının diğer algoritmalara göre daha yüksek doğruluk verdiği görülmüştür [23].

Wu vd. (2014) tarafından yapılan çalışmada, kural tabanlı Otomatik Ürün Sınıflandırması Algoritması (ACCA-Automated Cropland Classification Algorithm) geliştirilmiştir. Uygulamada MODIS ve Landsat TM-5 kullanılmıştır. Birbirinden bağımsız veri setlerinde piksel tabanlı yapılan doğruluk analizinde $\hat{K}$ (Khat-Kappa) değeri 0,8 olarak hesaplanmıştır [39].

Lowe ve Kulkarni (2015) tarafından yapılan çalışmada RO, En Büyük Olasılık Sınıflandırıcısı, Sinir Ağları ve Destek Vektör Makineleri algoritmalarının performansları değerlendirilmiştir. Çalışmada Missisipi ve Yellowstone’a ait Landsat 8 OLI (Operational Land Imager-Operasyonel Yer Görüntüleyici) uydu görüntüleri kullanılarak arazi örtüsü sınıflandırması yapılmıştır. Sınıflandırma sonucunda %95,25 genel doğruluk oranıyla RO algoritmasının en doğru sonucu verdiği görülmüştür. Sinir Ağları, Destek Vektör Makineleri, En Büyük Olasılık Sınıflandırıcısı genel doğruluk oranları ise sırasıyla %76,87, %86,88 ve %83,13 olarak hesaplanmıştır [40].

Sonobe vd. (2017) tarafından yapılan çalışmada, Sentinel-1A ve Sentinel-2A uydu görüntüleri kullanılarak tarımsal ürün tipleri belirlenmiştir. Çalışmada ayrıca, RO, Destek Vektör Makineleri, Kernel Tabanlı Aşırı Makine Öğrenme (KELM-Kernel-Based Extreme Learning Machine) ve Çok Katmanlı İleri Beslemeli Sinir Ağları (Multilayer Feedforward Neural Networks) algoritmaları karşılaştırılmıştır. Genel doğrulukta KELM’in %96,28 ile en yüksek doğruluğu verdiği görülmüştür. Ayrıca Sentinel 1A VV ve Sentinel 2A bant 4 ün tarımsal ürün sınıflandırmasında önemli olduğu görülmüştür [31].

Belgiu ve Csillik (2018) tarafından yapılan çalışmada Sentinel 2 uydu görüntüleri kullanılarak 3 farklı alanda (Romanya, İtalya ve ABD) tarımsal ürün tespiti yapılmıştır. Çalışma Zaman-Ağırlıklı Dinamik Zaman Eğrisi (TWDTW-Time-Weighted Dynamic Time Warping) metodu ile yapılmıştır. Çalışmada ayrıca piksel ve nesne tabanlı sınıflandırma sonuçları da karşılaştırılmıştır. Üç çalışma alanında da nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha yüksek doğruluk verdiği görülmüştür [29].

1.2. Tezin Amacı

Bu tez çalışmasının amacı, çok zamanlı Sentinel-2 uydu görüntülerinden Gediz ovasının bir bölümünde yaz aylarında yetiştirilen tarımsal ürünleri nesne-tabanlı RO sınıflandırma yöntemi ile tespit etmektir. Çalışmanın diğer amacı, RO sınıflandırma algoritmasının parametreleri olan ağaç sayısı (*ntree*) ve rastgele değişken sayısını (*mtry*) otomatik olarak değiştirip sınıflandırma için en uygun parametre değerlerini tespit eden bir uygulama (EYDRO-En Yüksek Doğruluklu Rastgele Orman) hazırlamaktır. Çalışmanın bir diğer amacı, yaz ürünlerinin tespitinde kullanılacak Sentinel-2 uydu görüntüleri tarihlerinin ve sınıflandırmada kullanılması gereken en önemli özelliklerin tespit edilmesidir. Çalışmada ayrıca, çok zamanlı görüntü sınıflandırması ile tek zamanlı görüntü sınıflandırması sonuçlarının karşılaştırılması da amaçlanmıştır. Bundan başka, NDVI (Normalized Difference Vegetation Index–Normalleştirilmiş Fark Bitki İndeksi), standart sapma spektral

özelliklerinin yanında homojenlik, farklılık ve entropi doku özelliklerinin sınıflandırma doğruluğuna etkilerinin incelenmesi amaçlanmıştır.

1.3. Kullanılan Yazılımlar

Çalışmada yazılım olarak R, ArcGIS ve eCognition yazılımları kullanılmıştır. ArcGIS yazılımı ile eğitim ve test verilerinin düzenlenmesi yapılmıştır. Görüntü segmentasyonu işlemi, doku ve standart sapma bantlarının oluşturulması işlemleri eCognition yazılımında yapılmıştır. R yazılımında ise RO algoritması ile sınıflandırma işlemi gerçekleştirilmiştir.


1.4. Tezin Organizasyonu

Tez çalışması 7 bölümden oluşmaktadır. Tezin 2. bölümünde ağaç tipi sınıflandırıcılar ve RO algoritması, 3. bölümde yöntem ve takip edilen adımlar, 4. bölümde elde edilen sonuçların değerlendirilmesi, 5. bölümde sonuçlar anlatılmıştır. Son olarak 6. bölümde öneriler getirilmiştir. 7. bölüm eklerin bulunduğu bölümdür ve doğruluk analizleri tabloları verilmektedir.

2. AĞAÇ TİPİ SINIFLANDIRICILAR

2.1. Karar Ağacı

Karar ağacı sınıflandırıcıları eğitilmiş sınıflandırıcılar grubu içerisinde yer almaktadır. Karar ağacı düğüm ve dalların birleşiminden oluşmaktadır. Bölünmeler düğümlerde gerçekleşir. İşlemler tüm düğümlerde yapıldıktan sonra sonuç sınıflar yaprak düğümde tutulur. Düğümlerin bölünme değerlerini belirlemek için en sık kullanılan yöntemler: entropi, bilgi kazanımı ve Gini indeksi'dir. Bu çalışmada kullanılan R programının randomForest kütüphanesinde Gini indeksi kullanıldığı için aşağıda sadece Gini indeksi detaylı olarak anlatılmıştır. Bir örnek karar ağacı yapısı Şekil 1'de gösterilmiştir.



Şekil 1. Örnek karar ağacı yapısı [41]

2.1.1. GINI

Gini indeksi veya Gini katsayısı, dağılımın istatistiksel hesabıdır. İtalyan istatistikçi Corrado Gini tarafından 1912 yılında geliştirilmiştir [42]. Gini indeksi sınıfların heterojenliğini (impurity) ölçerek sonuca gider. Gini indeksi değeri küçük olan özellik en saf/homojen özellik olduğu için bölünmede öncelikli olarak kullanılır. Gini indeksi sağ ve sol olmak üzere ikili dallanma ile çalışmaktadır.

Gini indeksi hesabında öncelikle özellikler iki gruba ayrılır. Ayrım değeri özellikteki tüm değerlerin ortalaması alınarak hesaplanır. Özellikteki değerler, belirlenen eşik değerden küçük olanlar sol grup, büyük ve eşit olanlar sağ grup olmak üzere ikiye ayrılır. Her grup için sağ ve sol Gini indeksi hesaplanır (Eşitlik 1 ve 2).

$$G_{sağ} = 1 - \sum_{i=1}^n \left(\frac{R_i}{|D_{sağ}|} \right)^2 \quad (1)$$

$$G_{sol} = 1 - \sum_{i=1}^n \left(\frac{L_i}{|D_{sol}|} \right)^2 \quad (2)$$

Eşitlik 1 ve 2’ de kullanılan n sınıf sayısını, $D_{sağ}$ sağ taraftaki yani belirlenen eşik değerden büyük değere sahip örneklerin sayısını, D_{sol} sol taraftaki yani belirlenen eşik değerden küçük değere sahip örneklerin sayısını, R_i sağ taraftaki i sınıfında bulunan örnek sayısını ve L_i sol taraftaki i sınıfında bulunan örnek sayısını göstermektedir.

Eşitlik 1 ve 2’ de hesaplanan sağ ve sol Gini değerleri Eşitlik 3 kullanılarak her özelliğin Gini değeri hesaplanır.

$$Gini_i = \frac{1}{k} (|D_{sol}|G_{sol} + |D_{sağ}|G_{sağ}) \quad (3)$$

Eşitlik 3’ te kullanılan k eğitim verisi sayısını, $D_{sağ}$ sağ taraftaki örneklerin sayısını, D_{sol} sol taraftaki örneklerin sayısını, $G_{sağ}$ sağ Gini değerini ve G_{sol} sol Gini değerini ifade etmektedir.

Her bir özellik için hesaplanan Gini değerleri karşılaştırılır ve bölünme işlemi en küçük Gini değerine sahip özellik ile gerçekleştirilir.

2.2. Rastgele Orman

Rastgele orman (RO) algoritması topluluk (ensemble) sınıflandırma metotlarından [23]. RO algoritması tek karar ağacı algoritmalarına göre genellikle daha doğru sonuçlar vermektedir. RO algoritmasında birçok karar ağacı birbirinden bağımsız olarak oluşturulmaktadır. Eğitim verisinin 1/3 ü genelleştirilmiş hatalar (Out of Bag-OOB) hesabı için ayrılır. OOB sınıflandırmanın hata matrisi hesabında ve özellik önem derecesi (variable importance) hesabı için kullanılır. Eğitim verisinin geriye kalan 2/3’lük kısmı karar ağaçlarının oluşturulması için kullanılır. Ayrıca her düğümde “*mtry*” olarak adlandırılan rastgele özellik seçimi yapılır. *Mtry* değeri genel olarak tüm özelliklerin toplam sayısının karekökü alınarak hesaplanır. Her bir ağacın oluşturulması için bu işlemler tekrarlanır.

Orman oluşturulduktan sonra objeler tüm ağaçlar tarafından sınıflandırılır ve tüm sınıflandırmaların çoğunluk (majority) değeri alınarak sonuç sınıf elde edilir.

RO algoritması bir örnek ile şu şekilde açıklanabilir [40]. Örneğin, hırsızlıkla suçlanan bir kişi mahkemede duruşmaya çıkar. Jüri üyeleri kişiyi suçlu veya suçsuz olarak sınıflandıracaktır. Kişinin hırsızlık geçmişi rastgele alt gruplara ayrılarak her alt grup bir jüriye vermek üzere dağıtılır. Rastgele seçilen alt gruplar toplam dosyanın 2/3 oranındadır. Farklı dosyalarla eğitilen her jüri olayı elindeki dosyalara göre değerlendirecektir. Bazı jüriler çalınan miktara, kişinin yaşına bakarken bazıları cinsiyetine, inancına bakacaktır. Duruşma sonucunda her jüri üyesi suçlu veya suçsuz olmak üzere bir oy kullanacaktır ve karar oyların çoğunluğuna göre verilecektir. Bu örnekte jüri ormanı, jüri üyeleri ağaçları, hırsızlıkla suçlanan kişi sınıflandırılacak objeyi, dosyalar ise özellikleri temsil etmektedir.

2.2.1. Rastgele Orman Algoritması Girdileri

RO algoritmasında, ağaç sayısı (*ntree*) ve rastgele özellik seçimi (*mtry*) parametreleri kullanılmaktadır.

Ntree ağaç sayısı kullanıcı tarafından belirlenir. Her ağaç için eğitim verisi rastgele olarak 2/3 ve 1/3 olarak ikiye ayrılır. 2/3 ü karar ağacını oluşturmak için 1/3 ü doğruluğu test etmek için kullanılır. Test için kullanılan 1/3'lük kısım Genelleştirilmiş Hatalar (Out of Bag-OOB) olarak adlandırılır.


Mtry değeri ağaçtaki her bir düğümü dallara ayırmak için kullanılır. Ağaçtaki herhangi bir düğümdeki kuralı oluşturmada kullanılacak tahmini değişkenler (özellikler) için rastgele seçim yapılır. Tahmini değişkenlerin sayısı kullanıcı tarafından belirlenebilir. Ancak, genel olarak tüm değişkenlerin (özelliklerin) toplam sayısının karekökü olarak belirlenir. Değişken sayısının az tutulması doğruluğu olumsuz etkilemektedir. Seçimin rastgele yapılmasının amacı ağaçlar arasındaki korelasyonu en aza indirmektir. Tüm değişkenler ağaç oluşumunda kullanılırsa ağaçlar arasında yüksek korelasyon meydana gelir [23].

3. YÖNTEM

3.1. Çalışma Alanı ve Veriler

3.1.1. Çalışma Alanı

Çalışma alanı Türkiye'nin Manisa İlinin Salihli ve Ahmetli ilçelerinin bir bölümünden oluşmaktadır. Çalışma alanı aynı zamanda Gediz ovasında bulunmakta olup koordinatları Sol Üst Boylam: 27,844° Enlem: 38,625° Sağ Alt Boylam: 28,181° Enlem: 38,463° 'dır (Şekil 2). Çalışma alanının toplam yüz ölçümü yaklaşık 520 km² dir. Bölge tarım ürünleri açısından oldukça verimlidir. Yetiştirilen ürünler ağırlıklı olarak üzüm, mısır, buğday, pamuk, domates, biber, patlıcan, yonca ve zeytin olmakla beraber arpa, fiğ, lahana, brokoli, ıspanak ve meyve bahçeleri de bulunmaktadır. Çalışma alanı genel olarak düzlük ve sulanan alanlar olmakla beraber buğday ekilen ve zeytin bulunan bazı alanlar biraz engebeli ve sulanmayan arazilerdir. Bölgede sulama genel olarak Gediz nehri kullanılarak yapılmaktadır. Ayrıca yer altı suyu kullanımı da yapılmaktadır. Çalışma alanı 520 km² gibi büyük bir alandan oluştuğu için parsel büyüklükleri de bölgeden bölgeye farklılık göstermektedir. Bazı bölgelerde parsel büyüklüğü en küçük 3 dönüm en büyük 50 dönüm iken bazı bölgelerde en düşük 50 en büyük 700 dönüm olabilmektedir. Ürün çeşitliliğinin fazla olması ve farklı boyutlarda parsellerin bulunması sebebiyle seçilen alan zorlu bir çalışma alanı olma özelliği taşımaktadır.



Şekil 2. Çalışma alanı

3.1.2. Veriler

Çalışmada uydu görüntüleri olarak çok zamanlı Sentinel 2 uyduları görüntüleri kullanılmıştır. Görüntüler Earthexplorer adresinden (<https://earthexplorer.usgs.gov>) [24] ücretsiz olarak temin edilmiştir.

Arazi gerçeği verileri, ürünlerin büyük bölümünün arazide olduğu 25.08.2017-05.09.2017 tarihleri arasında arazi çalışmaları yapılarak yerinde tespit edilmiştir (Şekil 3-4). Ayrıca Çiftçi Kayıt Sistemi (ÇKS) verisi de (Tablo 1) arazi çalışmaları sırasında elde edilen verilerle değerlendirilerek arazi gerçeği verisi olarak kullanılmıştır. Arazi gerçeği verileri 430 tanesi arazi çalışmaları esnasında tespit edilen parseller olmak üzere toplamda 1195 adettir. Eğer bir kadastro parseline birden fazla ürün ekilmişse bu ürünleri ayıran sınırlar sayısallaştırılmış ve o kadastro parselindeki her bir ürünün ekildiği alan tarımsal ürün parseline dönüştürülmüştür. Böylelikle her arazi gerçeği poligonunda tek bir ürünün bulunması sağlanmıştır. Arazi gerçeği verilerinin çalışma alanındaki dağılımı Şekil 5'te gösterilmektedir.




Şekil 3. Arazi çalışmaları esnasında çekilmiş üzüm bağı fotoğrafı



Şekil 4. Arazi çalışmaları esnasında çekilmiş biber tarlası fotoğrafı

Tablo 1. Çiftçi kayıt sistemi verileri örneği

İl	İlçe	Köy	Ada No	Parsel No	Kullanılan Alan(da)	Parsel Alanı(da)	Ürün	Tarım Şekli	Ekim Tarihi	Hasat Tarihi	Ekili Alan (da)
MANİSA	AHMETLİ	KARGIN	0	1146	3.163	18.65	BUĞDAY (MUHTELİF)	Kuru	01/10/2016	01/04/2017	3.163
MANİSA	AHMETLİ	KARGIN	0	1148	4.268	25.166	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	10/11/2015	20/08/2017	4.268
MANİSA	AHMETLİ	KARGIN	0	1151	4.823	28.434	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/11/2015	21/08/2017	4.823
MANİSA	AHMETLİ	KARGIN	0	692	12.728	25.46	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/11/2015	20/08/2018	4.318
MANİSA	AHMETLİ	KARGIN	0	1318	9.256	21.767	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	31/12/1999	31/08/2018	9.256
MANİSA	AHMETLİ	KARGIN	0	1330	19.303	19.305	BUĞDAY (MUHTELİF)	Sulu	01/10/2016	01/05/2017	19.089
MANİSA	AHMETLİ	KARGIN	0	1330	19.303	19.305	MISIR (SİLAJLIK)	Sulu	01/06/2017	01/10/2017	19.089
MANİSA	AHMETLİ	KARGIN	0	385	8.699	26.1	DOMATES (MUHTELİF)	Sulu	01/04/2017	01/07/2017	8.699
MANİSA	AHMETLİ	KARGIN	0	1035	2.73	2.73	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/11/2016	20/08/2021	2.73
MANİSA	AHMETLİ	KARGIN	0	1140	8.668	8.668	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	02/02/1993	21/08/2017	8.66
MANİSA	AHMETLİ	KARGIN	0	1149	50.334	50.334	ÜZÜM (KURUTMALIK ÇEKİRDEKSİZ)	Sulu	01/01/1998	20/08/2017	50.33



Şekil 5. Arazi gerçeği verilerinin (mavi renkli alanlar) çalışma alanındaki dağılımı

3.1.2.1. Uydu Görüntüleri

Sentinel Avrupa Uzay Ajansı tarafından geliştirilen bir programın adıdır. Sentinel'in Türkçesi "gözcü"dür. Sentinel programı çerçevesinde her birisinde 2 uydu bulunan 7 farklı uydu serisi fırlatılacaktır.

Sentinel 2 serisi Sentinel 2A ve 2B olmak üzere iki uydudan oluşmaktadır. Sentinel 2A Haziran 2015, Sentinel 2B ise Temmuz 2016 tarihinde fırlatılmıştır. İki uydu aynı yörüngede ve birbirine 180° açıda bulunmaktadır. Her bir uydu yaklaşık olarak 1,2 ton ağırlığındadır.

Sentinel 2 uyduları geniş şerit genişliği, yüksek konumsal çözünürlüğü ve 13 spektral bantı ile bitki örtüsünün ve yeryüzünün izlenmesi için eşsiz bir perspektif sunmaktadır [25]. Yüksek konumsal çözünürlük, yeni spektral bantlar, geniş alanda görüntü alma ve 5 günde tekrar aynı yerden görüntü alabilme kabiliyeti Sentinel 2 uydusunu karasal kıyısız uygulamalarda oldukça kullanışlı hale getirmektedir [26]. Sentinel 2 uydularının genel özellikleri Tablo 2'de, spektral bantları ve bantların özellikleri Tablo 3'te gösterilmektedir. Arazideki yaz dönemi ürünlerini tespit edebilmek için her aydan bir görüntü seçilmiştir (Tablo 4). Seçim işlemi her aya ait tüm görüntülerin görsel olarak incelenmesi ile yapılmıştır. Bu çalışmada kullanılan 8 farklı tarihte alınmış Sentinel 2 uydu görüntüleri yalancı renk (yakın kızılötesi, kırmızı ve yeşil) gösterimi aylara göre sırasıyla Şekil 6-13'te gösterilmektedir.

Tablo 2. Sentinel 2 uydusu özellikleri

Uzay aracı	Eş yapıda 2 uydu
Spektral bantlar	13 (VIS-NIR-SWIR)
Konumsal çözünürlük	10m/20m/60m
Yörünge	786 km de güneşle eş zamanlı 10.30'da görüntü almaktadır
Şerit genişliği	290 km
Coğrafi çekim alanı	-54 ile +84 enlemleri arasında sistematik olarak çalışmaktadır.
Zamansal Çözünürlük	İki uydu ile ekvatorda 5 gün
Dayanım ömrü	7,5 yıl, 12 yıla uzatılabilir

Tablo 3. Sentinel 2 spektral bantları


Bantlar	Orta Dalga Boyu (µm)	Çözünürlük (m)
Bant 1 – Kıyı aerosol	0,443	60
Bant 2 - Mavi	0,490	10
Bant 3 - Yeşil	0,560	10
Bant 4 - Kırmızı	0,665	10
Bant 5 - Bitki Sıcak Nokta	0,705	20
Bant 6 - Bitki Sıcak Nokta	0,740	20
Bant 7 - Bitki Sıcak Nokta	0,783	20
Bant 8 - Yakın Kızılötesi	0,842	10
Bant 8A - Bitki Sıcak Nokta	0,865	20
Bant 9 – Su Buharı	0,945	60
Bant 10 - Kısa Dalga Kızılötesi (Cirrus)	1,375	60
Bant 11 - Kısa Dalga Kızılötesi	1,610	20
Bant 12 - Kısa Dalga Kızılötesi	2,190	20

Tablo 4. Çalışmada kullanılan uydu görüntüleri


Uydu	Görüntü Tarihi
Sentinel 2	10 Nisan 2017
Sentinel 2	3 Mayıs 2017
Sentinel 2	2 Haziran 2017
Sentinel 2	2 Temmuz 2017
Sentinel 2	1 Ağustos 2017
Sentinel 2	7 Eylül 2017
Sentinel 2	10 Ekim 2017
Sentinel 2	16 Kasım 2017




Şekil 6. 10 Nisan 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 7. 3 Mayıs 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 8. 2 Haziran 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)




Şekil 9. 2 Temmuz 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 10. 1 Ağustos 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 11. 7 Eylül 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 12. 10 Ekim 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)



Şekil 13. 16 Kasım 2017 tarihli görüntü (yalancı renk - YKÖ, K, Y)


3.1.2.2. Yer Gerçeęi Verileri

Yer gerçeęi verilerini oluřturmak iin 25.08.2017 - 05.09.2017 tarihleri arasında arazi alıřmaları gerekleřtirilmiřtir. Arazi alıřmaları ncesinde otomatik grnt sınıflandırma yntemleriyle tespit edilmesi planlanan rnler arazide grlerek parsel parsel kaydedilmiřtir. Bu řekilde 430 parsel tespit edilmiřtir. Arazi alıřmaları sonrasında Tarım Bakanlıęından ifti Kayıt Sistemi (KS) verileri de temin edilmiřtir. Temin edilen veriler arazi alıřmaları verisi ile karřılařtırılmıř ve uyumlu olup olmadıkları incelenmiřtir.

Arazi verilerinden rnlerin spektral yansımadaęerleri kayıt altına alınıp tek tek KS verileri kontrol edilmiřtir. KS kaydındaki bir parsel spektral olarak arazide bulunduęu tm tarihlerde kendi trnn yansımadaęerini vermemiř ise ilgili parsel elenmiřtir. rneęin iinde buęday bulunan bir parselin en belirgin zellięi Nisan ve Mayıs aylarında yksek NDVI ve NIR yansımadaęerlerine sahipken Temmuz ayında dřk NDVI ve NIR yansımadaęerlerine sahip olmasıdır. Deęerlendirme yapılırken rnlerin arazideki var oluř tarihleri ve yansımadaęerleri kullanılmıřtır. Bylelikle alıřmada eęitim ve test verisi olarak kullanmak iin alıřma alanı iine daęılmıř 1195 farklı noktada arazi gereęi verileri oluřturulmuřtur.

3.2. Yöntem

Çalışmada kullanılan yöntemin adımları Şekil 14’ te gösterilmektedir.



Şekil 14. Yöntemin akış diyagramı

Otomatik görüntü sınıflandırma metoduyla ürün deseni tespiti çalışması için öncelikle sınıflar belirlenmiştir. Arazi gerçeği verileri ve uydu görüntüleri üzerinde yapılan görsel analizler yardımıyla ÇKS kayıtları analiz edilmiş ve bu işlemler sonucunda sınıflandırma işleminde kullanılacak olan eğitim ve test verileri oluşturulmuştur.

Çalışmada Sentinel 2 uydularının 10m konumsal çözünürlüğe sahip mavi, yeşil, kırmızı ve yakın kızılötesi bantları (M, Y, K, YKÖ) kullanılmıştır. Diğer bantlar tarımsal ürünleri tespit etmede faydalı olabilir ancak konumsal çözünürlüğünün (20m) düşük olması sebebiyle etkisi azalabilir [27] [28] ve bu nedenle bu çalışmada kullanılmamıştır.

Görüntülerin segmentasyon işlemi eCognition nesne tabanlı görüntü işleme yazılımıyla yapılmıştır. Segmentasyon işlemi için kullanılan parametreler [22] tarafından yapılmış olan çalışmadan uyarlanmıştır. Segmentasyon işlemi bölüm 3.2.2’ de detaylı olarak anlatılmaktadır.

Segmentasyon işlemi sonrasında oluşan her segment için, her görüntüye ait NDVI değerleri hesaplanmıştır. Böylelikle 32 orijinal bant (8 Görüntü x 4 Bant (M, Y, K, YKÖ)) ve 8 NDVI bantı (8 Görüntü x 1 B_{NDVI}) olmak üzere toplam 40 bant oluşturulmuştur. Ayrıca, elde edilen 40 bantın her biri için segmentlere ait ortalama (mean), standart sapma (standard deviation), homojenlik (homogeneity), farklılık (dissimilarity) ve entropi (entropy) değerleri de hesaplanarak yeni bantlar (B_{ORT}, B_{STD}, B_{HMJ}, B_{FRK} ve B_{ENT}) oluşturulmuştur. Böylelikle toplam 200 bant (40 bant x 5 değer) elde edilmiş ve sınıflandırma işleminde 200 bant kullanılmıştır.

Hesaplanan özelliklerden NDVI farklı yansıma değerlerine göre bitkilerin durumunu ve yapısını izlemek için kullanılır (Eşitlik 4) [43] [44].

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (4)$$

Eşitlik 4'te NDVI normalize edilmiş bitki indeksi farkını, NIR yakın kızılötesi bantı ve Red kırmızı bantı ifade etmektedir.

Doku (texture) bir görüntüdeki ton değişiminin frekansıdır. Doku nesne özellikleri hakkında heterojen ürün alanlarının ayırt edilebilmesine yardımcı olabilecek ek bilgi sağlar. Ancak, doku bilgisinin kullanılması işlem yükünü artırmaktadır [45]. Bu çalışmada en yaygın kullanılan spektral özellikler ortalama (mean) (Eşitlik 5) ve standart sapma (standard deviation) (Eşitlik 6); doku ölçümleri homojenlik (homogeneity) (Eşitlik 7), farklılık (dissimilarity) (Eşitlik 8) ve entropi (entropy) (Eşitlik 9) kullanılmıştır.

$$Segment \text{ spektral ortalama} = \frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} C_k(x, y) \quad (5)$$

$$\begin{aligned} & \text{Standart Sapma} \\ & = \sqrt{\frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} \left(C_k(x, y) - \frac{1}{\#P_{Seg}} \sum_{(x,y) \in P_{Seg}} C_k(x, y) \right)^2} \quad (6) \end{aligned}$$

$$GLCM \text{ Homojenlik} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (7)$$

$$GLCM \text{ Farklılık} = \sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (8)$$

$$GLCM \text{ Entropi} = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (9)$$

Eşitlik 5–9’da P_{seg} piksel gruplarından oluşan her bir segmenti, $\#P_{seg}$ segmentteki toplam piksel sayısını, $C_k(x, y)$ (x,y) piksel koordinatında görüntü katmanının değeri, i eşdizimlilik (co-occurrence) matrisindeki satır numarasını, j eşdizimlilik (co-occurrence) matrisindeki sütun numarasını, $P_{i,j}$ i,j nin Eşitlik 10 ile normalize edilmiş halini ifade etmektedir.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (10)$$

Eşitlik 10’da $V_{i,j}$ eşdizimlilik (co-occurrence) matristeki i,j hücresinin değerini ve N eşdizimlilik (co-occurrence) matristeki satır ve sütunların toplam sayısını ifade etmektedir.

3.2.1. Sınıflandırılacak Ürünler

Çalışma alanı tarımsal olarak verimli topraklardan oluşmaktadır. Bölgede ağırlıklı olarak bulunan tarım ürünleri üzüm, zeytin, mısır, buğday, biber, domates, patlıcan, pamuk, yonca olarak sıralanabilir. Pamuk, biber, patlıcan, mısır gibi ürünlerin öncesinde az sayılabilecek miktarda da olsa lahana, brokoli, ıspanak gibi ürünler kış ürünü olarak ekilmektedir. Bu ürünler en geç Mart sonunda hasat edilmektedir. Yukarıda da bahsedildiği üzere bu çalışmanın temel amacı çok zamanlı Sentinel 2 uydu görüntülerinden yaz ürünlerini tespit etmektir. Dolayısıyla, çalışmada kış ürünlerinin bulunmadığı Nisan ayı sonrası uydu görüntüleri kullanılmıştır. Sınıflandırılacak ürünleri arazi çalışması sırasında çekilmiş fotoğraflarından örnekler Şekil 15’te verilmiştir. Ürün bazında parsellerden toplanan arazi gerçeği verileri bilgisi Tablo 5’ te gösterilmiştir.

Tablo 5. Ürün bazında eğitim ve test verisi dağılımı

Ürün İsmi	Eğitim Verisi Sayısı	Test Verisi Sayısı
Biber	17	17
Buğday	60	60
Domates	32	31
Mısır	84	83
Mısır2	68	69
Pamuk	30	30
Patlıcan	10	10
Üzüm	228	227
Yonca	11	11
Zeytin	58	59
Toplam	598	597
Genel Toplam	1195	



Mısır



Mısır2



Pamuk



Buğday



Zeytin



Yonca



Üzüm



Biber



Domates




Patlıcan

Şekil 15. Ürünlerin Ağustos sonu-Eylül başı fotoğrafları


Çalışma alanındaki tarımsal ürünlerin zamansal değişimi Tablo 6’da verilmiştir. Bölgede buğday ekimi Ekim, Kasım aylarında yapılır. Ürün ekim tarihinden 45 gün sonra yeşillenmeye başlar. Ocak, Şubat aylarında tarlayı toprak görünmeyecek şekilde kapatır. Nisan ve Mayıs en yeşil ve gür zamanıdır. Hasatı Haziran ayı içerisinde gerçekleştirilir. Hasattan 10-15 gün önce yeşil olan rengi sarıya döner. Arpa ile buğday çok benzer yansıma değerleri verir. Tek farkı hasat tarihleridir. Genellikle buğday arpadan 10-15 gün kadar önce hasat edilir. Ancak, bölgede arpa ekimi buğdaya göre sınırlı sayıda kaldığı için bu çalışmada arpa, buğday ayrımı yapılmayarak arpa da buğday sınıfına dahil edilmiştir. Arazi gerçeği verisi olarak kullanılan 120 adet buğday parselinin aylara göre ortalama NDVI değeri değişimi Şekil 16’da gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bir buğday parselinin farklı aylardaki yansıma değişimleri Şekil 17-19’da gösterilmiştir.

Tablo 6. Çalışma alanındaki tarımsal ürünlerin zamansal değişimi


Biber													
Buğday													
Domates													
Mısır													
Mısır2													
Pamuk													
Patlıcan													
Üzüm*													
Yonca	İki-üç haftada bir tekrar hasat edildiği için tabloya eklenememiştir.												
Zeytin	Yapraklarını dökmektedir. Bu sebeple zamanla belirgin bir değişim göstermemektedir.												
		Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
			Seyrek bitki örtüsü		Yoğun bitki örtüsü			Hasat dönemi					
* Üzümün hasat dönemi ağustos sonu-eylül başıdır. Burada gösterilen yaprakların sarardığı ve dökülmeye başladığı tarihlerdir.													




Şekil 16. Buğday parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 17. Mayıs ayında buğday (yalancı renk - YKÖ, K, Y)




Şekil 18. Haziran ayında buğday (yalancı renk - YKÖ, K, Y)




Şekil 19. Temmuz ayında buğday (yalancı renk - YKÖ, K, Y)

Bölge üzüm üretiminde ülkemizde birinci sırada yer almaktadır. Üzüm üretimi olarak sultani üzümü yetiştirilmektedir. Üzüm çok yıllık bitkilerdendir. Nisan ayında yeşermeye başlar. Haziran, Temmuz ve Ağustos ayları en yeşil ve gür zamanlarıdır. Eylül'den itibaren yaprakları sararmaya ve dökülmeye başlar. Aralık ayına kadar tüm yapraklarını döker (Tablo 6).

Ayrıca üzüm bağlarında sıraların aralarında bulunan boşluğa Ekim ayında bakla, ıspanak, şalgam ekilebilmektedir. Bu ürünler en geç Nisan ayına kadar hasat edilir. Dolayısıyla, bu ürünlerin sonuçları etkilememesi için işlemi Nisan ayı sonrası alınmış görüntüler kullanılmıştır. Arazi gerçeği verileri olarak kullanılan 455 adet üzüm parselinin aylara göre ortalama NDVI değeri değişimi Şekil 20' de gösterilmiştir. Yine çalışmada arazi gerçeği verisi olarak kullanılan bazı üzüm parsellerinin farklı aylardaki yansıma değişimleri Şekil 21-23'te gösterilmiştir.



Şekil 20. Üzüm parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 21. Mayıs ayında üzüm (yalancı renk - YKÖ, K, Y)




Şekil 22. Haziran ayında üzüm (yalancı renk - YKÖ, K, Y)



Şekil 23. Kasım ayında üzüm (yalancı renk - YKÖ, K, Y)

Zeytin bölgenin önemli tarımsal ürünlerindendir. Zeytin ağacı çok yıllık bitkilerdendir. Genelde zeytin tarlasına başka ürün ekilmez. Ancak, bazen buğday, arpa veya susam ekildiği görülmektedir. Ancak, bunlar dikkate alınmayacak kadar az sayıda gerçekleşmektedir. Dolayısıyla bu çalışmada da dikkate alınmayacaktır. Zeytin ağacı tüm yıl boyunca yapraklarını korur. Zeytin ağacında yaprak dökümü gerçekleşmez. Arazi gerçeği verisi olarak kullanılan 117 adet zeytin parselinin aylara göre ortalama NDVI değeri değişimi Şekil

24' te gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bazı zeytin parsellerinin farklı aylardaki yansıma değişimleri Şekil 25-27'de gösterilmiştir.



Şekil 24. Zeytin parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 25. Mayıs ayında zeytin (yalancı renk - YKÖ, K, Y)



Şekil 26. Ağustos ayında zeytin (yalancı renk - YKÖ, K, Y)




Şekil 27. Kasım ayında zeytin (yalancı renk - YKÖ, K, Y)


Zeytin parsellerinin Kasım ayı yalancı renk gösteriminde renginin kırmızı gözükmemesinin sebebi histogram eşitlemedir. Tüm görüntüde yakın kızılötesi yansıması yüksek ürün kalmadığı için zeytinin yakın kızılötesi yansıması kırmızı olarak gözükmektedir. Spektral yansımasında önemli bir farklılık yoktur.

Mısır bölgede en yaygın ekilen ürünlerden birisidir. Mısırlı halk diliyle ası ve körpe mısır olarak ikiye ayrılmaktadır. Ayrıca mısır kurutmalık ve slajlık olarak ikiye ayrılır. Ası mısır Nisan ayında ekilir, Haziran ayında tarlayı doldurur (Tablo 6). En yeşil ve gür zamanı


Temmuz ve Ağustos aylarıdır. Ağustos sonuna doğru sararır. Slajlık mısır Temmuz sonu - Ağustos başı hasat edilir. Kurutmalık mısır ise Ağustos sonu - Eylül başı hasat edilir. Körpe mısır, öncesinde buğday ekilen mısırdır. Başka bir deyişle, tarlaya önce buğday ekilir, buğdayın hasatından sonra ise mısır ekilir. Körpe mısır Temmuz ortalarına doğru ekilir, Ekim sonu - Kasım başı hasat edilir. Körpe mısır slajlık olarak ekilir. Bu çalışmada önce buğday sonra mısır ekilen parseller mısır2 olarak isimlendirilmiştir. Arazi gerçeği verisi olarak kullanılan sırasıyla 167 ve 137 adet mısır ve mısır2 parsellerinin aylara göre ortalama NDVI değeri değişimi sırasıyla Şekil 28 ve Şekil 29 ‘ da gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bazı mısır ve mısır2 parsellerinin farklı aylardaki yansıma değişimleri Şekil 30-33’te gösterilmiştir.




Şekil 28. Mısır parsellerinin ortalama NDVI değerlerinin aylara göre değişimi




Şekil 29. Mısır2 parsellerinin ortalama NDVI değerlerinin aylara göre değişimi




Şekil 30. Mayıs ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)



Şekil 31. Temmuz ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)




Şekil 32. Eylül ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)




Şekil 33. Kasım ayında mısır ve mısır2 (yalancı renk - YKÖ, K, Y)


Bölgede üretilen ürünlerden domates Nisan ortası - Mayıs ortası arasında ekilir, Temmuz sonu - Ağustos sonu arasında hasat edilir. Arazi gerçeği verisi olarak kullanılan 63 adet domates parselinin aylara göre ortalama NDVI değeri değişimi Şekil 34' te gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bazı domates parsellerinin farklı aylardaki yansıma değişimleri Şekil 35-37'de gösterilmiştir.




Şekil 34. Domates parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 35. Mayıs ayında domates (yalancı renk - YKÖ, K, Y)




Şekil 36. Temmuz ayında domates (yalancı renk - YKÖ, K, Y)




Şekil 37. Eylül ayında domates (yalancı renk - YKÖ, K, Y)

Bölgede ekimi yapılan patlıcan ve biber benzer ekim tarihleri ve spektral yansımaları sahiptir (Tablo 6). Mayısın ilk haftası ekimi yapılır. Ağustos ve Eylül en yeşil ve gür olduğu aylardır. Ağustos sonu hasat başlar Ekim ortasında biter. Hasat işlemi bitse bile tarla işlenmezse biber ve patlıcanın kuruması zaman alabilir. Yani spektral yansıması yeşil ürün olarak devam eder. Arazi gerçeği verisi olarak kullanılan sırasıyla 34 ve 20 adet biber ve patlıcan parsellerinin aylara göre ortalama NDVI değeri değişimi sırasıyla Şekil 38 ve Şekil

39' da gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan biber ve patlıcan parsellerinin farklı aylardaki yansıma değişimleri Şekil 40- 42'de gösterilmiştir.



Şekil 38. Biber parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 39. Patlıcan parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 40. Mayıs ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)




Şekil 41. Eylül ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)




Şekil 42. Kasım ayında biber ve patlıcan (yalancı renk - YKÖ, K, Y)


Bölgede pamuğun ekimi Nisan ortasında yapılır Ekim sonu-Kasım başı hasat edilir (Tablo 6). Hasat işlemi bittikten sonra tarla işleninceye kadar yeşil bitki yansıması vermeye devam eder. Arazi gerçeği verisi olarak kullanılan 60 adet pamuk parselinin aylara göre ortalama NDVI değeri değişimi Şekil 43’ te gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bazı pamuk parsellerinin farklı aylardaki yansıma değişimleri Şekil 44-46’da gösterilmiştir.




Şekil 43. Pamuk parsellerinin ortalama NDVI değerlerinin aylara göre değişimi



Şekil 44. Mayıs ayında pamuk (yalancı renk - YKÖ, K, Y)




Şekil 45. Ağustos ayında pamuk (yalancı renk - YKÖ, K, Y)




Şekil 46. Kasım ayında pamuk (yalancı renk - YKÖ, K, Y)


Yonca yaklaşık 5 yıl arazide kalan bir bitkidir. 2-3 haftada bir hasat yapılır. Hasat için biçilen yerler yeşil olarak kalmaya devam eder. Biçilmeyen yerler sararır. Hasat tarihleri parselden parselde değişim gösterir. Arazi gerçeği verisi olarak kullanılan 22 adet yonca parselinin aylara göre ortalama NDVI değeri değişimi Şekil 47’ de gösterilmiştir. Yine, çalışmada arazi gerçeği verisi olarak kullanılan bazı yonca parsellerinin farklı aylardaki yansıma değişimleri Şekil 48-52’de gösterilmiştir.




Şekil 47. Yonca parsellerinin ortalama NDVI değerlerinin aylara göre değişimi




Şekil 48. Nisan ayında yonca (yalancı renk - YKÖ, K, Y)



Şekil 49. Haziran ayında yonca (yalancı renk - YKÖ, K, Y)



Şekil 50. Ağustos ayında yonca (yalancı renk - YKÖ, K, Y)



Şekil 51. Ekim ayında yonca (yalancı renk - YKÖ, K, Y)




Şekil 52. Kasım ayında yonca (yalancı renk - YKÖ, K, Y)

3.2.2. Görüntü Segmentasyonu

Çalışmada görüntü segmentasyonu, çoklu-çözünürlük segmentasyon (multi-resolution segmentation) yöntemi ile eCognition yazılımında gerçekleştirilmiştir. Bunun için *eCognition>Append New> Multiresolution Segmentation* komutu çalıştırılıp *ölçek (scale)*, *şekil (shape)* ve *kompaktlık (compactness)* parametreleri ve bu parametreler için sırasıyla 100, 0,1 ve 0,7 parametre değerleri ile işlem yapılmıştır. Girilen parametre değerleri José M. Peña-Barragán vd. (2011) tarafından gerçekleştirilen çalışmadan uyarlanmıştır [22].

Segmentasyon işlemi toplam 8 Sentinel 2 uydusu görüntüsü ve bu görüntülerden üretilen NDVI bantlarıyla yapılmıştır. Çalışma alanının bir kısmında segmentasyon sonucu Şekil 53'te gösterilmiştir.

Segmentasyon işlemi sonrasında oluşan her segment için, tüm bantlara ait ortalama (Eşitlik 5), standart sapma (Eşitlik 6), homojenlik (Eşitlik 7), farklılık (Eşitlik 8) ve entropi (Eşitlik 9) değerleri hesaplanmıştır. Hesaplanan bu değerler her segmentin özellik tablosuna yazdırılıp “.shp” uzantılı olarak kaydedilmiştir (Tablo 7).



Şekil 53. Çoklu çözünürlük segmentasyon sonucu elde edilen segmentler

Tablo 7. Elde edilen segmentlerin özellik değerleri

Segment ID	Hmj_1	...	Ent_1	...	Frk_1	...	Std_1	...	Agu_NDVI	...	Agu_4
0	0,0679	...	7,277	...	14,19	...	235,670887	...	0,245637	...	2303,2
1	0,0272	...	7,051	...	40,64	...	99,883585	...	0,521415	...	2393,6
2	0,0475	...	7,954	...	19,63	...	230,109395	...	0,228988	...	2641,1
3	0,0277	...	6,881	...	33,42	...	146,286179	...	0,455326	...	2322,3
.		.		.		.		.		.	
.		.		.		.		.		.	
.		.		.		.		.		.	
13367	0,0392	...	8,238	...	22,2	...	190,020753	...	0,331537	...	1918,6
13368	0,0209	...	6,55	...	30,73	...	90,737601	...	0,25294	...	1889,4
13369	0,0362	...	7,964	...	25,17	...	205,644434	...	0,330685	...	1805,2
13370	0,0349	...	7,715	...	28,94	...	170,22599	...	0,313037	...	1999,3

Tablo 7-9'daki sütunların açıklamaları şu şekildedir.

Hmj: Nisan ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarından başlayıp Kasım ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarına kadar olan toplam 40 bantın her segment için homojenlik değerleridir. Hmj_1'den Hmj_40'a kadardır.

Ent: Nisan ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarından başlayıp Kasım ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarına kadar olan toplam 40 bantın her segment için entropi değerleridir. Ent_1'den Ent_40'a kadardır.


Frk: Nisan ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarından başlayıp Kasım ayı görüntüsünün (M, Y, K, YKÖ, NDVI) bantlarına kadar olan toplam 40 bantın her segment için farklılık değerleridir. Frk_1'den Frk_40'a kadardır.

..._NDVI: Nisan ayı görüntüsünün (NDVI) bantından başlayıp Kasım ayı görüntüsünün (NDVI) bantına kadar olan toplam 8 bantın her segment için ortalama değerleridir. Nis_NDVI'den Kas_NDVI'a kadardır.


...(1,2,3,4): Nisan ayı görüntüsünün (M(1), Y(2), K(3), YKÖ(4)) bantlarından başlayıp Kasım ayı görüntüsünün (M(1), Y(2), K(3), YKÖ(4)) bantlarına kadar olan toplam 32 bantın her segment için ortalama değerleridir. Nisan_1'den Kas_4'e kadardır.

3.2.3. Segmentlerden Eğitim ve Test Alanlarına Değer Aktarılması

Arazi çalışması ve sonrasında ÇKS verilerinin değerlendirilmesi ile elde edilen arazi gerçeği verileri poligon formatındadır ve segment sınırları ile karşılaştırıldığında birden çok segmentin sınırı ile kesişebilmektedir. Bu duruma örnek Şekil 54'te gösterilmiştir. Dolayısıyla, sadece parseller ile örtüşen segmentlerin özellik değerlerini aktarabilmek için her arazi gerçeği verisine ait poligonun içinde kalacak şekilde poligonların ortasına nokta atılmıştır (Şekil 55). Atılan noktalara ArcGIS programının *spatial join* komutu ile segmentlerden tüm özelliklerin değerleri aktarılmıştır (Tablo 8-9).



Şekil 54. Parsel (kırmızı) ve segment (siyah) kesişimi



Şekil 55. Çalışma alanının bir bölümünde yer alan parsellerin orta noktaları

Tablo 8. ArcGIS spatial join fonksiyonu ile yapılan işlem sonrası oluşan eğitim verisi özellik tablosu

Eğitim Parsel No	Ürün	Hmj_1	...	Ent_1	...	Frk_1	...	Std_1	...	Agu_NDVI	...	Agu_4
0	zeytin	0,06	...	8,32	...	14,91	...	334,28	...	0,23	...	2683,40
1	bugday	0,06	...	8,32	...	16,80	...	136,48	...	0,13	...	3270,71
2	zeytin	0,04	...	8,41	...	26,43	...	149,27	...	0,27	...	2112,45
3	zeytin	0,07	...	7,67	...	17,41	...	343,57	...	0,22	...	2275,49
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
598	uzum	0,07	...	8,74	...	17,28	...	283,39	...	0,52	...	2910,26
599	bugday	0,04	...	6,31	...	34,20	...	114,13	...	0,21	...	2896,19
600	misir2	0,03	...	7,63	...	26,88	...	73,23	...	0,49	...	2880,23
601	bugday	0,03	...	6,61	...	27,85	...	161,57	...	0,33	...	2966,15

Tablo 9. ArcGIS spatial join fonksiyonu ile yapılan işlem sonrası oluşan test verisi özellik tablosu

Test Parsel No	Ürün	Hmj_1	...	Ent_1	...	Frk_1	...	Standard_1	...	Agu_NDVI	...	Agu_4
0	bugday	0,07	...	7,81	...	17,70	...	257,99	...	0,11	...	2497,32
1	zeytin	0,06	...	8,48	...	17,09	...	247,37	...	0,26	...	2415,19
2	zeytin	0,04	...	8,50	...	24,93	...	103,90	...	0,26	...	2073,67
3	bugday	0,06	...	7,07	...	23,29	...	75,46	...	0,38	...	2827,51
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
598	misir	0,04	...	7,20	...	26,45	...	62,06	...	0,64	...	2760,07
599	misir	0,08	...	7,68	...	16,31	...	180,05	...	0,69	...	3208,92
600	misir	0,03	...	7,47	...	26,45	...	117,96	...	0,70	...	3090,92
601	misir	0,07	...	7,40	...	18,85	...	147,76	...	0,69	...	3100,56

3.2.4. Rastgele Orman Algoritması ile Sınıflandırma

RO algoritması ile yapılan sınıflandırma işlemi R programında bulunan randomForest kütüphanesi kullanılarak yapılmıştır [46]. R ücretsiz bir yazılımdır ve ayrıca programlama dilidir. Shp formatında olan eğitim ve test verilerinin özelliklerini içeren tablolar csv formatında kaydedilmiştir. Kaydedilen csv uzantılı eğitim ve test verileri R programında okutulmuştur.

RO algoritmasının doğruluğunu artırmak için ağaç sayısı (*ntree*) ve rastgele özellik sayısı (*mtry*) için R programında EYDRO uygulaması oluşturulmuştur. EYDRO uygulamasının *mtry* ve *ntree* aşağıda gösterildiği gibidir.

ntree= 100'den 1000'e 100 artımla (100,200,300,...,900,1000)

mtry=1'den (2* özelliklerin toplamının karekökü)'ne 1 artımla (1,2,3,..., (bant sayısının karekökünün 2 katı))

Yukarıdaki algoritmada oluşan her kombinasyon için RO algoritması 3 kez çalıştırılmış ve en yüksek $\hat{K}$ değerini oluşturan RO modeli seçilmiştir. Son olarak tüm segmentler, en yüksek $\hat{K}$ değerini veren RO modelini kullanarak R programında bulunan *predict* fonksiyonu ile sınıflandırılmıştır. $\hat{K}$ değeri hata matrisini kullanarak doğruluk hesabı yapılan ve sıklıkla tercih edilen bir yöntemdir.

Bantların sınıflandırmadaki etkilerini de tespit edebilmek için yukarıda açıklanan sınıflandırma işlemi farklı bant kombinasyonları ile tekrarlanmıştır.

Çalışmada kullanılan bant kombinasyonları için aşağıdaki kısaltmalar kullanılmıştır.

$\text{Özellik}_{\text{Bant}}^{\text{Tarih}}$:

Özellik: Ortalama (Ort), standart sapma (Std), homojenlik (Hmj), farklılık (Frk) ve entropi (Ent).

Bant: Sentinel 2 uydularının Mavi, Yeşil, Kırmızı ve Yakın Kızılötesi bantları ve bu bantlardan üretilen NDVI bantları.

Tarih: Nisan, Mayıs, Haziran, Temmuz, Ağustos, Eylül, Ekim ve Kasım ayları.

M: Mavi Bant.

Y: Yeşil Bant.

K: Kırmızı Bant.

YKÖ: Yakın Kızılötesi Bant.

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

Ort: Segment ortalama değeri.


Std: Segment standart sapma değeri.

Hmj: Segment homojenlik değeri.

Frk: Segment farklılık değeri.

Ent: Segment entropi değeri.

RO algoritmasının çıktılarından birisi olan değişken önem derecesi hesabı incelendiğinde doku ve standart sapma bantlarının ($Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$) sınıflandırmaya katkısının diğer bantlara göre ciddi oranda az olduğu görülmüştür. Bu tespit üzerine doku ve standart sapma bantları sınıflandırma dışında bırakılarak sınıflandırma işlemi tekrar yapılmıştır. Elde edilen sonuçlara göre sınıflandırma doğruluğunun, [47] ve [48] tarafından yapılan çalışmalarda olduğu gibi az miktarda da olsa, düştüğü tespit edilmiştir. RO algoritmasının özellik önem derecesi fonksiyonu sonucunda çıkan en önemli 20 özellik Şekil 56'da gösterilmiştir.



Şekil 56. Çalışmada kullanılan bantlara ait özellik önem derecesi (variable importance) (200 bant içerisinde)

Tablo 10’da EYDRO’nun $Ort_{NDVI}^{May, Tem, Eyl}$ bantlarının kombinasyonu için farklı *ntree* ve *mtry* değerleri sonucu hesaplanan $\hat{K}$ değerleri ve *OOB* sonuçları gösterilmektedir. Burada en yüksek $\hat{K}$ değerini veren *ntree*, *mtry* ve *iterasyon* değerleri sırasıyla 700, 1 ve 3 olarak tespit edilmiştir Tablo 10. Dolayısıyla sınıflandırma işlemi tespit edilen *ntree* ve *mtry* değerlerinin oluşturduğu RO modeli ile gerçekleştirilmiştir. Diğer tüm özellik kombinasyonlarında aynı işlemler tekrarlanmıştır. Çalışmada kullanılan özellik (bant) kombinasyonları Tablo 11’ de verilmiştir.

Tablo 10. En önemli 3 bant ($Ort_{NDVI}^{May, Tem, Eyl}$) *ntree* ve *mtry* kombinasyonu $\hat{K}$ ve *OOB* değerleri

	$\hat{K}$	OOB	Ntree	Mtry	İterasyon
1	0,906912	0,125418	100	1	1
2	0,907058	0,122074	100	1	2
3	0,902894	0,120401	100	1	3
4	0,900801	0,128763	100	2	1
5	0,900849	0,132107	100	2	2
6	0,896633	0,128763	100	2	3
7	0,906927	0,125418	200	1	1
8	0,902834	0,118729	200	1	2
9	0,902899	0,128763	200	1	3
10	0,898712	0,133779	200	2	1
11	0,896713	0,135452	200	2	2
12	0,896644	0,128763	200	2	3
13	0,904927	0,120401	300	1	1
14	0,904945	0,122074	300	1	2
15	0,909189	0,115385	300	1	3
16	0,900893	0,128763	300	2	1
17	0,898687	0,135452	300	2	2
18	0,900816	0,130435	300	2	3
19	0,904942	0,120401	400	1	1
20	0,902884	0,120401	400	1	2
21	0,907108	0,118729	400	1	3
22	0,8987	0,12709	400	2	1
23	0,898709	0,133779	400	2	2
24	0,900812	0,125418	400	2	3
25	0,905014	0,120401	500	1	1
26	0,907073	0,120401	500	1	2
27	0,902809	0,115385	500	1	3
28	0,896571	0,123746	500	2	1
29	0,898709	0,132107	500	2	2

30	0,898697	0,133779	500	2	3
31	0,904995	0,123746	600	1	1
32	0,904961	0,123746	600	1	2
33	0,905021	0,117057	600	1	3
34	0,898697	0,132107	600	2	1
35	0,90292	0,132107	600	2	2
36	0,898683	0,128763	600	2	3
37	0,907006	0,123746	700	1	1
38	0,904942	0,123746	700	1	2
39	0,90924	0,123746	700	1	3
40	0,89658	0,123746	700	2	1
41	0,898765	0,130435	700	2	2
42	0,900867	0,132107	700	2	3
43	0,904999	0,117057	800	1	1
44	0,907129	0,117057	800	1	2
45	0,904942	0,122074	800	1	3
46	0,898765	0,133779	800	2	1
47	0,900867	0,132107	800	2	2
48	0,898709	0,132107	800	2	3
49	0,907006	0,120401	900	1	1
50	0,907129	0,115385	900	1	2
51	0,904999	0,120401	900	1	3
52	0,898697	0,132107	900	2	1
53	0,898765	0,128763	900	2	2
54	0,898705	0,125418	900	2	3
55	0,90924	0,120401	1000	1	1
56	0,907129	0,120401	1000	1	2
57	0,907129	0,122074	1000	1	3
58	0,898697	0,128763	1000	2	1
59	0,898687	0,128763	1000	2	2
60	0,900867	0,128763	1000	2	3

Tablo 11. Çalışmada kullanılan özellik (bant) kombinasyonları

	Özellik(bant) kombinasyonu	Açıklama
1	$Ort_{Tüm}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	Orijinal Bantlar + NDVI + Doku + SS
2	$Ort_{Tüm}^{Tüm}$	Orijinal Bantlar + NDVI
3	$Ort_{M,Y,K,YKÖ}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	Orijinal Bantlar + Doku + SS
4	$Ort_{NDVI}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	NDVI + Doku + SS
5	$Ort_{M,Y,K,YKÖ}^{Tüm}$	Yalnız orijinal Bantlar
6	$Ort_{NDVI}^{Tüm}$	Yalnız NDVI bantları
7	$Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	Doku+SS
8	$Ort_{NDVI}^{May,Tem,Eyl,Kas}$	En önemli 4 özellik (Ekim, Eylül, Temmuz, Mayıs NDVI)
9	$Ort_{NDVI}^{May,Tem,Eyl}$	En önemli 3 özellik (Eylül, Temmuz, Mayıs NDVI)
10	$Ort_{NDVI}^{May,Tem}$	En önemli 3 özellikten ikisi (Temmuz, Mayıs NDVI)
11	$Ort_{NDVI}^{May,Eyl}$	En önemli 3 özellikten ikisi (Eylül, Mayıs NDVI)
12	$Ort_{NDVI}^{Tem,Eyl}$	En önemli 3 özellikten ikisi (Eylül, Temmuz NDVI)
13	Ort_{NDVI}^{Eyl}	En önemli 3 özellikten biri (Eylül NDVI)
14	Ort_{NDVI}^{Tem}	En önemli 3 özellikten biri (Temmuz NDVI)
15	Ort_{NDVI}^{May}	En önemli 3 özellikten biri (Mayıs NDVI)

3.2.5. Doğruluk Analizleri

Doğruluk analizleri hata matrisi kullanarak ve parsel tabanlı yapılmıştır. Hata matrisi genel doğruluk hesaplamada en yaygın kullanılan yöntemdir. Sınıf sayımız a ise axa boyutunda bir hata matrisi oluşur. Bu matriste sol üstten sağ alta inen köşegende yer alan değerler doğru sınıflandırılmış parselleri, bu köşegenin dışındaki değerler yanlış sınıflandırılmış parselleri ifade etmektedir. Genel doğruluk doğru sınıflandırılmış parsellerin test verisinde bulunan

toplam parsel sayısına bölünmesi ile elde edilir. Her sınıf için *üretici doğruluğu* sınıfa ait doğru sınıflandırılmış parsellerin, yine aynı sınıfa ait test verisinde toplam parsel sayısına bölümü ile gerçekleştirilir. Ayrıca hata matrisinden $\hat{K}$ değerleri de hesaplanmıştır. $\hat{K}$ değeri (Eşitlik 11) hata matrisinde yer alan referans veri ile sınıflandırma verisi arasındaki korelasyonu ifade eder [49].

Örnek bir hata matrisi Tablo 12’de gösterilmektedir. Tablo 12’de verinin genel doğruluğu $(11+58+27+79+64+29+7+222+9+57)/597$ işlemi ile %94,30 olarak hesaplanır. Mısır sınıfı için *üretici doğruluğu* %95,18 (79/83) ve *kullanıcı doğruluğu* %96,34 (79/82) olarak hesaplanır. $\hat{K}$ değeri ise Eşitlik 11 ile hesaplanmaktadır.

$$Kappa (\hat{K}) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} X x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} X x_{+i})} \quad (11)$$

Eşitlik 11’de N hata matrisindeki toplam örnek sayısını, r hata matrisindeki satırların sayısını, x_{ii} kendi sınıfında sınıflandırılmış örnekleri, x_{+i} i satırının toplamını, x_{i+} i sütununun toplamını temsil etmektedir [23]. Tablo 12’deki hata matrisi için $\hat{K}$ değeri Eşitlik 11 ile 0,9281 olarak hesaplanır.

Tablo 12. Örnek Hata Matrisi

	Referans Veri										Satır
	Biber	Buğday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin	Toplam
Sınıflandırılmış Veri	Biber	11	0	0	0	0	0	0	0	0	11
	Buğday	0	58	0	0	4	0	0	1	1	64
	Domates	0	0	27	2	0	1	0	0	0	30
	Mısır	0	0	1	79	1	0	0	1	0	82
	Mısır2	0	2	0	0	64	0	0	1	0	67
	Pamuk	0	0	1	0	0	29	1	0	0	31
	Patlıcan	1	0	0	0	0	7	1	0	0	9
	Üzüm	5	0	1	2	0	0	2	222	0	233
	Yonca	0	0	0	0	0	0	0	9	0	9
	Zeytin	0	0	1	0	0	0	3	0	57	61
	Sütun										
	Toplam	17	60	31	83	69	30	10	227	11	597

4. BULGULAR VE DEĞERLENDİRMELER

Bu çalışmada R programı ortamında hazırlanan EYDRO ile en yüksek doğruluğu veren *ntree* ve *mtry* parametreleri seçilerek sınıflandırma işlemleri gerçekleştirilmiştir. Ayrıca sınıflandırma işlemleri R programında bulunan *randomForest* algoritmasında varsayılan parametreler ile de yapılmış ve sonuçlar karşılaştırılmıştır (Tablo 13). R programında varsayılan değerler, *ntree* için 500 ve *mtry* için özelliklerin toplam sayısının kareköküdür.

Tablo 13. Farklı özellik kombinasyonları için varsayılan RO ve EYDRO ile elde edilen $\hat{K}$ ve genel doğruluk değerlerinin karşılaştırması*

	Özellik Kombinasyonu	RO		EYDRO	
		$\hat{K}$	Genel Doğruluk	$\hat{K}$	Genel Doğruluk
1	$Ort_{Tüm}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0,9280	94,30	0,9344	94,81
2	$Ort_{Tüm}^{Tüm}$	0,9323	94,64	0,9365	94,97
3	$Ort_{M,Y,K,YKÖ}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0,9130	93,09	0,9279	94,30
4	$Ort_{NDVI}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0,8959	91,81	0,9238	93,97
5	$Ort_{M,Y,K,YKÖ}^{Tüm}$	0,9301	94,47	0,9344	94,81
6	$Ort_{NDVI}^{Tüm}$	0,9238	93,98	0,9303	94,47
7	$Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm},$ $Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0,7895	83,71	0,8117	85,43
8	$Ort_{NDVI}^{May,Tem,Eyl,Kas}$	0,9113	92,98	0,9156	93,30
9	$Ort_{NDVI}^{May,Tem,Eyl}$	0,9049	92,45	0,9092	92,80
10	$Ort_{NDVI}^{May,Tem}$	0,7531	81,23	0,7678	81,57
11	$Ort_{NDVI}^{May,Eyl}$	0,8545	88,43	0,8628	89,11
12	$Ort_{NDVI}^{Tem,Eyl}$	0,8387	87,26	0,8452	87,77
13	Ort_{NDVI}^{Eyl}	0,5735	66,16	0,5738	66,16
14	Ort_{NDVI}^{Tem}	0,6349	71,02	0,6349	71,02
15	Ort_{NDVI}^{May}	0,5860	67,50	0,5865	67,50

Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

*Daha fazla bant kombinasyonu Ek Tablo 16'da verilmektedir.

Ayrıca, sınıflandırma doğrulukları, tüm özellik kombinasyonları için ürün bazında da hesaplanmış olup elde edilen değerler Tablo 14’te verilmektedir. Tablo 14’te üstteki değerler *üretici doğruluğu* değerini, alttaki değerler ise *kullanıcı doğruluğu* değerini göstermektedir.


Tablo 14. Her ürün için tüm özellik kombinasyonlarında hesaplanmış *üretici doğruluğu* ve *kullanıcı doğruluğu* değerleri

	Özellik Kombinasyonu	Üretici Doğruluğu (Producer’s Accuracy) / Kullanıcı Doğruluğu (User’s Accuracy)									
		Biber	Bugday	Domates	Mısır	Mısır2	Pamuk	Patlıcan	Üzüm	Yonca	Zeytin
1	$Ort_{Tüm, Std_{Tüm}}$	70,59/	95,00/	83,87/	96,39/	95,65/	96,67/	70,00/	97,80/	90,91/	96,61/
	$Hmj_{Tüm, Frk_{Tüm}, Ent_{Tüm}}$	92,31	95,00	92,86	95,24	95,65	96,67	87,50	94,87	100,00	93,44
2	$Ort_{Tüm}$	70,59/	96,67/	87,10/	96,39/	94,20/	96,67/	80,00/	97,80/	81,82/	96,61/
		100,00	93,55	93,10	96,39	97,01	100,00	88,89	94,07	100,00	93,44
3	$Ort_{M,Y,K,YKÖ, Std_{Tüm}}$	70,59/	96,67/	87,10/	95,18/	92,75/	96,67/	60,00/	97,80/	81,82/	96,61/
	$Hmj_{Tüm, Frk_{Tüm}, Ent_{Tüm}}$	100,00	93,55	96,43	94,05	96,97	96,67	85,71	93,28	100,00	93,44
4	$Ort_{Tüm, Std_{NDVI}}$	64,71/	95,00/	74,19/	97,59/	95,65/	96,67/	80,00/	97,80/	63,64/	96,61/
	$Hmj_{Tüm, Frk_{Tüm}, Ent_{Tüm}}$	100,00	96,61	95,83	91,01	89,19	96,67	88,89	95,28	100,00	93,44
5	$Ort_{M,Y,K,YKÖ}$	70,59/	96,67/	83,87/	96,39/	94,20/	96,67/	80,00/	97,80/	81,82/	96,61/
		100,00	93,55	92,86	95,24	95,59	100,00	80,00	94,87	100,00	93,44
6	Ort_{NDVI}	70,59/	95,00/	83,87/	93,98/	97,10/	93,33/	70,00/	97,80/	90,91/	96,61/
		92,31	96,61	86,67	95,12	94,37	100,00	77,78	95,69	83,33	93,44
7	$Std_{Tüm, Hmj_{Tüm}}$	47,06/	81,67/	32,26/	92,77/	86,96/	76,67/	50,00/	98,24/	36,36/	86,44/
	$Frk_{Tüm, Ent_{Tüm}}$	88,89	75,38	83,33	91,67	80,00	95,83	83,33	84,47	100,00	94,44
8	$Ort_{May, Tem, Eyl, Kas, NDVI}$	70,59/	95,00/	80,65/	91,57/	95,65/	90,00/	70,00/	97,36/	90,91/	94,92/
		85,71	95,00	80,65	92,68	94,29	96,43	77,78	95,67	83,33	93,33
9	$Ort_{May, Tem, Eyl, NDVI}$	64,71/	95,00/	77,42/	90,36/	95,65/	90,00/	60,00/	97,36/	90,91/	96,61/
		84,62	95,00	77,42	91,46	94,29	96,43	75,00	95,67	83,33	91,94
10	$Ort_{May, Tem, NDVI}$	52,94/	60,00/	54,84/	86,75/	66,67/	66,67/	50,00/	96,04/	81,82/	93,22/
		75,00	60,00	51,52	84,71	63,89	80,00	71,43	94,78	75,00	90,16
11	$Ort_{May, Eyl, NDVI}$	64,71/	93,33/	70,97/	86,75/	86,96/	86,67/	70,00/	96,48/	63,64/	88,14/
		78,57	88,89	68,75	90,00	88,24	96,30	70,00	94,40	58,33	88,14
12	$Ort_{Tem, Eyl, NDVI}$	52,94/	85,00/	77,42/	89,16/	89,86/	76,67/	60,00/	96,04/	45,45/	88,14/
		75,00	87,93	77,42	90,24	92,54	88,46	54,55	91,60	71,43	80,00
13	$Ort_{Eyl, NDVI}$	47,06/	58,33/	48,39/	56,63/	56,52/	50,00/	60,00/	86,34/	36,36/	50,85/
		57,14	64,81	45,45	54,65	57,35	57,69	75,00	84,48	22,22	51,72
14	$Ort_{Tem, NDVI}$	58,82/	46,67/	48,39	85,54/	55,07/	40,00/	60,00/	88,11/	36,36/	67,80/
		58,82	47,46	71,43	78,89	54,29	50,00	46,15	86,58	25,00	71,43

15	Ort_{NDVI}^{May}	52,94/ 52,94	55,00/ 48,53	41,94/ 50,00	75,90/ 71,59	55,07/ 60,32	40,00/ 52,17	50,00/ 35,71	89,43/ 81,85	54,55/ 50,00	35,59/ 55,26
----	--------------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------

Kırmızı renkli değerler sütundaki en büyük değeri ifade etmektedir.

Tablo 13 incelendiğinde, en yüksek $\hat{K}$ değerini $Ort_{Tüm}^{Tüm}$ bant kombinasyonunun verdiği görülmektedir. Dolayısıyla, nesne tabanlı sınıflandırma işlemi, en yüksek $\hat{K}$ değerini veren bu kombinasyon ile oluşturulan RO modeli tüm segmentlere uygulanmak suretiyle gerçekleştirilmiştir. Elde edilmiş sınıflandırılmış görüntü Şekil 57’ de gösterilmiştir.



Şekil 57. Nesne-tabanlı sınıflandırma sonucu

Görüntü sınıflandırma işleminde doku bantlarının ($Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$) kullanılmasının doğruluğu her zaman artırmadığı hatta bazen düşürdüğü görülmüştür [50]. Bu çalışmada elde edilen sonuçlar incelendiğinde (Tablo 13) ilave olarak doku bantları eklenen tüm bant kombinasyonlarının doğruluğu az miktarda da olsa düşürdüğü görülmektedir. Örneğin ($Ort_{Tüm}^{Tüm}$) bant kombinasyonunda $\hat{K}$ değeri 0,9365 iken ($Ort_{Tüm}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$) bant kombinasyonunda $\hat{K}$ değeri 0,9344 olarak hesaplanmıştır. Benzer şekilde, ($Ort_{M,Y,K,YKÖ}^{Tüm}$) bant kombinasyonunda $\hat{K}$ değeri

0,9344 iken $(Ort_{M,Y,K,YKÖ}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm})$ bant kombinasyonunda $\hat{K}$ değeri 0,9279 olarak hesaplanmıştır. Yine, $(Ort_{NDVI}^{Tüm})$ kombinasyonunda $\hat{K}$ değeri 0,9303 iken $(Ort_{NDVI}^{Tüm}, Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm})$ kombinasyonunda $\hat{K}$ değeri 0,9238 olarak elde edilmiştir.

RO algoritmasının sahip olduğu özellik önem derecesi (variable importance) fonksiyonu ile en önemli bantlar tespit edilebilmektedir. Şekil 56 incelendiğinde en önemli bantların NDVI bantları olduğu görülmektedir. RO algoritmasının her düğümünde kullanılan değişkenler rastgele olarak seçildiği için özellik önem derecesinde küçük değişiklikler meydana gelebilmektedir. Bunun için RO algoritması 10 kez çalıştırılarak özellik önem dereceleri incelenmiştir. Yapılan inceleme sonucunda $Ort_{NDVI}^{May, Tem, Eyl, Kas}$ bantlarının ilk 4 önem derecesinde olduğu görülmüştür. İlk 4 önem derecesinde bulunan söz konusu bantlar ile EYDRO uygulaması çalıştırıldığında $\hat{K}$ değeri 0,9156 olarak hesaplanmıştır.

$Ort_{NDVI}^{May, Tem, Eyl, Kas}$ bantları ile RO sınıflandırma işlemi yapıldığında en önemli 3 bantın $Ort_{NDVI}^{May, Tem, Eyl}$ bantları olduğu görülmüştür. Söz konusu bantlar ile sınıflandırma işlemi yapıldığında $\hat{K}$ değeri 0,9092 olarak hesaplanmıştır. Bu değer, 200 bant ile yapılan sınıflandırma sonucuna göre yaklaşık %2-%3 oranında düşüktür. Dolayısıyla, elde edilen sonuçlar tarımsal yaz ürünlerinin sınıflandırılmasında doğru tarih ve bant seçiminin önemini göstermektedir. Doğru tarih ve bant seçiminde RO algoritmasının özellik önem derecesi fonksiyonunun yüksek doğruluklu sonuçlar verdiği görülmüştür.

Tarımsal ürünlerin sınıflandırılmasında ürünlerin ekim, gelişim ve hasat tarihlerinde görüntülerin alınması diğer ürünler ile arasındaki zamansal değişimi ortaya çıkardığı için önemlidir. Tek tarihte alınmış bir görüntü ile yapılacak işlemlerin, ürünlerin farklı tarihlerde zamansal değişimini yansıtmadığı için yetersiz olduğu görülmüştür. Örneğin Tablo 13' te $Ort_{NDVI}^{May, Tem, Eyl}$ bantları tekil olarak sınıflandırılmış ve $\hat{K}$ değerleri sırasıyla 0,5865, 0,6349, 0,5739 olarak elde edilmiştir.

Ort_{NDVI}^{May} bantı ile yapılan sınıflandırma incelendiğinde (Ek Tablo 15), Mısır2 öncesinde buğday ekilen mısır olduğu için Mayıs ayında mısır2 olarak bilinen tüm arazilerde buğday bulunduğu için buğday ve mısır2 sınıfları birbirleri ile karışmıştır. Benzer şekilde Mayıs ayında domates, biber, patlıcan, mısır ve pamuk ürünleri arazide toprağı kapatamayacak seviyede bulunduğu için bu ürünler arasında da karışma mevcuttur. Ayrıca, üzüm bağları Mayıs başında tam olarak yeşillenmediği için zeytin sınıfından da üzüm sınıfına geçiş olmuştur.

Ort_{NDVI}^{Tem} bantı ile yapılan sınıflandırma incelendiğinde (Ek Tablo 14), Temmuz ayında buğday tamamen hasat edilmiş durumdadır. Mısır2 sınıfında ikinci ürün olarak ekilen mısır ürünü ise en fazla 1-2 haftalıktır ve arazi çıplak durumdadır. Bu nedenle, buğday ve mısır2 sınıfları arasında yine ağırlıklı olarak birbirine geçiş olmuştur. Temmuz ayında domates, biber, patlıcan, mısır ve pamuk ürünleri genel olarak belirginleşse de her parseldeki ürünün kalite veya ekilme tarihi aynı olmadığı için farklı yansımalara sahiptir. Yani bu ürünlerde birbirine geçişler azalmakla beraber devam etmektedir.

Ort_{NDVI}^{Eyl} bantı ile yapılan sınıflandırma incelendiğinde (Ek Tablo 13), Eylül ayında belirgin olarak birbirine geçiş yapan ürünler pamuk ve mısır2'dir. Pamuk ve mısır2 Eylül ayında en belirgin yansımaya sahiptir. Eylül ayı başında mısır ve domates büyük oranda hasat edilmiştir. Yani bu ürünler boş arazi olan buğday, yeşil ürün yansımalarını kuvvetli biçimde vermediği için zeytin, hasat dönemi geçtiği için bazı üzüm parsellerine geçiş yapmıştır. Aynı zamanda Eylül ayında mısır hasat edildiği için zeytin bahçeleri de mısır olarak sınıflandırılmıştır.

Çalışma kapsamında ayrıca, iki tarihte alınmış görüntüler ile de sınıflandırma yapılmış ve elde edilen sonuçlar değerlendirilmiştir. Örneğin Tablo 13'te görüldüğü üzere $Ort_{NDVI}^{May,Tem}$ bantları, $Ort_{NDVI}^{May,Eyl}$ bantları ve $Ort_{NDVI}^{Tem,Eyl}$ bantları sınıflandırma sonuçları $\hat{K}$ değerleri sırasıyla 0,7678, 0,8628 ve 0,8452 olarak hesaplanmıştır.

$Ort_{NDVI}^{May,Tem}$ bantları ile yapılan sınıflandırma incelendiğinde (Ek Tablo 10), buğday ve mısır2 nin Mayıs ayında buğday olarak en yeşil zamanı ve Temmuz ayında da buğdayın hasat edilmiş ve mısır2 parsellerinde en fazla 1-2 haftalık mısır ürünü bulunduğu için buğday ve mısır2 birbirine geçiş yapmıştır. Ayrıca, domates, biber, patlıcan, mısır ve pamuk ürünleri özellikle Temmuz ayında bir miktar birbirinden ayrılabilse de bu ürünler tam olarak olgunlaşmadığı için ve parselden parsel bakımı ve ekim tarihleri az da olsa farklılık gösterdiği için birbirlerine geçiş olmaktadır.

$Ort_{NDVI}^{May,Eyl}$ bantları ile yapılan sınıflandırma incelendiğinde (Ek Tablo 11), en belirgin karışmanın mısır ve domates sınıfları arasında olduğu görülmektedir. Çünkü, mısır ve domates Mayıs ayında 1 aylık ürünlerdir ve benzer yansımalara sahiptir. Eylül ayında mısır ve domates büyük oranda hasat edildiği için yine benzer yansımalara sahip olmaktadır.

$Ort_{NDVI}^{Tem,Eyl}$ bantları ile yapılan sınıflandırma incelendiğinde (Ek Tablo 12), sınıflar arasında belirgin bir geçiş olmamakla beraber zeytin ve buğday sınıfları arasında bir miktar karışma

mevcuttur. Çünkü buğdayın arazide bulunduğu Mayıs ayı görüntüsü sınıflandırmaya dahil edilmemiştir.

En önemli 4 bant ($Ort_{NDVI}^{May, Tem, Eyl, Kas}$) ile yapılan sınıflandırma incelendiğinde (Ek Tablo 8), en önemli karışımın domates ve mısır sınıfları arasında olduğu gözlenmiştir. En önemli 4 bant ile yapılan sınıflandırma tüm bantlar ile yapılan sınıflandırmadan %2 oranında düşük $\hat{K}$ değeri vermiştir. Bu düşüşün sebebi genel olarak mısır ve domates sınıfları arasındaki karışmadır. Bu nedenle, tüm ürünleri tam olarak ayırabilmek için tüm ürünlerin ayırıcı dönemlerini içeren tarihlerde görüntülerin alınması önem arz etmektedir. Ancak, özel olarak tespit edilmek istenen ürün varsa sadece o ürünün diğerlerinden ayrıldığı tarihlerde görüntü alınması gerekmektedir. Ya da varsa ilgili ürünü ayıran bir özelliğin (bantın) kullanılması gerekmektedir.

Bu çalışmada, tarımsal yaz ürünlerin çok zamanlı Sentinel 2 uydu görüntülerinden RO sınıflandırma algoritmasıyla tespit edilmesinde 0,9365 $\hat{K}$ değerine ulaşılmış olup bu değer oldukça yüksek bir doğruluk değeridir.

Bu çalışma kapsamında R programında hazırlanan EYDRO'nun $\hat{K}$ değerini bant kombinasyonuna göre değiştirmekle birlikte yaklaşık %3 oranına kadar artırdığı görülmüştür. Ancak, Tablo 13'ten de görüleceği üzere EYDRO'nun doğruluğu artırdığı kombinasyonlar bant sayısının fazla olduğu kombinasyonlardır. Bunun nedeni, bant sayısı azaldıkça RO algoritmasındaki rastgele özellik seçimi parametresinin kullanacağı alternatif özelliklerin de azalmasıdır. Bu sebeple bant sayısının az olduğu kombinasyonlarda doğruluk önemsenmeyecek derecede değişmekte veya hiç değişiklik olmamaktadır.

Sentinel 2 uydu görüntülerine ücretsiz olarak ulaşılabilmesi, konumsal çözünürlüğün (10 m) orta büyüklükteki tarımsal ürün parsellerinin bulunduğu alanlardaki tarımsal uygulamalar için yeterli olması ve 5 gün zamansal çözünürlüğe sahip olması Sentinel 2 uydu görüntülerini tarımsal ürün deseni için çok kıymetli hale getirmiştir. Bu çalışmada da görüldüğü üzere Sentinel 2 uydu görüntüleri tarımsal ürün deseni tespitinde son derece yüksek doğruluk vermiştir.

Arazi gerçeği verileri makine öğrenme algoritmalarında modelin eğitilmesinde kullanılmaktadır. Arazi gerçeği verileri için arazi çalışmaları yapılmalıdır. Ya da arazi çalışmaları yerine geçebilecek tarımsal ürün parselindeki ürün bilgisini gösterebilecek bir veriye ihtiyaç duyulmaktadır. Ülkemizde çiftçilere destekleme verilirken ekecekleri ürünler sorulmakta ve ürün bilgisi kayıt altına alınmaktadır. Bu sisteme çiftçi kayıt sistemi (ÇKS)

denilmektedir. Bu çalışma boyunca gerçekleştirilen işlemlerden, ÇKS verilerinin arazi gerçeği verisi olarak kullanılabilmesi için birtakım işlemlerden ve analizlerden geçirilmesi gerektiği tespit edilmiştir.

Çok bantlı veri setlerinde RO algoritmasının, belirlenen bir eşik değerin altı ve üstü (binary) olarak gruplama yaparak çalıştığı için işlem hızının yüksek olduğu görülmüştür. Örneğin 8 çok zamanlı görüntü (8x4 bant=32 bant) en büyük olasılık sınıflandırma metoduyla sınıflandırılma işlemi başlatılmış ancak verinin boyutunun büyüklüğü sebebiyle işlem tamamlanamamıştır. Aynı şekilde, 5 çok zamanlı görüntü (5x4 bant=20 bant) en büyük olasılık sınıflandırma metoduyla sınıflandırılmıştır. Ancak sınıflandırma işlemi 1 saat 23 dakikada tamamlanmıştır. 8 çok zamanlı görüntünün RO algoritmasıyla sınıflandırılması ise nesne tabanlı yapıldığında 5 saniye, piksel tabanlı yapıldığında 3 dakikada içerisinde tamamlanmıştır.

Tablo 14 incelendiğinde üzüm sınıfı sınıflandırma doğruluğunun en yüksek olduğu kombinasyonun Doku ve Standart Sapma bant kombinasyonu olduğu görülmektedir. Yani Sentinel 2 uydu görüntüsü ile nesne tabanlı hesaplanan doku ve standart sapma bantlarının üzüm bağlarının sınıflandırılmasında önemli olduğu görülmüştür.

5. SONUÇLAR

- Çalışma kapsamında R yazılımında, RO algoritmasının ağaç sayısı (n_{tree}) ve rastgele özellik sayısı (m_{try}) parametrelerinin otomatik olarak değiştirilip en yüksek doğruluğun elde edilmesi için en uygun parametre değerlerini seçen bir uygulama (EYDRO) yazılmıştır. Bu çalışmada elde edilen sonuçlara göre, EYDRO $\hat{K}$ değerini, kullanılan bant kombinasyonuna göre değişmekle beraber, yaklaşık %3 oranına kadar artırmıştır.
- Çalışmada sınıflandırma işlemi 15 farklı bant kombinasyonu kullanılarak yapılmıştır. Doku ve standart sapma özellikleri bantlarının ilave edildiği kombinasyonlarda sınıflandırma doğruluğunda artış olmamış hatta azalma olmuştur.
- RO algoritmasının özellik önem derecesi fonksiyonu kullanılarak en önemli bantlar ve görüntü tarihleri tespit edilmiştir. Özellik önem derecesi fonksiyonu ile en önemli 4 bant, NDVI bantları olarak belirlenmiştir. En önemli 4 bantın görüntü tarihleri olarak Mayıs, Temmuz, Eylül ve Ekim ayları belirlenmiştir. Ürünlerin zamansal gelişimleri incelendiğinde bu tarihlerin ürünler arasında ayırım yapılmasına olanak veren tarihler olduğu görülmektedir. En önemli 4 bant ($Ort_{NDVI}^{May, Tem, Eyl, Kas}$) ile yapılan sınıflandırmanın doğruluğu tüm bantlar (200 bant) ile yapılan sınıflandırmanın doğruluğundan sadece %2 oranında düşük olduğu hesaplanmıştır.
- Bir ürünün diğer ürünlerden ayrılmasında ürünlerin zamansal değişimi büyük etkiye sahiptir. Bu zamansal değişimi yansıtmayan tarihler ile sınıflandırma yapıldığında doğruluğun ciddi oranlarda düştüğü tespit edilmiştir. Çünkü, tek tarihlilikte bazı ürünler hiç bulunmamakta, bazı ürünler ise benzer spektral yansıma vermektedir. Bu sebeple, sınıflandırmada ürünlerin zamansal değişimini (ekim, gelişim, olgunluk ve hasat) gösteren çoklu tarihli görüntülerin kullanılması önem arz etmektedir.
- Bu çalışmada elde edilen sonuçlara göre, 10 metre konumsal çözünürlüğe sahip Sentinel-2 uydu görüntülerinin tarımsal ürün tespiti için yeterli olduğu görülmüştür. Aynı zamanda, sınıflandırmada Sentinel uydu görüntülerinin yalnız 10m konumsal çözünürlüklü mavi, yeşil, kırmızı ve kızılötesi bantları ile bu bantlardan elde edilen NDVI bantların kullanılmasıyla yüksek doğru değerine ulaşılabildiği görülmüştür.
- Bu çalışmada elde edilen sonuçlara göre, çalışma alanı Gediz Ovası'nda bulunan yaz tarımsal ürünlerin Sentinel-2 uydu görüntüleri ile tespitinde en önemli tarihler Mayıs,

Temmuz ve Eylül ayları olarak belirlenmiştir. Ayrıca, yaz tarımsal ürün tespitinde en önemli bantların NDVI bantları olduğu tespit edilmiştir.

- RO algoritmasının her düğümde rastgele özellik seçilmesi ve ağaçların budanmaması algoritmanın doğruluğunu artırmaktadır. Ayrıca RO algortimasında her düğüm için bir eşik değeri belirlenip ilgili düğümde kullanılan görüntüdeki pikseller eşik değerin altı ve üstü olarak ikiye (binary) ayrılır. Bu şekilde bir ayırmanın yapılması işlem yükünü azaltmaktadır. Bu sebeple, RO algoritmasının çok hızlı bir şekilde sınıflandırma yaptığı görülmüştür. Algoritmanın hızı en yaygın kullanılan en büyük olasılık sınıflandırma algoritması hızı ile karşılaştırılmıştır. Bunun için, 8 çok zamanlı görüntünün ($8 \times 4 = 32$) en büyük olasılık sınıflandırma algoritmasıyla sınıflandırılma işlemi başlatılmış ancak, verinin boyutunun büyüklüğü sebebiyle işlem tamamlanamamıştır. Aynı şekilde, 5 çok zamanlı görüntü ($5 \times 4 = 20$) en büyük olasılık sınıflandırma algortimasıyla sınıflandırılmıştır fakat sınıflandırma işlemi 1 saat 23 dakikada tamamlanmıştır. 8 çok zamanlı görüntünün RO algoritmasıyla sınıflandırılması, nesne tabanlı olarak yapıldığında 5 saniye, piksel tabanlı olarak yapıldığında 3 dakikada içerisinde tamamlanmıştır.
- ÇKS verileri çiftçinin beyanına dayalı olarak hazırlanmaktadır. Bu sebeple hatalar olabilmektedir. ÇKS verilerindeki ürün cinsleri uydu görüntüleri ile görsel olarak teyit edildiğinde veya arazi çalışmaları esnasında ürün cinsi tespit edilen parseller baz alınarak bulunduğu ürün cinsinin yansımaları veren ÇKS parselleri belirlendiğinde ÇKS verilerinin arazi gerçeği verileri olarak kullanılabileceği kanaatine varılmıştır.
- Bu çalışmadan elde edilen sonuçlara göre, ÇKS verilerindeki hataların tespit edilebildiği görülmüştür.
- ÇKS verilerinde ürün cinsi bilgisi bulunmayan parsellerin ürün cinsleri tespit edilmiştir. Böylelikle, alanda bulunan tüm parsellerdeki ürün cinsleri tespit edildiği için rekolte tahmini ve bölgedeki ürün tipinin yıllar içindeki değişiminin izlenmesi gibi konularda daha yüksek doğruluklu sonuçlar elde edilebilecektir.
- Tablo 13’de verilen sonuçlara göre, EYDRO’nun bant sayısı arttıkça doğruluğa olumlu etkisi olduğu görülmektedir. Tek bantla yapılan sınıflandırma sonuçlarına ise neredeyse hiç olumlu etkisi olmamaktadır.

6. ÖNERİLER

- Ücretsiz olarak görüntüleri elde edilebilen Sentinel-2 uyduları ile her yıl tarımsal alanlar değerlendirilip rekolte tahmini yapılabilir. Yine Sentinel-2 uydu görüntüleri ile ürünlerin yıldan yıla değişimi gözlenip kuraklık, iklim değişikliği vb durumların tarıma etkisi gibi analizler yapılabilir. Ayrıca, Sentinel-2 uydu görüntüleri ile çiftçilere ürün ekimi karşılığı verilen desteklemelerin, ürünün ekilip ekilmediğinin kontrolü yapılarak desteklemelerin doğru kişilere ulaşması sağlanabilir.
- Tarımsal ürünlerin uydu görüntüleri ile tespitinde NDVI bantlarının kullanılması, tüm bantların kullanılmasına göre neredeyse aynı doğruluk sonucunu vermektedir. Bu sebeple, işlem yükünü azaltmak için tüm bantlar yerine sadece NDVI bantları ile sınıflandırma yapılabilir.
- Yüksek çözünürlüklü veya ücretli uydularla talep doğrultusunda tarımsal ürünlerin tespiti için görüntü elde edilecekse Gediz ovası için en önemli tarihler olan Mayıs, Temmuz ve Eylül aylarına ait görüntüler alınmalıdır.
- Çalışma, ürünlerin farklı zamansal değişiminin olduğu alanlarda yapıp sonuçlar karşılaştırılabilir.

KAYNAKLAR

- [1] United-Nations, World population prospects: the 2015 revision, %1 içinde *In: Population Division of the Department of Economic and Social Affairs of the United Nations Secretariat*, New York, **2015a**.
- [2] T. M. Lillesand ve R. W. Kiefer, Remote Sensing and Image Interpretation, **1979**.
- [3] M. Ozdogan ve C. E. Woodcock, Resolution dependent errors in remote sensing of cultivated areas, *Remote Sensing of Environment*, no. 103, p. 203–217, **2006**.
- [4] S. P. Thenkabail, C. M. Biradar, P. Noojipady,, V. Dheeravath, Y. Li, M. Velpuri, M. Gumma, O. Gangalakunta, H. Turrall, X. Cai, J. Vithanage, M. A. Schull ve R. Dutta, Global irrigated area map (GIAM), derived from remote sensing, for the end of the last millennium, *International Journal of Remote Sensing*, no. 30, p. 3679–3733, **2009a**.
- [5] P. Thenkabail, G. J. Lyon, H. Turrall ve C. M. Biradar, Remote Sensing of Global Croplands for Food Security, %1 içinde *CRC Press/Taylor and Francis Group*, Boca Raton/Florida, **2009b**.
- [6] V. Dheeravath, P. S. Thenkabail, G. Chandrakantha, P. Noojipady, G. Reddy, C. M. Biradar, M. K. Gumma ve M. Velpuri, Irrigated areas of India derived using MODIS 500 m time series for the years 2001-2003, *ISPRS Journal of Photogrammetry and Remote Sensing*, no. 65, p. 42–59, **2010**.
- [7] P. S. Thenkabail, M. A. Hanjra, V. Dheeravath ve M. Gumma, A holistic view of global croplands and their water use for ensuring global food security in the 21st century through advanced remote sensing and non-remote sensing approaches, *Remote Sensing*, no. 2, p. 211–261, **2010**.
- [8] M. K. Gumma, A. Nelson, P. S. Thenkabail ve A. N. Singh, Mapping rice areas of South Asia using MODIS multitemporal data, *Journal of Applied Remote Sensing*, no. 26, **2011**.
- [9] P. S. Thenkabail, M. A. Hanjra, V. Dheeravath ve M. Gumma, Global croplands and their water use remote sensing and non-remote sensing perspectives, %1 içinde *Advances in Environmental Remote Sensing: Sensors, Algorithms, and Applications*, Florida, **2011**.
- [10] P. Thenkabail ve Z. Wu, An automated cropland classification algorithm (ACCA) for Tajikistan by combining Landsat, MODIS, and secondary data, *Remote Sensing*, no. 4, p. 2890–2918, **2012**.
- [11] M. Immitzer, F. Vuolo ve C. Atzberger, First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe, *remote sensing*, no. 8, p. 166, **2016**.
- [12] C. Gómez, J. C. White ve M. A. Wulder, Optical remotely sensed time series data for land cover classification: a review, *ISPRS J. Photogramm. Remote Sens.*, no. 116, pp. 55-72, **2016**.
- [13] J. A. Long, R. L. Lawrence, M. C. Greenwood, L. Marshall ve P. R. Miller, Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest, *GISci. Remote Sens.*, no. 50, p. 418–436, **2013**.

- [14] D. Arvor, M. Jonathan, M. P. Meirelles, V. Dubreuil ve L. Durieux, Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil, *Int. J. Remote Sens.*, no. 32, p. 7847–7871, **2011**.
- [15] V. Maus, G. Camara, R. Cartaxo, A. Sanchez, F. M. Ramos ve G. D. Queiroz, A time-weighted dynamic time warping method for land-use and land-cover mapping, *IEEE J. Select. Top. Appl. Earth Observ. Remote Sens*, pp. 1-11, **2016**.
- [16] C. Senf, P. J. Leitão, D. Pflugmacher, S. van der Linden ve S. Hostert, Mapping land cover in complex Mediterranean landscapes using Landsat: improved classification accuracies from integrating multi-seasonal and synthetic imagery, *Remote Sens. Environ.*, no. 156, p. 527–536, **2015**.
- [17] H. Müller, P. Rufin, P. Griffiths, A. B. Siqueira ve P. Hostert, Mining dense Landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape, *Remote Sens. Environ.*, no. 156, p. 490–499, **2015**.
- [18] M. TURKER ve M. ARIKAN, 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**.
- [19] P. Serra ve X. Pons, Monitoring farmers' decisions on Mediterranean irrigated crops using satellite image time series, *International Journal of Remote Sensing*, no. 29(8), p. 2293–2316, **2008**.
- [20] C. S. MURTHY, P. V. RAJU ve K. V. BADRINATH, Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks, *INT. J. REMOTE SENSING*, cilt 24, no. 23, p. 4871–4890, **2003**.
- [21] V. Simonneaux, B. Duchemin, D. Helson, S. Er-Raki, A. Oliosio ve G. A. Chehbouni, The use of high-resolution image time series for crop classification and evapotranspiration estimate over an irrigated area in central Morocco, *International Journal of Remote Sensing* , no. 29(1), p. 95, **2008**.
- [22] 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**.
- [23] 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**.
- [24] USGS, Earthexplorer, [Çevrimiçi]. Available: <https://earthexplorer.usgs.gov>. [Erişildi: 25 09 2017].
- [25] 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 Sens. Environ.*, no. 120, p. 25–36, **2012**.
- [26] Z. Malenovský, H. Rott, J. Cihlar, E. M. Schaepman, G. García-Santos, R. Fernandes ve M. Berger, Sentinels for science: Potential of Sentinel-1, -2 and -3 missions for scientific observations of ocean, cryosphere, and land, *Remote Sens. Environ.*, no. 120, p. 91–101, **2012**.

- [27] 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**.
- [28] O. Csillik ve M. Belgiu, Cropland Mapping from Sentinel-2 time series data using object-based image analysis, Wageningen, **2017**.
- [29] M. Belgiu ve O. Csillik, Sentinel-2 cropland mapping using pixel-based and object-based and timeweighted dynamic time warping analysis, *Remote Sensing of Environment*, cilt 204, pp. 509-523, **2018**.
- [30] S. Ferrant, A. Selles, M. L. Page, P.-A. Herrault, C. Pelletier, A. Al-Bitar, S. Mermoz, S. Gascoin, A. Bouvet, M. Saqalli, B. Dewandel, Y. Caballero, S. Ahmed, J.-C. Maréchal ve Y. Kerr, Detection of Irrigated Crops from Sentinel-1 and Sentinel-2 Data to Estimate Seasonal Groundwater Use in South India, *remote sensing*, cilt 1019, no. 9, pp. 1-21, **2017**.
- [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] W. J. De Wit ve P. J. Clevers, Efficiency and accuracy of per-field classification for operational crop mapping, *Int. J. Remote Sens*, no. 25, p. 4091–4112, **2004**.
- [33] Y. Pan, T. Hu, X. Zhu, J. Zhang ve X. Wang, Mapping cropland distributions using a hard and soft classification model, *IEEE Trans. Geosci. Remote Sens*, no. 50, p. 4301–4312, **2012**.
- [34] D. B. Wardlow, L. S. Egbert ve H. J. Kastens, Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains, *Remote Sensing of Environment*, no. 108(3), p. 290–310, **2007**.
- [35] D. B. Wardlow ve L. S. Egbert, Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains, *Remote Sensing of Environment*, no. 112(3), p. 1096–1116, **2008**.
- [36] 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**.
- [37] 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**.
- [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, *IGARSS*, pp. 174-177, **2012**.
- [39] Z. Wu, P. S. Thenkabail ve J. P. Verdin, Automated Cropland Classification Algorithm (ACCA) for California Using Multi-sensor Remote Sensing, *PHOTOGRAMMETRIC ENGINEERING & REMOTE SENSING*, cilt 80, no. 1, p. 81–90, **2014**.

- [40] B. Lowe ve A. Kulkarni, MULTISPECTRAL IMAGE ANALYSIS USING RANDOM FOREST, *International Journal on Soft Computing*, **2015**.
- [41] A. Kulkarni ve A. Shrestha, Multispectral Image Analysis using Decision Trees, (IJACSA) *International Journal of Advanced Computer Science and Applications*, cilt 8, no. 16, pp. 11-18, **2017**.
- [42] <https://www.investopedia.com/terms/g/gini-index.asp>, [Çevrimiçi]. [Erişildi: 18 11 2017]
- [43] A. A. Gitelson, Y. J. Kaufman, R. Stark ve D. Rundquisk, Novel Algorithms For Remote Estimation of Vegetation Fraction, *Remote Sensing of Environment*, pp. 76-82, **2002**.
- [44] 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**.
- [45] F. Pacifici, M. Cihini ve W. Emery, A neural network approach using multiscale textural metrics from very high-resolution panchromatic imagery for urban land-use classification, *Remote Sensing of Environment*, pp. 1276-1296, **2009**.
- [46] R, cran.r-project, [Çevrimiçi]. Available: <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>. [Erişildi: 13 11 2017].
- [47] R. Devadasa, R. J. Denham ve M. Pringle, SUPPORT VECTOR MACHINE CLASSIFICATION OF OBJECT-BASED DATA FOR CROP MAPPING, USING MULTI-TEMPORAL LANDSAT IMAGERY, %1 içinde *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Melbourne, Australia, **2012**.
- [48] L. Breiman, Random forests, *Machine learning*, **2001**.
- [49] J. Cohen, A coefficient of agreement for nominal scales, *Educ. Psychol. Meas.*, no. 20, pp. 37-46, **1960**.
- [50] 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**.

7. EKLER

Farklı bant kombinasyonlarında sınıflandırma işlemi hata matrisleri

Orijinal görüntüler + NDVI+ Doku + SS dan oluşan 200 bantlık veri seti

Ek Tablo 1. Orijinal Bant + NDVI + Doku + SS bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	1	0	0	0
bugday	0	57	0	0	2	0	0	0	0	1
domates	0	0	26	1	0	1	0	0	0	0
misir	0	0	2	80	1	0	0	1	0	0
misir2	0	2	0	0	66	0	0	0	1	0
pamuk	0	0	1	0	0	29	0	0	0	0
patlican	0	0	0	0	0	0	7	1	0	0
uzum	5	1	1	2	0	0	2	222	0	1
yonca	0	0	0	0	0	0	0	0	10	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall Statistics

Accuracy : 0.9481
95% CI : (0.9271, 0.9644)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9344
McNemar's Test P-Value : NA

*EYDRO ile en yüksek doğruluğu ntree=100 mtry=22 iterasyon=3 vermiştir.

Orijinal görüntüler + NDVI dan oluşan 40 bantlık veri seti

Ek Tablo 2. Orijinal Bant + NDVI bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	0	0	0	0
bugday	0	58	0	0	3	0	0	0	0	1
domates	0	0	27	1	0	1	0	0	0	0
misir	0	0	1	80	1	0	0	1	0	0
misir2	0	1	0	0	65	0	0	0	1	0
pamuk	0	0	0	0	0	29	0	0	0	0
patlican	0	0	0	0	0	0	8	1	0	0
uzum	5	1	2	2	0	0	2	222	1	1
yonca	0	0	0	0	0	0	0	0	9	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall Statistics

Accuracy : 0.9497
95% CI : (0.929, 0.9658)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9365
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=6 iterasyon=1 vermiştir.

Orijinal görüntüler + Doku + SS bantlardan oluşan 192 bantlık veri seti

Ek Tablo 3. Orijinal + Doku + SS bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	0	0	0	0
bugday	0	58	0	0	3	0	0	0	0	1
domates	0	0	27	1	0	0	0	0	0	0
misir	0	0	1	79	2	1	0	1	0	0
misir2	0	1	0	0	64	0	0	0	1	0
pamuk	0	0	0	0	0	29	1	0	0	0
patlican	0	0	0	0	0	0	6	1	0	0
uzum	5	1	2	3	0	0	3	222	1	1
yonca	0	0	0	0	0	0	0	0	9	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall statistics

Accuracy : 0.943
95% CI : (0.9213, 0.9602)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9279
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=24 iterasyon=2 vermiştir.

NDVI + Doku + SS bantlardan oluşan 168 bantlık veri seti

Ek Tablo 4. NDVI + Doku + SS bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	11	0	0	0	0	0	0	0	0	0
bugday	0	57	0	0	1	0	0	0	0	1
domates	0	0	23	0	1	0	0	0	0	0
misir	0	0	5	81	1	1	0	1	0	0
misir2	0	3	0	1	66	0	0	0	4	0
pamuk	0	0	1	0	0	29	0	0	0	0
patlican	0	0	0	0	0	0	8	1	0	0
uzum	6	0	1	1	0	0	2	222	0	1
yonca	0	0	0	0	0	0	0	0	7	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall statistics

Accuracy : 0.9397
95% CI : (0.9175, 0.9574)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9238
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=24 iterasyon=1 vermiştir.

Orijinal bantlardan oluşan 32 bantlık veri seti

Ek Tablo 5. Orijinal bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	0	0	0	0
bugday	0	58	0	0	3	0	0	0	0	1
domates	0	0	26	1	0	1	0	0	0	0
misir	0	0	2	80	1	0	0	1	0	0
misir2	0	2	0	0	65	0	0	0	1	0
pamuk	0	0	0	0	0	29	0	0	0	0
patlican	0	0	1	0	0	0	8	1	0	0
uzum	5	0	1	2	0	0	2	222	1	1
yonca	0	0	0	0	0	0	0	0	9	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall statistics

Accuracy : 0.9481
95% CI : (0.9271, 0.9644)
No Information Rate : 0.3802
P-value [Acc > NIR] : < 2.2e-16

Kappa : 0.9344
McNemar's Test P-Value : NA

* EYDRO en yüksek doğruluğu ntree=900 mtry=7 iterasyon=1 vermiştir.

NDVI bantlarından oluşan 8 bantlık veri seti

Ek Tablo 6. NDVI bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	1	0	0	0
bugday	0	57	0	0	1	0	0	0	0	1
domates	0	0	26	3	0	1	0	0	0	0
misir	0	0	2	78	0	1	0	1	0	0
misir2	0	3	0	0	67	0	0	0	1	0
pamuk	0	0	0	0	0	28	0	0	0	0
patlican	0	0	1	0	0	0	7	1	0	0
uzum	5	0	1	1	0	0	2	222	0	1
yonca	0	0	0	1	1	0	0	0	10	0
zeytin	0	0	1	0	0	0	0	3	0	57

Overall statistics

Accuracy : 0.9447
95% CI : (0.9232, 0.9616)
No Information Rate : 0.3802
P-value [Acc > NIR] : < 2.2e-16

Kappa : 0.9303
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=4 iterasyon=1 vermiştir.

Doku + SS bantlardan oluşan 160 bantlık veri seti

Ek Tablo 7. Doku + SS bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	8	0	0	0	0	1	0	0	0	0
bugday	0	49	6	1	5	1	1	0	1	1
domates	0	0	10	0	0	0	1	1	0	0
misir	0	1	4	77	0	0	0	1	1	0
misir2	2	5	2	0	60	1	1	1	3	0
pamuk	0	0	1	0	0	23	0	0	0	0
patlican	0	0	0	0	0	0	5	1	0	0
uzum	7	4	7	5	3	4	2	223	2	7
yonca	0	0	0	0	0	0	0	0	4	0
zeytin	0	1	1	0	1	0	0	0	0	51

Overall statistics

Accuracy : 0.8543
95% CI : (0.8234, 0.8816)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.8117
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=200 mtry=24 iterasyon=3 vermiştir.

Birçok deneme sonucunda sürekli en önemli 4 bant olarak tespit edilen Eylül, Temmuz, Mayıs ve Ekim NDVI bantlarından oluşan veri seti

Ek Tablo 8. En önemli 4 bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	12	0	0	0	0	0	1	1	0	0
bugday	0	57	0	0	1	0	0	0	0	2
domates	0	0	25	5	0	1	0	0	0	0
misir	0	0	3	76	1	1	0	1	0	0
misir2	0	3	0	0	66	0	0	0	1	0
pamuk	0	0	1	0	0	27	0	0	0	0
patlican	0	0	0	0	0	1	7	1	0	0
uzum	5	0	1	1	0	0	2	221	0	1
yonca	0	0	0	1	1	0	0	0	10	0
zeytin	0	0	1	0	0	0	0	3	0	56

Overall statistics

Accuracy : 0.933
95% CI : (0.9099, 0.9517)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9156
McNemar's Test P-Value : NA

* EYDRO en yüksek doğruluğu ntree=600 mtry=2 iterasyon=2 vermiştir.

En önemli 3 bant olan Eylül, Temmuz ve Mayıs NDVI bantlarından oluşan veri seti

Ek Tablo 9. En önemli 3 bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	11	0	0	0	0	0	2	0	0	0
bugday	0	57	0	0	2	0	0	0	0	1
domates	0	0	24	6	0	1	0	0	0	0
misir	0	0	5	75	0	1	0	1	0	0
misir2	0	3	0	0	66	0	0	0	1	0
pamuk	1	0	0	0	0	27	0	0	0	0
patlican	0	0	0	0	0	1	6	1	0	0
uzum	5	0	1	1	0	0	2	221	0	1
yonca	0	0	0	1	1	0	0	0	10	0
zeytin	0	0	1	0	0	0	0	4	0	57

Overall Statistics

Accuracy : 0.928
95% CI : (0.9042, 0.9474)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9092
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=300 mtry=1 iterasyon=2 vermiştir.

En önemli 3 banttan ikisi olan Temmuz ve Mayıs NDVI bantlarından oluşan veri seti

Ek Tablo 10. Temmuz ve Mayıs NDVI bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	9	0	0	0	0	2	0	1	0	0
bugday	0	36	0	0	20	0	0	0	1	3
domates	0	0	17	8	0	5	1	2	0	0
misir	0	0	10	72	0	2	0	1	0	0
misir2	0	24	0	0	46	0	0	1	1	0
pamuk	2	0	1	0	0	20	2	0	0	0
patlican	0	0	0	0	0	1	5	1	0	0
uzum	4	0	2	3	0	0	2	218	0	1
yonca	0	0	0	0	3	0	0	0	9	0
zeytin	2	0	1	0	0	0	0	3	0	55

Overall Statistics

Accuracy : 0.8157
95% CI : (0.7823, 0.8461)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.7678
McNemar's Test P-Value : NA

* EYDRO en yüksek doğruluğu ntree=600 mtry=1 iterasyon=3 vermiştir.

En önemli 3 banttan ikisi olan Eylül ve Mayıs NDVI bantlarından oluşan veri seti

Ek Tablo 11. Eylül ve Mayıs NDVI bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	11	0	0	0	0	1	1	1	0	0
bugday	0	56	0	0	5	0	0	0	1	1
domates	0	0	22	7	0	1	0	1	0	1
misir	0	0	4	72	0	1	0	1	0	2
misir2	0	2	0	1	60	0	0	1	3	1
pamuk	0	0	1	0	0	26	0	0	0	0
patlican	1	0	0	0	0	1	7	1	0	0
uzum	5	1	1	2	0	0	2	219	0	2
yonca	0	1	0	0	4	0	0	0	7	0
zeytin	0	0	3	1	0	0	0	3	0	52

Overall statistics

Accuracy : 0.8911
95% CI : (0.8633, 0.915)
No Information Rate : 0.3802
P-value [Acc > NIR] : < 2.2e-16

Kappa : 0.8628
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=200 mtry=1 iterasyon=1 vermiştir.

En önemli 3 banttan ikisi olan Eylül ve Temmuz NDVI bantlarından oluşan veri seti

Ek Tablo 12. Eylül ve Temmuz NDVI bant doğruluk analizi*

Prediction	Reference									
	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	9	0	0	0	0	2	1	0	0	0
bugday	0	51	0	0	1	0	0	0	0	6
domates	0	0	24	5	1	1	0	0	0	0
misir	0	0	3	74	1	0	0	4	0	0
misir2	1	3	0	0	62	1	0	0	0	0
pamuk	1	0	0	0	1	23	0	0	1	0
patlican	0	0	0	1	0	2	6	2	0	0
uzum	6	0	3	1	1	1	3	218	4	1
yonca	0	0	0	2	0	0	0	0	5	0
zeytin	0	6	1	0	2	0	0	3	1	52

Overall statistics

Accuracy : 0.8777
95% CI : (0.8487, 0.9029)
No Information Rate : 0.3802
P-value [Acc > NIR] : < 2.2e-16

Kappa : 0.8452
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=300 mtry=1 iterasyon=2 vermiştir.

Tüm denemelerde en önemli bant olarak belirlenen Eylül NDVI bantı

Ek Tablo 13. Eylül NDVI bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	8	0	0	0	1	0	0	5	0	0
bugday	0	35	7	3	2	0	0	1	0	6
domates	0	7	15	4	3	0	0	2	0	2
misir	0	6	1	47	3	0	0	11	2	16
misir2	2	3	1	2	39	12	2	4	1	2
pamuk	0	0	0	0	11	15	0	0	0	0
patlican	0	0	0	0	0	0	6	2	0	0
uzum	5	1	3	13	7	1	2	196	2	2
yonca	2	0	1	2	3	2	0	3	4	1
zeytin	0	8	3	12	0	0	0	3	2	30

overall statistics

Accuracy : 0.6616
95% CI : (0.6221, 0.6996)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.5738
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=200 mtry=1 iterasyon=2 vermiştir.

En önemli 3 banttan birisi olan Temmuz NDVI bantı

Ek Tablo 14. Temmuz NDVI bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	10	0	0	0	0	1	0	4	0	2
bugday	0	28	0	0	20	1	0	1	0	9
domates	0	0	15	5	0	0	0	1	0	0
misir	1	0	9	71	0	3	1	4	1	0
misir2	0	25	0	0	38	0	0	3	1	3
pamuk	0	2	0	1	1	12	0	5	0	3
patlican	0	0	1	0	0	0	6	5	1	0
uzum	3	0	4	4	4	9	2	200	4	1
yonca	1	0	1	2	1	3	1	2	4	1
zeytin	2	5	1	0	5	1	0	2	0	40

overall statistics

Accuracy : 0.7102
95% CI : (0.672, 0.7463)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.6349
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=1 iterasyon=1 vermiştir.

En önemli 3 banttan birisi olan Mayıs NDVI bantı

Ek Tablo 15. Mayıs NDVI bant doğruluk analizi*

	Reference									
Prediction	biber	bugday	domates	misir	misir2	pamuk	patlican	uzum	yonca	zeytin
biber	9	0	1	2	0	2	0	2	0	1
bugday	0	33	0	1	25	0	0	1	5	3
domates	0	0	13	3	0	4	3	2	0	1
misir	3	0	6	63	0	11	0	3	0	2
misir2	0	24	0	0	38	0	0	0	0	1
pamuk	1	1	4	2	3	12	0	0	0	0
patlican	0	0	2	5	0	1	5	1	0	0
uzum	4	0	4	5	0	0	2	203	0	30
yonca	0	2	0	1	3	0	0	0	6	0
zeytin	0	0	1	1	0	0	0	15	0	21

Overall statistics

Accuracy : 0.675
95% CI : (0.6358, 0.7125)
No Information Rate : 0.3802
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.5865
McNemar's Test P-Value : NA

* EYDRO ile en yüksek doğruluğu ntree=100 mtry=1 iterasyon=3 vermiştir.

Ek Tablo 16. Özellik kombinasyonları genişletilmiş

	RO	EYDRO
Özellik Kombinasyonu	$\hat{K}$	$\hat{K}$
$Ort_{Tüm}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0.9280	0.9344
$Ort_{Tüm}^{Tüm}$	0.9323	0.9365
$Ort_{M,Y,K,YKÖ}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0.9130	0.9279
$Ort_{NDVI}^{Tüm}, Std_{Tüm}^{Tüm},$ $Hmj_{Tüm}^{Tüm}, Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0.8959	0.9238
$Ort_{M,Y,K,YKÖ}^{Tüm}$	0.9301	0.9344
$Ort_{NDVI}^{Tüm}$	0.9238	0.9303
$Std_{Tüm}^{Tüm}, Hmj_{Tüm}^{Tüm},$ $Frk_{Tüm}^{Tüm}, Ent_{Tüm}^{Tüm}$	0.7895	0.8117

En Önemli 4 Tarih	$Ort_{Tüm}^{May, Tem, Eyl, Kas}$	0.9302	0.9345
	$Ort_{M,Y,K,YKÖ}^{May, Tem, Eyl, Kas}$	0.9175	0.9260
	$Ort_{NDVI}^{May, Tem, Eyl, Kas}$	0.9113	0.9156
En Önemli 3 Tarih	$Ort_{Tüm}^{May, Tem, Eyl}$	0.9174	0.9281
	$Ort_{M,Y,K,YKÖ}^{May, Tem, Eyl}$	0.9026	0.9131
	$Ort_{NDVI}^{May, Tem, Eyl}$	0.9049	0.9092
En Önemli 3 Tarihten Temmuz Mayıs	$Ort_{Tüm}^{May, Tem}$	0.8600	0.8665
	$Ort_{M,Y,K,YKÖ}^{May, Tem}$	0.8317	0.8466
	$Ort_{NDVI}^{May, Tem}$	0.7531	0.7678
En Önemli 3 Tarihten Mayıs Eylül	$Ort_{Tüm}^{May, Eyl}$	0.8881	0.8924
	$Ort_{M,Y,K,YKÖ}^{May, Eyl}$	0.8667	0.8859
	$Ort_{NDVI}^{May, Eyl}$	0.8545	0.8628
En Önemli 3 Tarihten Temmuz Eylül	$Ort_{Tüm}^{Tem, Eyl}$	0.8877	0.8936
	$Ort_{M,Y,K,YKÖ}^{Tem, Eyl}$	0.8688	0.8854
	$Ort_{NDVI}^{Tem, Eyl}$	0.8387	0.8452
En Önemli 3 Tarihten Eylül	$Ort_{Tüm}^{Eyl}$	0.7721	0.7825
	$Ort_{M,Y,K,YKÖ}^{Eyl}$	0.7704	0.7765
	Ort_{NDVI}^{Eyl}	0.5735	0.5738
En Önemli 3 Tarihten Temmuz	$Ort_{Tüm}^{Tem}$	0.7543	0.7755
	$Ort_{M,Y,K,YKÖ}^{Tem}$	0.7588	0.7680
	Ort_{NDVI}^{Tem}	0.6349	0.6349
En Önemli 3 Tarihten Mayıs	$Ort_{Tüm}^{May}$	0.7237	0.7391
	$Ort_{M,Y,K,YKÖ}^{May}$	0.7168	0.7436
	Ort_{NDVI}^{May}	0.5860	0.5865

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Mesut YILMAZ

Doğum Yeri : TURGUTLU

Medeni Hali : EVLİ

E-Posta : m.yilmaz4588@gmail.com

Adresi :

Eğitim Bilgileri

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

Yabancı Dil ve Düzeyi

İngilizce (İyi)

İş Deneyimi

2014 - ... : Orman ve Su İşleri Bakanlığı / Orman ve Su İşleri Uzmanı

2013 - 2014 : Karayolları Genel Müdürlüğü / Kontrol Mühendisi

Deneyim Alanları

İleri düzeyde CAD (Netcad, Autocad, Microstation)

İleri düzeyde GIS uygulamaları (Qgis, ArcGIS)

Proje Yönetimi (Ms Office yazılımları)

Orta düzeyinde programlama (R, MATLAB)

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

-

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

-



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

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

Tarih: 01/08/2018

Tez Başlığı: TARIMSAL YAZ ÜRÜNLERİN SENTİNEL-2 UYDU GÖRÜNTÜLERİNDEN RASTGELE ORMAN ALGORİTMASI İLE NESNE-TABANLI SINIFLANDIRILMASI


Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam 65 sayfalık kısmına ilişkin, 01/08/2018 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.


01/08/2018

Adı Soyadı: MESUT YILMAZ
Öğrenci No: N14327758
Anabilim Dalı: GEOMATİK MÜHENDİSLİĞİ
Programı: GEOMATİK
Statüsü: ☒ Y.Lisans ☐ Doktora ☐ Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.


Prof. Dr. Mustafa TÜRKER