

**YANMIŞ ORMAN ALANLARININ UYDU
GÖRÜNTÜLERİ İLE TESPİTİ**

Yüksek Lisans Tezi

Murat KURUCA

Eskişehir 2018

**YANMIŞ ORMAN ALANLARININ UYDU
GÖRÜNTÜLERİ İLE TESPİTİ**

Murat KURUCA

YÜKSEK LİSANS TEZİ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Doç.Dr. Uğur AVDAN

Eskişehir

Anadolu Üniversitesi

Fen Bilimleri Enstitüsü

Ağustos 2018

JÜRİ VE ENSTİTÜ ONAYI

Murat KURUCA'nın "Yanmış Orman Alanlarının Uydu Görüntüleri İle Tespiti" başlıklı tezi 10/08/2018 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvanı Adı Soyadı

İmza

Üye (Tez Danışmanı)

: Doç.Dr. Uğur AVDAN

.....

Üye

: Doç.Dr. Murat UYSAL

.....

Üye

: Dr. Öğr. Üyesi Hakan UYGUÇGİL

.....

Prof.Dr. Ersin YÜCEL

Fen Bilimleri Enstitüsü Müdürü

ÖZET

YANMIŞ ORMAN ALANLARININ UYDU GÖRÜNTÜLERİ İLE TESPİTİ

Murat KURUCA

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Ağustos, 2018

Danışman: Doç.Dr. Uğur AVDAN

Doğal varlıklar hızla tahrip edilirken orman alanlarının bu tahribattan payını alması da kaçınılmaz bir sondur. 2016 yılı yangın verilerine göre toplam 9156 hektar orman alanı yanmıştır. Bu yangınların %23,5’u Antalya bölgesinde meydana gelmiştir (http-1). Bu çalışmada, 2016 yılı Haziran ayında, Adrasan ve Kumluca bölgelerinde meydana gelen yangından etkilenen alanların Göktürk-2, Landsat-8 ve Worldview-2 uydularına ait uydu görüntüleri temin edilmiştir. Bu uydu görüntüleri önce Erdas 2014 programı ile birleştirilmiş ve Pansharping uygulanmış, daha sonra eCognition programı ile NDVI, SAVI, GEMI, VI, RVI ve AVI indisleri kullanılarak Göktürk-2 için ölçek:80, şekil:0,3, yoğunluk:0,7, Landsat-8 için ölçek:100, şekil:0,3, yoğunluk:0,7, Worldview-2 için ise ölçek:120, şekil:0,4, yoğunluk:0,6 parametreleri ile segmentasyon işlemi yapılmıştır. Daha sonra elde edilen Şekil dosyaları ArcMap programı ile kesilerek test ve eğitim verisine ait csv dosyaları oluşturulmuş ve Weka programında Destek Vektör Makineleri (DVM) ve Rotasyon Orman (ROR) sınıflandırmaları yapılmıştır. Elde edilen sınıflandırma sonuçlarının doğruluk analizi yapılmıştır. Yapılan doğruluk analizine göre Göktürk-2 için DVM; Kappa 0,68 ve Toplam doğruluk 0,84, ROR için ise Kappa 0,63 ve Toplam doğruluk 0,82 bulunmuştur, Landsat-8 için DVM; Kappa 0,69 ve Toplam doğruluk 0,85, ROR için ise Kappa 0,69 ve Toplam doğruluk 0,85, Worldview-2 için ise DVM; Kappa 0,9 ve Toplam doğruluk 0,95, ROR için ise Kappa 0,86 ve Toplam doğruluk 0,93 bulunmuştur. Her üç uydu görüntüsü karşılaştırıldığında en yüksek doğruluğa Worldview-2 uydusu sahiptir ve en iyi sınıflandırma sonucunu DVM vermiştir.

Anahtar Sözcükler: DVM, Rotasyon Orman, Nesne-tabanlı sınıflandırma, Yanmış Orman Alanları, Göktürk-2

ABSTRACT

LOCATING BURNED FOREST AREAS WITH SATELLITE IMAGES

Murat KURUCA

Department of Remote Sensing and Geographical Information Systems

Anadolu University, Graduate School of Sciences, August, 2018

Advisor: Assoc. Prof. Dr. Uğur AVDAN

While natural beings have been destroyed rapidly, it is inevitable for forest lands to get their share of this havoc. According to the blaze data of 2016, a total of 9156 hectare forest was consumed by the fire. 23,5% of this blazes occurred in Antalya region (http-1). In this study, satellite images, belonging to the Göktürk-2, Landsat-8 and Worldview-2 satellites, of the areas affected from the blazes happened in Adrasan and Kumluca in June 2016 are obtained. These satellite images are merged by Erdas 2014 program first and pansharpening is applied to them, then, by the help of eCognition program, segmentation process is applied by using NDVI, SAVI, GEMI, VI, RVI, and AVI indexes with parameters of Scale:80, Shape:0,3, Compactness:0,7 for Göktürk-2; Scale:100, Shape:0,3, Compactness:0,7 for Landsat-8; Scale:120, Shape:0,4, Compactness:0,6. for Worldview-2. Later, csv files of test and education data are formed with the obtained figure files, and are classified according to Support Vector Machines (SVM) and Rotation Forest (ROF) by the help of Weka program. Accuracy analysis of the obtained results of the classifications has performed. According to results of the accuracy analysis, for Göktürk-2; Kappa is 0,68 and total accuracy is 0,84 for SVM, Kappa is 0,63 and total accuracy is 0,82 for ROF; for Landsat-8; Kappa is 0,69 and total accuracy is 0,85 for SVM, Kappa is 0,69 and total accuracy is 0,85 for ROF; for Worldview-2; Kappa is 0,9 and total accuracy is 0,95 for SVM, Kappa is 0,86 and total accuracy is 0,93 for ROF. When all three satellite images are compared, it is seen that Worldview-2 satellite has the highest accuracy and SVM yields the best classification result.

Keywords: SVM, Rotation Forest, OBIA, Burned Forest Area, Göktürk-2

TEŞEKKÜR

Bu tezin konusunun belirlenmesinden basılmasına kadar tüm basamaklarda kıymetli görüş ve bilgileriyle katkılarını esirgemeyen değerli hocam Sayın Doç.Dr. Uğur AVDAN'a,

Tezin oluşturulması esnasında kıymetli görüşleri ile yolumu aydınlatan Sayın Öğr.Gör. Dilek KÜÇÜK MATCI'ya,

Göktürk-2 uydu görüntüsünü temin etmemde göstermiş olduğu yardımlardan dolayı Sayın Arda AYAN'a,

Bana, her konuda olduğu gibi bu tezi hazırlamamda da bir an olsun desteğini ve sevgisini eksik etmeyen sevgili eşim Neslihan KURUCA'ya,

Teşekkürlerimi sunarım.

Murat KURUCA

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Anadolu Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Murat KURUCA

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ.....	xii
1. GİRİŞ.....	1
1.1. Çalışmanın Amacı	3
1.2. Literatür Araştırması	4
2. MATERYAL VE YÖNTEM	13
2.1. Çalışma Alanı.....	13
2.2. Veri	14
2.2.1. Göktürk-2 uydusunun özellikleri.....	14
2.2.2. Landsat-8 uydusunun özellikleri.....	15
2.2.3. Worldview-2 uydusunun özellikleri.....	16
2.3. Uzaktan Algılamada İleri Sınıflandırma Teknikleri.....	17
2.3.1. Nesne tabanlı sınıflandırma.....	17
2.3.1.1. Görüntü Bölütleme (Segmentasyon)	18
2.3.1.2. İndisler	20
2.3.2. Destek vektör makineleri (DVM).....	25
2.3.3. Rotasyon Orman.....	30
2.4. Kontrol Noktası Tespiti	31
2.5. Doğruluk Analizi	31
2.5.1. Hata matrisi ve Kappa katsayısı ile doğruluk analizi	32
2.5.1.1. Kullanıcı doğruluğu (UA- User Accuracy)	33
2.5.1.2. Üretici doğruluğu (PA- Producer Accuracy)	33
2.5.1.3. Komisyon Hataları (CE-Commission Errors).....	33

	<u>Sayfa</u>
2.5.1.4. İhmal Hataları (OE- Omission Errors).....	33
2.5.1.5. Genel Doğruluk (OA- Overall Accuracy)	34
2.5.2. Ki-Kare (χ^2) testi.....	35
2.6. Uygulama	36
2.6.1. Uydu görüntülerinin kaynaştırılması ve füzyon işlemi	36
2.6.2. İndislerin belirlenmesi.....	38
2.6.3. Görüntü bölütleme (segmentasyon).....	40
2.6.4. Eğitim ve test verilerinin oluşturulması	41
2.6.5. Kural setlerinin oluşturulması	44
2.6.6. Doğruluk analizi	47
3. SONUÇ, TARTIŞMA VE ÖNERİLER.....	51
3.1. Sonuç	51
3.2. Tartışma	51
3.3. Öneriler	52
KAYNAKÇA.....	53
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 2.1. Göktürk-2 uydusuna ait spektral band bilgileri	14
Tablo 2.2. Landsat-8 uydusuna ait spektral band bilgileri	16
Tablo 2.3. Worldview 2 uydusuna ait spektral band bilgileri	17
Tablo 2.4. Hata matrisi istatistiği örnek uygulaması.....	32
Tablo 2.5. Kappa değerlendirme tablosu	35
Tablo 2.6. Segmentasyon parametre değerleri	41
Tablo 2.7. Doğruluk analizi sonuçları	50

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Kumluca ve Adrasan yangın alanları	13
Şekil 2.2. Pikseller (a) bir segmentasyon işlemiyle görüntü nesnelere (b) gruplandırılmıştır	19
Şekil 2.3. NDVI'a ait eCognition ekran görüntüsü	21
Şekil 2.4. RVI'ya ait eCognition ekran görüntüsü	21
Şekil 2.5. SAVI'ye ait eCognition ekran görüntüsü	22
Şekil 2.6. GEMI'ye ait eCognition ekran görüntüsü	23
Şekil 2.7. AVI'ye ait ekran görüntüsü	24
Şekil 2.8. VI'ya ait ekran görüntüsü	25
Şekil 2.9. Doğrusal olarak ayrılabilen veri seti	25
Şekil 2.10. Doğrusal olarak ayrılamayan veri seti	26
Şekil 2.11. Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi	27
Şekil 2.12. Verinin Kernel fonksiyonu yardımıyla daha yüksek bir boyuta transformasyonu	28
Şekil 2.13. Çalışmanın iş akışı	36
Şekil 2.14. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait ekran görüntüsü	36
Şekil 2.15. ERDAS 2014 “HPF” ye ait ekran görüntüsü	37
Şekil 2.16. Göktürk-2 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü	38
Şekil 2.17. Landsat-8 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü	39
Şekil 2.18. Worldview-2 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü	39
Şekil 2.19. eCognition “Subset Selection” ekran görüntüsü	40
Şekil 2.20. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait segmentasyon sonrası ekran görüntüsü	41
Şekil 2.21. (1) Göktürk-2, (2) Landsat-8 ve (3) Worldview-2 uydularına ait (a) test ve (b) eğitim şekil dosyaları	42
Şekil 2.22. Eğitim verisine ait örnek öznitelik tablosu ekran görüntüsü	42
Şekil 2.23. ArcMap “Export” sekmesine ait ekran görüntüsü	43

Şekil 2.24. (a) DVM ve (b) ROR’a ait Weka kural seti örnek ekran görüntüsü	44
Şekil 2.25. Visualize Classifier Errors’a ait örnek ekran görüntüsü	44
Şekil 2.26. (a) “arff” uzantılı dosyanın Notepad ++’da düzenlendikten sonra elde edilen (b) “txt” uzantılı dosyalara ait ekran görüntüsü	45
Şekil 2.27. ArcMap’te birleştirmeye ait ekran görüntüsü	45
Şekil 2.28. (1) Göktürk-2, (2) Landsat-8 ve (3) Worlldview-2 uydularının (a) DVM ve (b) ROR sınıflandırmalarına ait görsellerin ekran görüntüsü.....	46
Şekil 2.29. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait kontrol noktalarının ekran görüntüsü	47
Şekil 2.30. ArcMap “Feature to raster” özelliğine ait ekran görüntüsü	48
Şekil 2.31. ArcMap “Extract values to points” özelliğine ait ekran görüntüsü.....	48
Şekil 2.32. ArcMap “Frequency” özelliğine ait ekran görüntüsü.....	49
Şekil 2.33. ArcMap “Pivot table” özelliğine ait ekran görüntüsü	49

SİMGELER VE KISALTMALAR DİZİNİ

α	: alfa
AVI	: Ashburn Vegetation Index (Ashburn Bitki Örtüsü İndisi)
C	: Düzenleme parametresi
daa	: Dekar alan
DT	: Decision Tree (Karar Ağacı)
DVM	: Destek Vektör Makineleri
F	: Veri setindeki özellik sayısı
Φ	: Φ_i
FMC	: Fuel Moisture Content (Yakıt Nem İçeriği)
γ	: Gamma
GEMI	: Global Environmental Monitoring Index (Küresel Çevre İzleme İndisi)
HPF	: High Pass Filter (Yüksek Geçiş Filtresi)
JDT	: J48 Decision Tree (J48 Karar Ağacı)
ξ	: Ksi
L	: Toprak Parlaklığı Düzeltme Faktörü
MIR	: Mid-infrared (Orta-kızılötesi)
MIRBI	: Mid-Infrared Burn Index (Orta-kızılötesi Yanma İndisi)
MO	: Maksimum olabilirlik
MODIS	: The Moderate Resolution Imaging Spectroradiometer (Orta Çözünürlüklü Görüntüleme Spektrometresi)
MRS	: Multiresolution Segmentation (Çok Çözünürlüklü Görüntü Bölütleme)
n	: Arazi örtüsü/kullanım sınıfı sayısı
N	: İhtiyaç duyulan örnek sayısı
NBR	: Normalized Burn Ratio (Normalize Edilmiş Yanma Şiddeti)
NDA	: Nonparametric Discriminant Analysis (Parametrik Olmayan Ayırık Veri Analizi)
NDVI	: Normalized Difference Vegetation Index (Normalize Edilmiş Fark Bitki Örtüsü İndisi)
NDWI	: Normalized Difference Water Index (Normalize Edilmiş Fark Su İndisi)
NIR Band	: Near-infrared Band (Yakın Kızılötesi Band)
OBIA	: Object-based Image Analysis (Nesne-tabanlı Görüntü Analizi)
ω	: omega

OLI : Operational Land Imager (Operasyonel Arazi Görüntüleyici)
PCA : Principal Component Analysis (Temel Bileşen Analizi)
PLS-DA: Partial Least Squares Discriminant Analysis (Ayrık Veri Analizi için En Küçük Kareler Yöntemi)
RF : Random Forest
ROR : Rotasyon Orman
RVI : Ratio Vegetation Index (Bitki Örtüsü Oran İndisi)
 σ : sigma
SAE: Study-Auto Encoder (Otomatik Çalışma Kodlayıcısı)
SAVI : Soil Adjusted Vegetation Index (Toprak Ayarlı Bitki Örtüsü İndisi)
SCT-SVM : Sequential Classifier Training Support Vector Machine (Sıralı Sınıflandırıcı Eğitimi Destek Vektör Makinesi)
SVM : Support Vector Machine (Destek Vektör Makinesi)
T : Karar ağacı sayısı
TIRS : Thermal Infrared Sensor (Isıl Kızılötesi Sensör)
TOD : Türkiye Ormancılar Derneği
VARI : Visible Atmospherically Resistant Index (Görünür Atmosferik Dirençli İndis)
VHR : Very High Resolution (Çok Yüksek Çözünürlüklü)
VI : Vegetation Index (Bitki Örtüsü İndisi)
X : Eğitim veri seti
Y : Veri setindeki sınıf etiketleri
YSA : Yapay Sinir Ağı

1. GİRİŞ

Yaklaşık olarak son 35 yıldır uzaktan algılama, giderek artan bir şekilde arazi örtüsü bilgilerinin temel kaynağı haline geldi [1, 2]. Bu, uydu sensörü teknolojisindeki ilerlemeler ile mümkün olmuş ve böylelikle geniş alanları kapsayan mekânsal, zamansal, spektral ve radyometrik çözünürlüklerde arazi örtüsü bilgilerinin edinilmesini mümkün kılmıştır [3]. Bir uydu görüntüsündeki piksellerin bilinen arazi görüntüsü ile ilişkilendirilmesi görüntü sınıflandırma olarak adlandırılır. Sınıflandırma sürecini etkilemek için kullanılan algoritmalar görüntü sınıflandırıcıları olarak adlandırılır [4]. Görüntü sınıflandırıcılarını kullanarak uydu görüntülerinden arazi örtüsü bilgilerinin çıkarılması uzaktan algılamaya olan ilgiyi arttırmış ve araştırma konusu olmuştur [5]. Uzaktan algılamada kullanılan geleneksel sınıflandırıcılarından bazıları; en çok benzerlik ve en yakın mesafedir. Teknolojideki gelişmelerle birlikte yeni sınıflandırma algoritmaları olan karar ağaçları ve yapay sinir ağları gibi ana akımlar görüntü sınıflandırıcılarının bir parçası haline gelmiştir. Bu yeni teknikleri geleneksel yöntemlerle karşılaştırmak için birçok çalışma yapılmış ve geliştirilmiş sınıflandırmaların doğruluklarının geleneksele göre daha yüksek olduğu gözlemlenmiştir [6-8]. Bu alanda çalışmalar hala devam etmekte olup uzaktan algılanmış görüntülerin sınıflandırılması için kullanılan sınıflandırıcılara yönelik yenilikler elde etme çalışmaları hızla devam etmektedir [5]. Bu nedenle sınıflandırıcılara yönelik çalışmalar devam etmekte olup Destek Vektör Makinaları (DVM) ve Rotasyon Orman (ROR) gibi sınıflandırıcılar yakın zamanda uzaktan algılama ile uğraşanların dikkatini çekmiştir [9-12].

DVM'lerin temelleri istatistiksel öğrenme kuramına dayanır [13]. El yazısı tanıma, karakter tanıma, imza tanıma ve veri madenciliği gibi birçok alanda DVM kullanılmıştır [13, 14]. DVM son zamanlarda uydu görüntüsünün sınıflandırılmasında sıklıkla kullanılmaktadır [9, 15-17]. Yapay sinir ağları ve parametrik olmayan sınıflandırıcılar gibi DVM de popüler hale gelmiştir [2, 5]. DVM, giriş alanındaki eğitim verilerinin çekirdek fonksiyonunu kullanılarak sonsuz boyutta bir özellik alanına doğrusal olmayan şekilde yansıtılması mantığıyla işlev görür. Doğrusal olarak sınıflandırılabilir görüntüler doğrusal olan sınıflandırıcılar kullanılarak bu işlemi gerçekleştirir. DVM, genellikle doğrusal olarak ayıramayan uzaktan algılama veri setlerinin sınıflandırılmasını mümkün kılar. Birçok durumda, yüksek boyutlu uzaydaki sınıflandırma, giriş alanında aşırı uyuma neden olur. Ancak DVM'lerde aşırı uyum, yapısal risk minimizasyonu prensibi ile kontrol edilir [13]. Karar sınırı ve veri noktaları arasındaki mesafenin maksimize edilmesiyle

deneysel olarak yapılacak olan yanlış sınıflandırmalar minimize edilmiş olur [18]. Uygulamada, bu kriter hem sınıflandırıcının karmaşıklığını hem de marjinal noktaların yanlış sınıflandırılmasının derecesini içeren bir maliyet faktörünün en aza indirgenmesiyle yumuşatılır. Bu faktörler arasındaki geçiş genellikle çapraz doğrulama prosedürleriyle ayarlanan bir hata parametresi (genellikle C olarak adlandırılır) değeri ile yönetilir [18]. Verileri girdi alanından özellik alanına yansıtmak için kullanılan işlevler kernel (kernel makineleri) olarak adlandırılan polinomial, Gaussian (daha yaygın olarak radyal temel fonksiyonu olarak adlandırılır) ve ikinci dereceden fonksiyonlar içerir. Her fonksiyonun, sınıflandırmadan önce tespit edilmesi gereken benzersiz parametreleri vardır ve bunlar genellikle çapraz doğrulama işlemi ile belirlenir. Doğaları gereği DVM'ler ikili sınıflandırıcılardır ancak uzaktan algılama çalışmaları göstermiştir ki çok sınıflı sınıflandırıcılar olarak da kullanılabilirler [12, 19]. En yaygın kullanılan yaklaşımlar birebir ve bire hepsi tekniğidir [3].

Çoklu sınıflandırıcılar, genellikle tek sınıflandırıcılar ile karşılaştırıldığında üstün doğruluk gösterirler. Çoklu sınıflandırıcı modellerinde AdaBoost'un en iyi sınıflandırıcısı olduğu bildirilmiştir [20]. AdaBoost'a yakın bir rakip ise topluluk içindeki sınıflandırıcıların birbirinden bağımsız olarak bazı rastgeleleştirme yöntemleri kullanılarak inşa edildiği torbalamadır [21, 22]. Torbalama'nın, AdaBoost' a göre daha iyi performans gösterdiği bulunmuştur [23] ancak genellikle iki yöntemin de daha az doğru olduğu düşünülmektedir. Torbalamada çeşitliliği teşvik etmek için, Rastgele Orman modelinde daha fazla randomizasyon başlatılmıştır [22]. Rastgele bir orman topluluğu, veri setinden önyükleme numuneleri eğitilen karar ağaçlarından oluşur. Her düğümde özellik seçimini rastgele seçerek ek çeşitlilik ortaya çıkmaktadır. Ağaç oluşumu sırasında, her düğümdeki en iyi özellik M'nin algoritmanın bir parametresi olarak rastgele seçilmiş M özellikleri arasından seçilir. ROR, Rastgele Orman fikrine benzemektedir [10]. Temel sınıflandırıcılar ayrıca bağımsız olarak karar ağaçlarına da sahiptir, ancak Rotasyon Ormanı'nda her ağaç, döndürülmüş bir özellik alanında tüm veri kümesi üzerinde eğitilir. Ağaç öğrenme algoritması, özellik eksenlerine paralel olan hiperdüzlem kullanarak sınıflandırma bölgelerini oluşturduğundan, eksenlerin küçük bir dönüşü çok farklı bir ağaca yol açabilir. Rodriguez ve arkadaşları [10] yaptıkları çalışma sonucu ROR' u torbalama, Adaboost ve Random Forest'a tercih etmişlerdir. Kappa-hata diyagramları incelendiğinde, Rotasyon Ormanı'nın, AdaBoost'dan daha hassas

sınıflandırıcılar üreteceği ve bunun da torbalamadan daha farklı olduğu keşfedilmiştir [24].

1.1. Çalışmanın Amacı

Orman yangınları var olan ekosistemin devamı ve sera gazı salınımını etkileyen en önemli faktörlerden biridir. Yakılmış bir alanın haritalandırılması, ilgili yangın söndürme çalışmaları için kritik önem taşımaktadır. Yanmış yüzey alanı hakkında bilgi, orman yangınlarının etkilerini değerlendirmek için önemlidir [25].

Maalesef ülkemizde her sene orman alanları yakılarak veya kentselleşme sebebiyle yok edilmektedir. Orman ve Su İşleri Genel Müdürlüğü'nün yaptığı çalışmaya göre 1988-2016 yılları arasında 61.313 adet orman yangını vukuu bulmuş ve bunun sonunda 307.855 hektar orman alanı yok olmuştur. 2004-2016 yılları arasında çıkan orman yangınlarının il bazında karşılaştırılması yapıldığında Antalya ili 26.166 hektar alanla ilk sırada yer almaktadır (<http-1>).

Bu çalışmada, Adrasan ve Kumluca (Antalya)'da 2016 yılı Haziran ayında meydana gelen orman yangının sonucunda oluşan yanmış alanların tespiti için Göktürk-2, Landsat-8 ve Worldview 2 uydularından elde edilen görüntüler kullanılarak sınıflandırma işlemi yapılmıştır. Görüntü bölütleme yapılırken Normalize Edilmiş Fark Bitki Örtüsü İndisi (NDVI), Bitki Örtüsü Oran İndisi (RVI), Toprak Ayarlı Bitki Örtüsü İndisi (SAVI), Küresel Çevre İzleme İndisi (GEMI), Ashburn Bitki İndisi (AVI) ve Bitki Örtüsü İndisi (VI) kullanılmıştır. Yanmış alanların tespitinde veri setine nesne tabanlı ileri sınıflandırma tekniklerinden olan Rotasyon Orman ve DVM işlemleri uygulanmıştır. İşlem sonucunda yanmış alan ve yanmamış alan olarak iki sınıf elde edilmiştir. Elde edilen sınıflara doğruluk analizi uygulanmıştır.

Bu çalışmada amaç bilimsel bir doküman oluşturmak, Milli keşif ve gözlem uydularımızın bilimsel yönde kullanımına katkıda bulunmaktır. Ayrıca, yanmış orman alanlarının nesne tabanlı sınıflandırma ile kısa sürede tespitini sağlayarak oluşan hasarın belirlenmesine ve yenileme çalışmalarına katkıda bulunmaktır.

Bu çalışmanın diğer çalışmalardan farkları;

1. Milli uydumuz olan Göktürk-2, Landsat-8 ve Worldview-2 uydularının üçünün birlikte böyle bir çalışmada kullanılıyor olması,
2. Nesne tabanlı sınıflandırmada Destek Vektör Makineleri ve Rotasyon Orman'ın aynı anda kullanımı,

3. Bu çalışmada literatür taranarak tespit edilmiş olan; Normalize Edilmiş Fark Bitki Örtüsü İndisi (NDVI), Bitki Örtüsü Oran İndisi (RVI), Toprak Ayarlı Bitki Örtüsü İndisi (SAVI), Küresel Çevre İzleme İndisi (GEMI), Ashburn Bitki İndisi (AVI) ve Bitki Örtüsü İndisi (VI) her üç uydu görüntüsü için de kullanılması,
4. Çalışma sonunda hangi sınıflandırma ve uydu performansının bu çalışma için daha uygun olduğunun belirlenmesidir.

1.2. Literatür Araştırması

Nesne tabanlı sınıflandırma ile uzaktan algılanmış görüntülerden ihtiyaca göre değişik alanlarda detay tespit işlemleri yapılmaktadır. Nesne tabanlı sınıflandırma diğer sınıflandırmalara göre daha başarılı sonuçlar verdiği için son zamanlarda yapılan çalışmalarda kullanımı giderek yaygınlaşmaktadır. Uydu teknolojilerinde ve görüntüleme sensörlerinde elde edilen başarılı gelişmeler bu tarz çalışmaların başarısını doğrudan etkilemektedir. Uzaktan algılanmış görüntünün çözünürlüğü ne kadar yüksek olursa nesne tabanlı sınıflandırma çalışmasının güvenilirliği de o kadar yüksek olmaktadır yani doğruluğu doğrudan etkilemektedir.

Aşağıda literatür ile ilgili yapılan taramaların sonucu kronolojik sıraya göre verilmiştir.

(Kauth, Thomas, 1976) çalışmada, LANDSAT uydu verilerinin tarımsal veri noktalarının yörüngeleri püsküllü bir yün şapkayı (Tasselled Cap) andırdığını düşündüren bir örüntüyü oluşturduğu gösterilmiştir. Bu kolayca görselleştirilen üç boyutlu yapıyı kullanarak, bitki gelişimi ve gözlem değişkenlerinin önemli fenomenlerinin çoğu işaret edilmiş, adlandırılmış, tartışılmış ve ölçülmüştür. Önemli dış değişkenler; görüş açısı, güneş açısı, atmosfer bulanıklığı ve atmosferik su buharıdır. Tasselled Cap'in niceliksel bir resminin geliştirilmesi, ürün ve atmosfer etkileri modellemesine ve veri sinyallerinin ampirik gözlemine bağlıdır. Tasselled kapak yapısı, küme lotları ve diyagramları ile gösterilmiştir. Ayrıca Bitki Örtüsü İndisi (VI)'nın tanımlanması için önemli denklemler ortaya konulmuştur [26].

(Tucker, 1979) çalışmada, toplanan spektrometre verileri, kırmızı ve fotografik kızılötesi radyasyonların çeşitli lineer kombinasyonları ve deneysel arsa biyo-kütlesi, yaprak su içeriği ve klorofil içeriği arasındaki ilişkileri değerlendirmek ve ölçmek için kullanılmıştır. Ayrıca, mukayese amaçlı yeşil ve kırmızı lineer kombinasyonlar karşılaştırmalı olarak değerlendirilmiştir. Regresyon analizi, aynı yeşil ve kırmızı lineer

kombinasyonlar karşısında IR ve kırmızı lineer kombinasyonların kullanımının arttığını göstermiştir. IR / kırmızı oranının bitki örtüsü indisi, dönüştürülmüş bitki örtüsü indisi ve karekökü, IR / kırmızı oranı ile yakından takip edilen en önemli faktörlerdir. Bu doğrusal kombinasyonların kullanımının öncelikle yeşil yaprak bölgesine veya yeşil yapraklı biokütleyle duyarlı olduğu gösterilmiştir. Bu şekilde, kırmızı ve fotografik IR radyasyonlarının bu lineer kombinasyonları, bitki kanopilerinin fotosentetik olarak aktif biokütlesinin izlenmesi için kullanılabilmektedir [27].

(Corrina, Vapnik, 1995) çalışmada, Destek Vektör Makinası (DVM) girdi vektörleri, çok yüksek boyutlu bir özellik alanına doğrusal olmayan şekilde eşlenmiştir. Bu özellik alanında doğrusal bir karar düzlemi inşa edilmiştir. Karar düzleminin özel özellikleri, öğrenme makinasının yüksek genelleme kabiliyetini sağlar. Polinom giriş dönüşümlerini kullanan destek vektör makinaları yüksek genelleme kabiliyeti göstermiştir. Ayrıca, destek vektör makinalarının performansı, Optik Karakter Tanıma çalışmasında yer alan çeşitli klasik öğrenme algoritmalarıyla karşılaştırılmıştır [13].

(Trigg, Flasse, 2001) çalışmada, kırmızı-orta-kızılötesi (MIR) dalga boylarında beş spektral banda dönüştürülmüş spektrometrik verilerin analizine dayanarak yanmış ve yanmamış bitki örtüsü sınıflarının sayısal olarak ayrılması sağlanmıştır. İki MIR bandının kombinasyonundan yanmış ve yanmamış numunelerin güçlü spektral ayrılmasına sahip olduğu bulunmuştur. Bu bantları kullanarak, yanmaya bağlı olarak spektral değişikliklere karşı oldukça hassas olan ve içsel değişkenliğe nispeten duyarsız olan bir spektral indis formüle edilmiştir [28].

(Huang, Davis, Townshend, 2002) çalışmada, uzaktan algılanmış uydu görüntülerinden Destek Vektör Makinesi (DVM)'nin arazi örtüsü sınıflandırmalarında doğruluğu, kararlılığı ve DVM'nin teorik gelişimi, eğitim hızı deneysel olarak değerlendirilmiştir. DVM'nin performansı karar ağacı sınıflandırıcıları, nöral ağ sınıflandırıcıları ve maksimum olasılık sınıflandırıcı dahil olmak üzere üç sınıflandırıcıyla karşılaştırılmıştır. Bunun yanında kernel konfigürasyonunun bahsi geçen sınıflandırmalardaki eğitim verisi ve girdi değişkenlerinin seçimi üzerindeki etkileri de değerlendirilmiştir [9].

(Pal, Mather, 2005) çalışmada, çok sınıflı DVM'lerin sınıflandırma doğruluğu açısından Maksimum Olabilirlik (MO) ve Yapay Sinir Ağı (YSA) yöntemleri ile karşılaştırıldığı iki deneyin sonuçlarını bildirmektedir. İki arazi örtüsü sınıflandırma deneyleri, doğu İngiltere ve orta İspanya'daki test bölgeleri için multispektral (Landsat -

7 ETM +) ve hiperspektral (DAIS) verileri kullanmaktadır. Sonuç olarak DVM'in MO veya YSA sınıflandırıcısından daha yüksek bir sınıflandırma doğruluğu seviyesine ulaştığı ve DVM'nin küçük eğitim veri setleri ve yüksek boyutlu verilerle kullanılabileceği gösterilmiştir [29].

(Stow, Niphadkar, Kaiser, 2005) çalışmada, Chaparral Fundalıkların Canlı Yakıt Nem İçeriğinin (Fuel Moisture Content, FMC) izlenmesi için Görünür Atmosferik Dirençli İndisi (Visible Atmospherically Resistant Index, VARI) ve Normalize Edilmiş Fark Su İndisi (Normalized Difference Water Index, NDWI) karşılaştırılmıştır. Regresyon katsayıları, yer bazlı FMC ölçümleri ve MODIS - türetilmiş NDVI'ların birbirinden farklı mekânsal kararları verildiğinde alınan sonuçlar tatmin edicidir. VARI, yalnızca görünür dalga bandı yansıma verilerine dayanmasına rağmen, daha büyük geçici değişkenlik ($0.79 > r^2 < 0.94$) ve FMC ile NDWI' dan daha fazla uzamsal dayanıklılık sergilemiştir [30].

(Rodriguez, Kuncheva, Alonso, 2006) çalışmada, WEKA kullanılarak, Rotasyon Orman topluluğunu UCI (UC Irvine) deposundan rastgele seçilmiş 33 referans veri seti üzerinde incelenmiş ve torbalama, AdaBoost ve Rastgele Orman ile karşılaştırılmıştır [10].

(Smith, vd., 2007) çalışmada, Landsat ETM + ile türetilmiş referans görüntülerin, spektral olarak bilgilendirilmiş yöntemler kullanılarak daha doğru bir şekilde üretilip üretilmeyeceğini araştırılmıştır. Bir dizi mekânsal ölçek üzerinde yanmış ve yanmamış yüzeyler arasında ayırım yapmak için çeşitli spektral indis yöntemlerinin etkinliği (zemin, IKONOS, Landsat ETM + ve Orta Çözünürlüklü Görüntüleme Spektrometresi (Moderate Resolution Image Spectrometer, MODIS) verileri değerlendirilmiştir. Yanmış alanın optimal Landsat ETM + referans görüntüsü, piksellerin piksel başına oranı %50'yi aştığında yanmış olarak tanımlanmışlardır. Orta Kızılötesi Yanma İndisi (Mid-Infrared Burn Index, MIRBI) en uygun bölgesel yanmış alan haritalama indisi olarak belirlenmiştir [31].

(Kuncheva, Rodríguez, 2007) Rotasyon Orman karşılaştırmalı veri kümelerinden oluşan bir koleksiyonun, AdaBoost ve Rastgele Orman topluluklarından daha doğru olduğu görülmüştür. Bu çalışmada, hangi parametrelerin ve randomizasyon tahminlerinin performanstan sorumlu olduğunu bulmak için Rotasyon Orman üzerinde bir lezyon çalışması yürütülmektedir. Yaygın düşüncenin aksine, Temel Bileşen Analizi (Principal Component Analysis, PCA) ile elde edilen özellikler, parametrik olmayan

ayrık veri analizi (Nonparametric Discriminant Analysis, NDA) veya rastgele çıkarımlarla çıkarılmış olanlara kıyasla en iyi sonuçları vermiştir. Rotasyon Orman başarısının ana faktörünün, doğrusal çıkarılan özellikleri hesaplamak için kullanılan dönüşüm matrisinin seyrek olduğu ortaya çıkarılmıştır [24].

(Oruç, Marangoz, Karakış, 2007) çalışmada, obje tabanlı ve piksel tabanlı görüntü analizi yaklaşımları kullanılarak elde edilen sınıflandırmalar sınanmıştır. Çalışma alanına ait 6 spektral banda sahip Landsat 7 ETM+ görüntüsü ile pankromatik bandın kaynaştırılmasıyla oluşturulan görüntüyle sınıflandırma yapılmıştır. Bunun yanı sıra yüksek çözünürlüklü görüntülerin sınıflandırılmasında iyi sonuçlar veren obje tabanlı uzaktan algılanmış görüntü eCognition programı ile sınanmıştır [32].

(Lang, 2008) çalışmada, nesne tabanlı görüntü analizinin (Object-Based Image Analysis, OBIA) sınıf modellemesinin metodolojik çerçevesinin ayrıntılı bir portresi de dahil olmak üzere olası cevapları tartışılmıştır. Çalışma, standart ölçme yöntemleri ile doğruluk değerlendirmesi ve değişiklik algılamasının gerekli uyarlamasının yanı sıra çizilen ve sınıflandırılmış nesnelerin nihai kritere yani insan algısına karşı değerlendirilmesiyle sonuçlandırılmıştır [33].

(Bayburt, 2009) çalışmada, çeşitli uydu görüntülerinin sınıflandırılmasında farklı yöntemler kullanılmış ve sınıflandırılma sonucu oluşturulan arazi örtüsü ve arazi kullanımı haritalarının sonuçları incelemiştir. Çalışılan bölgede obje ve piksel tabanlı sınıflandırma sonucu altı tane sınıf elde edilmiştir. Yapılan çalışmada güvenilirlik analizi yapılmıştır [34].

(Çölkesen, 2009) çalışmada bilinen sınıflandırma yöntemlerinin yanı sıra uzaktan algılamada son zamanlarda tercih edilen karar ağaçları, yapay sinir ağları Destek Vektör Makineleri, K-star sınıflandırıcı ve karar ağacı iyileştirme algoritmaları gibi ileri sınıflandırma teknikleri kullanılarak uygulama gerçekleştirilmiştir. Elde edilen veriler analiz edilmiş ve uzaktan algılanmış görüntüler üzerinde kullanılan bu ileri sınıflandırma yöntemlerinin, sık kullanılan sınıflandırma yöntemlerine göre daha iyi ve etkili oldukları sonucuna varılmıştır [35].

(Dener, Dörtler, Orman, 2009) çalışmada, açık kaynak kodlu Veri Madenciliği programlarından birkaçı anlatılmıştır. Kullanılan programlar Rapid Miner, R ve WEKA'dır. Bu çalışmada bahsi geçen paket programların performans değerlendirmelerine yer verilmiştir. Ayrıca çalışmada örnek olması maksadıyla WEKA programında bir uygulama yapılmıştır [36].

(Kavzoğlu, Çölkesen, 2010) çalışmada, karar ağaçlarının uydu görüntüsü sınıflandırma performansı incelenmiştir. En çok benzerlik yönteminin performansı sınıflandırma performansı ile karşılaştırılmıştır. Z testi ile elde edilen veri seti istatistiksel olarak analiz edilmiştir. Sonuç olarak karar ağaçlarının uydu görüntülerinin sınıflandırmasında karar ağaçlarının etkin bir yöntem olduğunu gösterilmiştir [37].

(Kalkan, Maktav, 2010) çalışmada, yüksek mekânsal çözünürlüklü IKONOS görüntüsü kullanılarak piksel tabanlı ve nesne tabanlı sınıflandırmalar karşılaştırılmıştır. Pikselleri görüntü bölütleme aşamasında oluşturulmak istenen nesne tabanlı sınıflandırma için bölütlerin sıklık, renk ve komşuluk gibi özellikleri kullanılmıştır. Piksel tabanlı sınıflandırma sadece piksellerin istatistiksel analizine dayandığından oluşturulan sınıf için obje tabanlı sınıflandırmayla çok iyi ve anlamlı neticeler elde edilmiştir [38].

(Blaschke, 2010) çalışmada, görsel ve işitsel bilginin bütünleştirici bir şekilde kullanılması için görüntü işleme ve CBS işlevlerini birleştiren, aynı zamanda kolayca kullanılabilir nesnelere ait görüntüleri tasvir etmeyi amaçlayan nesne tabanlı yöntemlerin geliştirilmesine yönelik genel bir bakış sunulmaktadır [39].

(Bhaskaran, Paramananda, Ramnarayan, 2010) çalışmada, kentsel özellikleri Yüksek Çözünürlüklü (Very High Resolution, VHR) uydu verilerinden gruplandırmak için hem piksel hem de obje tabanlı sınıflandırma yöntemleri kullanan bir yaklaşım açıklanmaktadır. Ikonos uydu verilerinin, kentsel özellikleri bir planlama ölçeğinde, gerçek zamanlı olarak gruplandırmak için uygunluğu test edilmiştir [40].

(Akar, Güngör, Akar, 2010) çalışmada, 4 bantlı IKONOS uydu görüntüsü Rastgele Orman (ROR) ileri sınıflandırma yöntemi kullanılarak sınıflandırılmıştır. Sınıflandırma işlemi için arazi kullanım alanları, eğitim ve test verisi oluşturulmuştur. ROR yöntemi ile Fisher Lineer Diskriminant, ECHO Spectral-Spatial, En Çok Benzerlik, En Küçük Mesafe gibi sınıflandırma yöntemleriyle karşılaştırılmıştır. Çalışma sonucunda Rotation Forest yönteminin diğer yöntemlere göre en fazla doğruluğa sahip yöntem olduğu ortaya çıkarılmıştır [41].

(Myint vd., 2011) araştırma, bölümlere ayrılmış nesnelerin arazi örtülerini temsil eden sınıflandırıcılar, üyelik fonksiyonlarını ve en yakın komşu sınıflandırıcısını içermektedir. Ayrıca, bu çalışmada segmentasyon ve sınıflandırma için farklı parametrelerin uygulanması, kompozit ve orijinal grupların birlikte kullanımı, farklı ölçek düzeylerinin seçilmesi ve sınıflandırıcıların seçimi incelenmektedir [16].

(Coşkun, Baykal, 2011) çalışmada, WEKA programı yardımıyla SEER veri kaynağı üzerinde çeşitli sınıflandırma metotlarına ait algoritmalar kullanılmış ve bunlara ait modeller oluşturulmuştur. Elde edilen bu modellerin tahminleme oranları karşılaştırılmıştır. Bunun sonucunda veri kaynağında hangi algoritmanın daha başarılı olduğu ortaya konulmuştur [42].

(Kotsiantis, 2011) çalışmada, her birinde 6 alt sınıflandırıcı ile torbalama, hızlandırma, Rotasyon Orman ve Rastgele Alt Uzay yöntemleri topluluğu oluşturulmuş ve daha sonra nihai tahmin için bir oylama metodolojisi kullanılmıştır [43].

(Tekerek, 2011) çalışmada, Orange, WEKA, Knime, Rapid Miner, Keel ve R gibi veri madenciliğinde kullanılan açık kaynak kodlu yazılımların karşılaştırılmaları yapılmıştır. Elde edilen sonuçlara göre, hangi veri için hangi yazılımın seçilmesinin daha doğru ve etkin olacağı bu çalışma ile tespit edilmiştir [44].

(Erener, Sarp, 2012) çalışmada, mekânsal çözünürlüğün ve görüntü homojenleştirmesinin yüksek çözünürlüklü uydu görüntüleriyle arazi kullanımı/örtüsü sınıflandırmasında doğruluğa etkisi araştırılmıştır [45].

(Xia ve vd., 2014) çalışmada, bir grup öğrenme yaklaşımı olan Rotasyon Orman sınıflandırması ilk kez hiperspektral uzaktan algılanmış görüntüye uygulanmıştır. Rotasyon Orman'ın özellikle PCA dönüşümüyle, torbalama, AdaBoost ve Rastgele Orman'dan daha doğru sonuçlar verebileceği ortaya koyulmuştur [46].

(Küpcü, Teke, Çabuk, 2014) çalışmada, milli gözetleme uyduları olan Göktürk 2 ve RASAT görüntülerinin uzaktan algılama için geliştirilmiş olan yazılımları ile yükseklik ve farklı referans datalarından faydalanılarak geometrik düzeltmesi yapılmış ve takiben sonuçlar karşılaştırılmıştır [47].

(Belgiu ve Drâgut, 2014) çalışmada, kontrollü ve kontrolsüz yaklaşımları ile çok çözünürlüklü görüntü bölütlemeye (Multi Resolution Segmentation, MRS) karşılaştırılmıştır. QuickBird ve WorldView-2 uydu görüntüleri, bir kontrollü ve iki kontrolsüz sınıflandırma yöntemi kullanılarak üç alanda test edilmiştir. Sonuçlar hem sınıflandırma değerlendirme yöntemleri hem de sonuçta ortaya çıkan bina sınıflandırmaları için bir doğruluk analizi kullanılarak değerlendirilmiştir. Böylece, görüntü nesnelerinin geometrilerindeki farklılıklar ve tatmin edici tematik doğruluklar elde etme potansiyeli değerlendirilmiştir. Bu çalışmanın sonuçlarının iki önemli etkisi vardır. Birincisi, nesne tabanlı görüntü analizinin, sınıflandırma doğruluğundan ödün vermeden otomatikleştirilebilmesi ve ikincisi daha önce sınıflamanın bölümlere ayırmaya

bağlı olduğu fikrinin, 'optimal sınıflandırma' değerine bağlı olduğuna dair şüphe uyandırmasıdır [48].

(Kuğu, Kısa, 2014) çalışmada, orman yangın alanına ait yüksek çözünürlüklü görüntü üzerinde nesne tabanlı görüntü analizi yöntemi kullanılarak bir hasar değerlendirmesi gerçekleştirilmiştir. Bu çalışmada eCognition yazılımı kullanılmıştır. Elde edilen sonuçlar yardımıyla bu yazılımın bu tür esnek sorgulamalar yapabildiği ortaya çıkarılmıştır [49].

(Bağdatlı, vd., 2016) çalışmada, Göktürk-2 uydusuna ait uzaktan algılanmış uydu görüntüsüyle tarım bölgesinde yetiştirilen 3 adet ürün tipi sınıflandırılmıştır. Destek Vektör Makinaları ve En Çok Benzerlik metotları yardımı ile piksel ve nesne tabanlı sınıflandırmalar gerçekleştirilmiştir. Doğruluk analizi için hata matrisleri, ürünlerin kullanıcı ve üretici doğrulukları ile Kappa değerleri hesaplanmıştır [50].

(Gürcan, Teke, Leloğlu, 2016) çalışmada, Göktürk-2 uydusundan temin edilen görüntüler için arazi sınıflandırması yöntemi geliştirilmiştir. Göktürk 2 uydusuna ait görüntünün her pikseli için “toprak”, “yeşil alanlar”, “yaş ya da su ihtiva eden bölgeler” veya “diğerleri” sınıflarından herhangi biri olacak şekilde gruplandırmak amacıyla; matematiksel ve her zaman geçerliliği olan bir model geliştirmek amaçlanmıştır. Ayrıca data analizinde “en küçük kareler (Partial Least Squarer Discriminant Analysis, PLS-DA) yöntemi” kullanılmıştır [17].

(Ergüç, vd., 2016) çalışmada, uzaktan algılanmış çok bantlı uydu görüntüsü WEKA veri madenciliği yazılımı kullanılarak 5 sınıfa ve 24 alt türe göre gruplandırıldığında Rastgele Orman algoritması ile sınıflandırılmada en yüksek sınıflandırma performansı elde edilmiştir [51].

(Teke, Yardımcı, 2016) çalışmada, Göktürk-2 uydusuna ait dokuz adet zaman serisi görüntüleri kullanarak bölgede yetişen üç çeşit ürün olan buğday, mısır ve pamuğun tespiti için Dinamik Zaman Bükme ve Spektral Açık Eşleyici yöntemleri kullanılarak başarılı ürün tespiti gerçekleştirilmiştir [52].

(Özlem, 2017) çalışmada, Rotasyon Orman algoritmasının performansını insansız hava aracı kullanarak benzer özelliklere sahip olan kentsel ve kırsal alanlarda, en güncel ve doğru arazi kullanım haritaları üretilmiştir. Rotasyon Orman algoritmasının performansı nesne tabanlı sınıflandırma için, örneğin Rastgele Orman ve Gentle AdaBoost gibi diğer sınıflandırma yöntemleri ile karşılaştırılmıştır [53].

(Özdemir, 2017) çalışmada, nesne tabanlı sınıflandırma açısından keskinleştirme yöntemleri değerlendirilmiştir. Üç farklı uydu görüntüsü (Landsat-8, Kompsat-3, ve WorldView-2) kullanılarak spektral ve mekânsal anlamda zenginleştirilmiş görüntülerin görüntü keskinleştirme ile nesne tabanlı sınıflandırmanın sonuçları sınıflandırma doğrulukları açısından incelenmiştir [54].

(Liu ve vd., 2017) çalışmada, uzaktan algılanmış görüntüler sınıflandırırken DVM'in bazı durumlarda Otomatik Çalışma Kodlayıcısından (Study-Auto Encoder, SAE) daha iyi performans gösterebildiği ve her iki yöntemde yüksek sınıflandırma doğruluğunu sağlamak için aktif öğrenme programlarının kullanılabilirliği gösterilmiştir [19].

(Çömert ve vd., 2017) çalışmada Landsat-8'e ait Kumluca ve Adrasan (Antalya) alanlarının uydu görüntüleri ile 2016 yılı Haziran ayında vukuu bulan yangınlar neticesinde meydana gelen yanmış alanların belirlenmesi amacıyla obje tabanlı sınıflandırma işlemi gerçekleştirilmiştir. Obje tabanlı sınıflandırma tekniği için gerekli olan kural setleri üzerine çalışılmış ve ilgili set geliştirilmiştir. Elde edilen kural setleri yardımıyla yerleşim alanı, sera, yeşil bitki alanı yanmış alan ve su alanları ile diğer bölgeler uzaktan algılanmış uydu görüntüsü üzerinde sınıflandırılmıştır [55].

(Başak, Yıldırım, 2017) çalışmada, kentlerdeki kaçak yapılaşma oranı binaların otomatik olarak tespiti Göktürk-2 uydu görüntüsü kullanılmıştır [56].

(Erdem ve vd., 2018) çalışmada, Landsat 8 uydusu tarafından görselleştirilen ve Karadeniz sahilinde yer alan Terkos Gölü ve civarında bulunan alandaki kıyı çizgileri Random Forest sınıflandırma tekniği kullanılarak MATLAB programı yardımıyla tespit edilmiştir. Random Forest yöntemine ait algoritma çalışma alanlarının farklı band görüntülerinin setlerine tatbik edilerek sınıflandırma süreci sonuçlandırılmıştır. Sınıflandırma neticesinde su ve kara sınıfları diye iki sınıflı görüntüler temin edilmiştir. RGB, RGB-NIR ve NIR olmak üzere üç çeşit band seti uygulanmıştır. Elle sayısallaştırılmış olan kıyı çizgileri dayanak alınarak, çalışma sonucu elde edilen kıyı çizgilerinin, kıyı çizgisi ve alansal bazda güvenilirlikleri kontrol edilmiş yani doğruluk analizleri yapılmıştır [57].

(Hong ve vd., 2018) çalışmada, J48 Karar Ağacı (JDT) temel sınıflandırıcısı ile heyelan duyarlılık değerlendirmesi için AdaBoost, Torbalama ve Rotasyon Orman gibi mevcut son teknoloji topluluk tekniklerinin kullanımını araştırılmış ve karşılaştırılmıştır. Elde edilen modellerin genel performansı, alıcı çalışma karakteristiği eğrisi ve istatistiksel indisler altında alan kullanılarak değerlendirilmiş ve

karşılaştırılmıştır. Sonuç olarak, Rotasyon Orman'daki JDT'nin bu çalışmada en iyi optimize edilmiş model olduğu ve daha iyi doğruluk için benzer durumlarda heyelanlara duyarlılık haritalaması için umut verici bir yöntem olduğu düşünülmektedir [58].


(Guo, Jia, Paull, 2018) çalışmada, çok zamanlı uzaktan algılama görüntü sınıflandırması için DVM tabanlı bir Sıralı Sınıflandırıcı Eğitimi (SCT-SVM) yaklaşımı önerilmiştir. Bu yaklaşım, gelen bir görüntünün sınıflandırıcı eğitimi için gereken sayıda eğitim örneğini azaltmak için önceki görüntülerin sınıflandırıcılarını kullanır. Her gelen görüntü için, bir önceki sınıflandırıcı setinin zamansal eğilimine dayanan kaba bir sınıflandırıcı ilk olarak tahmin edilir. Öngörülen sınıflandırıcı daha sonra mevcut eğitim örnekleriyle daha doğru bir konuma ince ayar yapılır. Bu yaklaşım, her bir görüntüden sadece az sayıda eğitim numunesi alınmasıyla, ardışık olarak görüntü verisine uygulanabilmiştir [12].

(Maxwell, Warner, Fang, 2018) makalede, uygulamalı bir perspektiften makine öğrenimine genel bir bakış sunulmaktadır. Destek Vektör Makineleri, Tek Karar Ağaçları (DT'ler), Rastgele Orman, Artırılmış DT'ler, Yapay Sinir Ağları ve k-En Yakın Komşular (k-NN) yöntemleri üzerinde çalışılmıştır. Ayrıca algoritma seçimi, eğitim veri gereksinimleri, kullanıcı tanımlı parametre seçimi ve optimizasyonu, özellik alanı etkileri ve azaltma ve hesaplama maliyetleri üzerine çalışmalar yapılmıştır [59].

2. MATERYAL VE YÖNTEM

2.1. Çalışma Alanı

TOD (Türkiye Ormancılar Derneği) raporuna (<http-1>) göre Türkiye'nin 1'inci derece orman yangını riski olan Antalya ilinde, 2016 yılı Haziran ayında Adrasan ve Kumluca bölgelerinde gerçekleşen orman yangını üzerinde çalışma yapılmıştır. Bahsi geçen raporda 2004-2016 yılları arasında Antalya'da toplam 26166 hektar orman alanı yanmıştır. Bölgeye ait Google Earth uydu görüntüsü Şekil 2.1. de verilmiştir. Kumluca'daki yangın alanında yaklaşık 300 dekar alan bahçe ve 200 dekar alan sera tahrip olmuş ve 17 adet hane yanmış, 60 adet büyük ve küçükbaş hayvan zayi olmuştur. Adrasan 'da meydana gelen yangın alanında yaklaşık 100 büyük ve küçükbaş hayvan telef olmuştur [55].



Şekil 2.1. Kumluca ve Adrasan yangın alanları

2.2. Veri

Yanmış alanların tespitiye yönelik 2016 yılı Haziran ayı sonrasına ait Göktürk-2, Landsat-8 ve Worldview-2 uydularına ait uzaktan algılanmış görüntüler kullanılmıştır. Çalışmada kullanılan uydulara ait bilgiler aşağıdaki gibidir;

2.2.1. Göktürk-2 uydusunun özellikleri

TAI ile bütünleşmesi gerçekleştirilen ve tamamıyla TÜBİTAK UZAY personeli tarafından tasarlanan ve geliştirilen Göktürk 2 keşif uydusu 2012 yılı Aralık ayında Çin’de bulunan Jiuquan Fırlatma Üssü’nden fırlatılmıştır. 2,5 m çözünürlüğe malik olan uydu 409 kg ağırlığındadır. Uydu için geliştirilen görev bilgisayarı, bu bilgisayarda kullanılan tüm görev yazılımları TÜBİTAK UZAY mühendisliğinde tamamıyla Türkiye’de yapılmıştır. Türkiye’nin Cumhuriyet tarihinde bu maksatla üretilen ilk uydusu olma özelliğini taşımaktadır. Göktürk 2 uydusu 5 bant görüntüye sahip olup bunlar; PAN, Red, Green, Blue ve NIR’dir. Uydunun gerçek renk kombinasyonu 1, 2, 3’tür. Göktürk-2 uydusuna ait spektral band bilgileri Tablo 2.1’deki gibidir (http-2).

Tablo 2.1. Göktürk-2 uydusuna ait spektral band bilgileri

Band Numarası	Band Kodu	Dalga Boyu (µm)	Maksimum Çözünürlüğü (m)
1	Mavi	0,45-0,52	5
2	Yeşil	0,52-0,6	5
3	Kırmızı	0,63-0,69	5
4	Yakın Kızılötesi	0,76-0,9	5
5	Pankromatik	0,42-0,75	2,5

Çalışmada kullanılmak üzere 02.07.2016 tarihli uydu görüntüsü Hava Kuvvetleri Komutanlığı Uydu Taburundan temin edilmiştir. © Göktürk-2 verisinin mülkiyeti Genelkurmay Başkanlığı’na aittir ve tüm hakları Genelkurmay Başkanlığı tarafından saklı tutulmaktadır.

2.2.2. Landsat-8 uydusunun özellikleri

Landsat-8, NASA tarafından geliştirilen Landsat uydusu serisinin sekizinci üyesidir. Ormanlar, su, yiyecek benzeri insanların hayatlarını idame ettirmeleri için gerekli olan kaynakların izlenmesi, düzenlenmesi ve anlaşılmasında büyük rol oynayan elzem bilgilerin temin edilmesine ve Landsat programının devam etmesine olanak vermiştir.

Landsat-8, termal-kızılötesi, kısa-dalga-kızılötesi yakın-kızılötesi ve görünür dalga boyu aralıklarında görüntü temin etmektedir. Landsat 8 uydusu spektral değere göre 15 metre ile 100 metre arası uzamsal çözünürlüğe sahip veriler temin etmektedir. Landsat-8 günde 400 görüntü çekebilme kabiliyetiyle Landsat-7 uydusunun günde 250 görüntü çekme yeteneğine göre büyük bir avantaj sağlamaktadır.

Landsat-8 uydusu iki adet görüntüleme sensörü taşımaktadır: Operasyonel Arazi Görüntüleyici (OLI, Operational Land Imager), Cirrus bulutlarını tespit etmek için kısa-dalga-kızılötesi band, kıyı bölgesi ve su kaynaklarının araştırılması için özel olarak geliştirilmiş derin mavi band ve Landsat-8 uydusuna ait her ürüne bir Kalite Değerlendirme bandı da dahil edilmiştir.

Termal Kızılötesi Sensörü (TIRS, Thermal Infrared Sensor) önceki TM ve ETM + algılayıcılarından farklı olarak bir band tarafından kapsanan dalga boyu yerine iki tane spektral banda maliktir. Bu algılayıcılar, tanımlanmış gelişmiş gürültü sinyalinin (SNR) 12-bit dinamik mesafede radyometrik performansını temin eder. Bu, daha önceden geliştirilmiş 8 bitlik performansa sahip cihazlarda yalnızca 256 gri düzeyle mukayese edildiğinde görüntüdeki 4096 potansiyel gri düzeyine çevirir. Arazi kullanım durumunun daha iyi tanımlanabilmesi için gürültü performansına yönelik sinyal geliştirilmiştir. Temin edilen görüntüler 16 bit olarak hizmete sunulmaktadır. Landsat 8 uydusu, 15 metre ile 100 metre arası orta çözünürlüğe sahip veriler temin etmektedir.

Landsat uydularına ait görüntülerin birinci düzey görüntülerini web sitesi üzerinden herhangi bir ücret ödenmeden indirilebilmektedir (<http-3>). Bu tez çalışmasında Operasyonel Arazi Görüntüleyicisinden temin edilen 7 spektral band değere sahip uydusu görüntüsü yanmış alanların tespiti için kullanılmıştır (<http-4>).

Çalışma için temin edilen uydu görüntüsüne ait band bilgileri Tablo 2.2’de verilmiştir (http-5). Çalışma için 09.08.2016 tarihine ait ve yangın sonrası ait uydu görüntü kullanılmıştır.

Tablo 2.2. Landsat-8 uydusuna ait spektral band bilgileri

Band Numarası	Band Kodu	Dalga Boyu (µm)	Maksimum Çözünürlüğü (m)
1	Kıyı	0,435-0,451	30
2	Mavi	0,452-0,512	30
3	Yeşil	0,533-0,590	30
4	Kırmızı	0,636-0,673	30
5	Yakın Kızılötesi	0,851-0,879	30
6	Kısa Dalga Kızılötesi-1	1,566-1,651	30
7	Kısa Dalga Kızılötesi-2	2,107-2,294	30
8	Pankromatik	0,503-0,676	15

2.2.3. Worldview-2 uydusunun özellikleri

2009 yılının Ekim ayında WorldView-2 uydusu uzaya fırlatılmıştır. Worldview-3 uzaya fırlatılana kadar dünyanın 8 adet multispektral banda sahip ilk ve tek gözlem uydusuydu. 0,46 metre yersel pankromatik çözünürlüğe ve 1,84 metre multispektral yersel çözünürlüğe sahip olan WorldView-2 uydusu 770 km. irtifada konumlandırılmak suretiyle görüntü temin edilmektedir. Yaklaşık olarak 1,1 günlük tekrar ziyaret etme kabiliyetine sahiptir. Her gün en fazla 975,000 km²’lik alanın görüntüsünü çekebilme yeteneğine haizdir. Çalışmada 14.07.2016 tarihli Worldview 2 uydusuna ait 8 spektral band yanmış bölgelerin belirlenmesi maksadıyla kullanılmıştır.

Worldview-2 uydusuna ait spektral band bilgileri Tablo 2.3’de verilmiştir [60].

Tablo 2.3. Worldview 2 uydusuna ait spektral band bilgileri

Band Numarası	Band Kodu	Dalga Boyu (µm)	Maksimum Çözünürlüğü (m)
1	Kıyı	0,400-0,450	1,85
2	Mavi	0,450-0,510	1,85
3	Yeşil	0,510-0,580	1,85
4	Sarı	0,585-0,625	1,85
5	Kırmızı	0,630-0,690	1,85
6	Kırmızı Kenar	0,705-0,745	1,85
7	Yakın Kızılötesi-1	0,770-0,895	1,85
8	Yakın Kızılötesi-2	0,860-1,040	1,85
9	Pankromatik	0,450-0,800	0,46

2.3. Uzaktan Algılamada İleri Sınıflandırma Teknikleri

2.3.1. Nesne tabanlı sınıflandırma

Uydu ve algılayıcı teknolojilerindeki gelişim sonucu daha yüksek çözünürlükte uydu görüntüleri elde edilmeye başlanmıştır. Bunun sonucu olarak piksel tabanlı sınıflandırma olan eğitilmiş ve eğitimsiz sınıflandırma yerine yeni çalışmalarda nesne tabanlı sınıflandırmalara yer verilmeye başlanmıştır [34, 39, 53, 61]. Ayrıca bilgisayar programlarının işlem süreleri karşılaştırıldığında çalışılan alana bağlı olarak nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha avantajlı olduğu görülmektedir.


Geleneksel piksel tabanlı görüntü işlemenin aksine, nesne tabanlı görüntü analizinin yapı taşları bitişik homojen görüntü parçalarıdır. Bu segmentler genellikle görüntü nesneleri olarak hareket ederler. Nesne tabanlı görüntü analizinin insanın görsel algılarına göre anlamlı nesneler için gruplandırılmış pikseller, komşuluk ilişkileri dikkate

alınarak oluşturulmuş bağlamsal bilgiler ve farklı boyuttaki nesnelerden üretilmiş çoklu ölçekler gibi bilgiler bir görüntünün analiz edilmesini mümkün kılmaktadır. Yararlı görüntü nesneleri üretmek için, tüm analiz süreci için uygun bir görüntü bölümlenmesi hayati önem taşımaktadır. İçeriğe dayalı bilgilerden yararlanmak için nesnelerin komşuluklarının farkında olunması gerekir. Farklı büyüklükteki nesneler dikkate alınarak hiyerarşik olarak organize edilmelidir. Bu çalışmada kullanılan eCognition yazılımı görüntü nesnelerinin hiyerarşik bir ağı ve uygun bir görüntü segmentasyonu seçerek çoklu çözünürlük segmentasyonu gerçekleştirebilir. Böylece görüntü nesneleri, renk ve şekil olarak homojenlik kriterleri dikkate alınarak üretilir. Nesnelerin boyutu, nesnelerin izin verilen maksimum heterojenliğini belirleyen “Ölçek Parametresi” tarafından ayarlanır [62].

Temel olarak nesne tabanlı sınıflandırma; segmentasyon yani nesne çıkarımı ve sınıflandırma olarak iki farklı işlem basamağı içermektedir [63].

2.3.1.1. Görüntü Bölütleme (Segmentasyon)

Segmentasyon sözlük anlamı olarak “Bir vücut veya yapının benzer parçalardan oluşması”dır (http-6). Nesne tabanlı sınıflandırmada ilk adım görüntü nesnelerinin oluşturulmasıdır. Nesneleri oluşturmak için eCognition yazılımı yaygın olarak kullanılmaktadır. “Çok çözünürlüklü bölütleme” (Multiresolution Segmentation) uzaktan algılanmış görüntülerde oldukça iyi çözümler sunmaktadır [62]. Bir görüntüden yararlı bilgiler elde etmek için, segmentasyon süreci, görüntü nesneleri ve görüntü analizinin geri kalanı için temel oluşturan, sınıflandırılmamış “nesne ilkelleri”ne bölünür. Segmentasyonlar ve nesne temelleri ile nihai görüntü nesnelerinin ortaya çıkan özellikleri, kullanıcı tarafından ayarlanan parametreler aracılığıyla kontrol edilen şekil, boyut, renk ve piksel topolojisine dayanır. Parametrelerin değerleri, görüntü katmanlarının şekil ve boyutlarını tanımlamada görüntü katmanlarının spektral ve uzamsal özelliklerinin ne kadar etkileyeceğini tanımlar. Kullanıcı, hedefe, görüntü kalitesine, mevcut bantlara ve görüntü çözünürlüğüne bağlı olarak ayarları değiştirir.



Şekil 2.2. *Pikseller (a) bir segmentasyon işlemiyle görüntü nesnelere (b) gruplandırılmıştır*

Genel bir kural olarak, 'iyi' imaj nesneleri mümkün olduğunca geniş olmalı, ancak ilgi alanlarını gösterecek kadar küçük olmalı ve henüz tanımlanmamış ilgi nesneler için yapı taşları olarak görev yapmalıdır. Eğer, amaç büyük binaları sınıflandırmaksa, her nesne sadece bir (veya bir grup) bina içermelidir. Tek bir bina çok sayıda küçük nesneden oluşuyorsa, nesneler çok küçüktür. Segmentasyon parametreleri için “en iyi” ayarlar çok çeşitlidir ve genellikle deneme yanılma, hata ve deneyimin bir kombinasyonu ile belirlenir. Bir resim için iyi çalışan ayarlar, görüntüler benzer olsa bile, başka bir yerde çalışmayabilir.

Renk/şekil, yoğunluk/pürüzsüzlük, ölçek ölçütleri segmentasyon işleminde kullanılan en yaygın üç parametredir [63].

2.3.1.1.1. Renk / Şekil Parametresi

Renk ve şekil parametreleri, bir segmentasyon sırasında nesnelerin nasıl oluşturulduğunu etkiler. Renk veya şekil kriteri için değer ne kadar yüksek olursa, sonuçta elde edilen nesneler spektral veya uzaysal homojenlik için optimize edilir. Şekil ölçütü içinde, kullanıcı ayrıca nesnelerin düzgünlüğünün (nesne sınırının) ve yoğunluğunun derecesini de değiştirebilir.

Renk ve şekil parametreleri birbirini dengeler, yani eğer renk yüksek bir değere sahipse (segmentasyon üzerinde yüksek bir etkiye sahipse), şekil daha az etkiye sahip yani düşük bir değere sahip olmalıdır. Renk ve şekil parametreleri eşitse, her biri parçalanma sonucu üzerinde kabaca eşit miktarlarda etkilere sahip olacaktır.

Renk ve şekil ölçütleri, farklı ağırlıklar alarak 1'e tamamlanan iki ölçüt olarak değerlendirilmelidir. Örneğin; rengin 0,6 olarak belirlendiği bir segmentasyonda şekil

ölçütü 0,4 olmalıdır [63]. Deneme yanılma yoluyla ağırlıklar için ideal değerlerin saptanması için literatürde renk ölçütünün mümkün olduğunca yüksek değerde olması arzulanmaktadır [64].

2.3.1.1.2. Yoğunluk / Pürüzsüzlük Parametresi

Renk ve şekil ölçütünde olduğu gibi birbirini tamamlayan diğer bir parametre de yoğunluk ve pürüzsüzlüktür. Renk yoğunluğu ölçütünün değerlerinin değiştirilmesi renge bağlı olarak diğer nesnelerin daha kolay/zor tespit edilmesini sağlarken pürüzsüzlük parametresinin değeri ise nesnelerin sınırlarının belirlenmesinde yardımcı olur [63].

2.3.1.1.3. Ölçek Parametresi

Ölçek parametresinin değeri, görüntü nesnelerinin boyutunu belirleyerek görüntü bölümlmeyi etkiler. Ölçek değeri yüksekse, her bir nesnede izin verilen değişkenlik yüksektir ve görüntü nesneleri nispeten büyüktür. Tersine, küçük ölçek değerleri her segmentte daha az değişkenliğe izin vererek nispeten küçük segmentler oluşturur.

2.3.1.2. İndisler


Segmentasyon işlemi yapılırken yukarda geçen parametreler belirlendikten sonra nesnelerin daha kolay çıkarılması için band değerleri bir takım formülasyon işlemine tabii tutularak oranlar elde edilir. Bu çalışma kapsamında kullanılan indisler aşağıdaki gibidir;

2.3.1.2.1. Normalize Edilmiş Fark Bitki Örtüsü İndisi (NDVI)

Bu indis, yakın kızılötesinin (bitki örtüsünün güçlü bir şekilde yansıdığı) ve kırmızı ışığın (bitki örtüsünün emdiği) arasındaki farkı tespit ederek bitki örtüsünü ölçmektedir. NDVI, -1 ve +1 değerleri arasında bir değer alır. Örneğin, bir bölge için hesaplanan değerler negatif olduğunda, bu bölgenin su olması büyük olasılıktır. Öte yandan, bu değer +1'e yaklaşıyorsa, bu bölgede yoğun yeşil yapraklı bitkiler olma olasılığı yüksektir. NDVI sıfıra yakın olduğunda ise kentleşmiş bir alan olabilir.

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad [27] \quad (2.1)$$

Çalışılan alan için hesaplanmış NDVI indisine ait ekran görüntüsü Şekil 2.3’de verilmiştir.




Şekil 2.3. NDVI’ya ait eCognition ekran görüntüsü

2.3.1.2.2. Bitki Örtüsü Oran İndisi (RVI)

RVI, yakın kızılötesinin kırmızı banda oranı sonucu elde edilen değerdir. RVI indisine ait ekran görüntüsü Şekil 2.4’de verilmiştir.

$$RVI = \frac{NIR}{Red} \quad [65] \quad (2.2)$$



Şekil 2.4. RVI’ya ait eCognition ekran görüntüsü


2.3.1.2.3. Toprak Ayarlı Bitki Örtüsü İndisi (SAVI)

Bitki örtüsü oranının düşük olduğu (yani, <%40) ve toprak yüzeyinin maruz kaldığı bölgelerde yakın kızıl ötesi ve kırmızı spektrumlarda yansıma bitki örtüsü indis sonucunu etkileyebilmektedir. Yakın kızılötesi ve kırmızı dalga boylarında (yani değişik parlaklık değerlerine sahip topraklarda) farklı miktarlarda ışık yansıtabilen farklı toprak tiplerinde karşılaştırmalar yapıldığında özellikle sorunlu bir durumdur. Toprak Ayarlı Bitki Örtüsü İndisi, bitki örtüsü az olduğunda toprak parlaklığının etkisini düzeltmek için Normalleştirilmiş Fark Bitki Örtüsü İndisinin modifikasyonu olarak geliştirilmiştir.

SAVI, NDVI'la benzer şekilde yapılandırılmış, ancak “toprak parlaklığı düzeltme faktörü” eklenmiştir.

$$SAVI = (1+L) \frac{(NIR - Red)}{(NIR + Red + L)}$$
$$SAVI = (1+0,5) \frac{(NIR - Red)}{(NIR + Red + 0,5)} \quad [66] \quad (2.3)$$

Formülde kullanılan NIR, yakın kızılötesi bandın yansıtma değeridir, KIRMIZI kırmızı bandın yansımasıdır ve L, toprak parlaklığı düzeltme faktörüdür. L'nin değeri yeşil bitki örtüsünün miktarına veya kaplamasına göre değişir: çok yüksek bitki örtüsünde, L = 0 ve yeşil bitki örtüsü olmayan alanlarda, L = 1 olarak alınır. Genel olarak L için varsayılan değer 0,5'dir ve bu değer çoğu durumda iyi çalışır. L = 0 olduğunda SAVI NDVI'a eşittir. SAVI'ye ait ekran görüntüsü Şekil 2.5. deki gibidir.




Şekil 2.5. SAVI'ye ait eCognition ekran görüntüsü

2.3.1.2.4. Küresel Çevre İzleme İndisi (GEMI)

GEMI, atmosferik etkilerin göreceli etkisini en aza indirecek şekilde tasarlanan farklı bir indisin türetilmesinden oluşan alternatif bir indistir. Düşük bitki örtüsüne göre basit bir oran gibi davranan ve derin bitki örtüsü üzerinde NDVI gibi davranacak bir indis araştırıldığında kanalların doğrusal olmayan bir kombinasyonunun veya basit oranın gerekli olacağı sonucu ortaya çıkmıştır. GEMI, atmosferik etkilerle ilgili olarak, atmosferin üstündeki bitki örtüsü indisinin yüzeyin üzerindeki değeri mümkün olduğu kadar yüksek olan bir ‘iletim’ ve ‘aktarım’ indis değerlerine göre mümkün olduğunca duyarsız, atmosferin optik kalınlığındaki değişimlere göre mümkün olduğunca duyarsız bir ‘iletim’ özelliğine sahiptir. Ayrıca yeterince geniş bir dinamik aralığa sahiptir ve basit oran veya NDVI ile karşılaştırılabilir bir şekilde yüzey bitki örtüsünün kaplamasını deneysel olarak temsil etmektedir.

$$GEMI = \gamma(1 - 0,25\gamma) - \frac{(Red - 0,125)}{(1 - Red)}$$
$$\gamma = \frac{\left[2x(NIR^2 - Red^2) + (1,5xNIR) + (0,5xRed) \right]}{(NIR + Red + 0,5)} \quad [67] \quad (2.4)$$

GEMI'ye ait ekran görüntüsü Şekil 2.6. daki gibidir.




Şekil 2.6. GEMI'ye ait eCognition ekran görüntüsü

2.3.1.2.5. *Ashburn Bitki İndisi (AVI)*

Bu indis seyrek bitki örtüsüne duyarlıdır, yani %15-20 bitki örtüsü, çıplak topraktan erken dönem bitki örtüsünü ayırt edebilir. NDVI'da olduğu gibi, yüksek bitki örtüsündeki stres tespitine karşı hassasiyeti zayıftır. Toprak zeminine olan duyarlılığı ve yüksek yeşillikte azalan duyarlılığı, bu indis bitki örtüsü stresinin zayıf bir göstergesi olduğunu göstermiştir. Bu indis, atmosferik zayıflama etkilerini SR İndisi veya NDVI'dan daha fazla azaltır.

$$AVI = 2 \times NIR - Red \quad [68] \quad (2.5)$$

AVI'ye ait ekran görüntüsü Şekil 2.7. deki gibidir.




Şekil 2.7. AVI'ye ait ekran görüntüsü

2.3.1.2.6. *Bitki Örtüsü İndisi (VI)*

Bitki Örtüsü İndisi (VI), bitki örtüsü özelliklerinin katkısını arttırmak ve karasal fotosentez aktivitesi ile kanopi yapısal varyasyonlarının güvenilir mekânsal ve zamansal karşılaştırılmasını sağlamak için tasarlanmış iki veya daha fazla bandın spektral bir dönüşümüdür.

$$VI = \frac{(Green - Red)}{(Green + Red)} \quad [69] \quad (2.6)$$


VI'ya ait ekran çıktısı Şekil 2.8. deki gibidir.



Şekil 2.8. VI'ya ait ekran görüntüsü


2.3.2. Destek vektör makineleri (DVM)

Destek Vektör Makineleri karar sınırlarını tanımlayan karar düzlemleri kavramına dayanmaktadır. Bir karar düzlemi, farklı sınıf üyeliklerine sahip nesneler kümesi arasında ayırım yapan bir düzlemdir. Aşağıda Şekil 2.9. da şematik bir örnek gösterilmiştir. Bu örnekte, nesneler ya YEŞİL veya KIRMIZI sınıfına aittir. Ayırma çizgisi, tüm nesnelerin YEŞİL olduğu ve solunda tüm nesnelerin KIRMIZI olduğu sol tarafta bir sınır tanımlar. Sağa düşen herhangi bir yeni nesne (beyaz daire) etiketlenir, yani YEŞİL olarak sınıflandırılır (veya KIRMIZI olarak ayırma çizgisinin solunda kalmalıdır).




Şekil 2.9. Doğrusal olarak ayrılabilen veri seti

Yukarıdaki, doğrusal bir sınıflandırıcının klasik bir örneğidir. Yani, bir dizi nesneyi kendi gruplarına ayıran bir sınıflandırıcıdır (bu durumda YEŞİL ve KIRMIZI). Bununla birlikte çoğu sınıflandırma görevi optimal bir sınıflandırma yapmak yani mevcut olan örneklerle dayanarak yeni nesneleri doğru bir şekilde sınıflandırmak için çoğu zaman daha karmaşık yapılara ihtiyaç duymaktadır. Şekil 2.10. Şekil 2.9. a kıyasla, YEŞİL ve KIRMIZI nesnelerin tam olarak ayrılmasının bir eğri gerektireceği açıktır (bir satırdan daha karmaşıktır). Farklı sınıf üyelikleri arasındaki nesneleri ayırmak için ayırma çizgilerinin çizilmesine dayanan sınıflandırma görevleri hiperdüzlem sınıflandırıcıları olarak bilinir.



Şekil 2.10. Doğrusal olarak ayrılamayan veri seti

Uzaktan algılanmış uydu görüntüleri gibi doğrusal olmayan verilerin sınıflandırılması probleminin çözümünde klasik doğrusal olmayan çözümler mümkün değildir. Bu sorunun çözümü için iki sınıfa ait verileri uygun şekilde birbirinden ayırmak gerekir. Böyle bir durum olduğunda eğitim verilerinin belli bir kısmı optimum (en uygun) hiperdüzlemin öbür kısmında olmasından kaynaklanan sorun pozitif bir suni parametrenin (ξ_i) tanımlanmasıyla çözülür [Şekil 2.11]. Yanlış sınıflandırma hatalarının minimum hale getirilmesi ve sınırın maksimum hale getirilmesi arasındaki denge C ile gösterilen ve pozitif değere sahip bir düzenleme parametresi $0 < C < \infty$ tanımlanmasıyla giderilebilir [13].



Şekil 2.11. Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi

Düzenleme değişkeni ve suni parametre kullanılarak doğrusal ayrılamayan datalar için en uygun duruma getirme problemi:

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (2.7)$$


şeklini alır.

Buna bağlı sınırlamalar ise;

$$\begin{aligned} y_i (w\phi(x_i) + b) - 1 &\geq 1 - \xi_i \\ \xi &\geq 0 \text{ ve } i = 1, \dots, N \end{aligned} \quad (2.8)$$

şeklinde ifade edilir.

Formül 2.7 ve 2.8’de belirtilen en uygun duruma getirme sorununun çözümü için Şekil 2.12. den anlaşılacağı gibi girdi uzayında “n” boyutlu ve doğrusal ayrılamayan data Kernel Trick (çekirdek numarası) olarak bilinen yöntemle “n+1” hatta daha büyük boyutlara dönüştürülür. Böylelikle sınıflandırmanın daha hızlı ve daha yüksek doğrulukta yapılması sağlanır. Biraz daha açıklamak gerekirse Şekil 2.12. de KIRMIZI ve YEŞİL renkli verileri iki boyutlu olarak birbirinden ayırmakta zorlanırken, veriyi çekirdek numarası kullanarak üç boyutlu yapıldığında DVM’le oluşturulan hiperdüzlem sayesinde KIRMIZI ve YEŞİL verileri birbirinden kısa sürede ve kolaylıkla ayrılabilir.



Şekil 2.12. Verinin Kernel fonksiyonu yardımıyla daha yüksek bir boyuta transformasyonu

Matematiksel gösterimde DVM;

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (2.9)$$

şeklinde temsil edilen kernel fonksiyonu vasıtasıyla doğrusal olmayan transformasyonlar gerçekleştirilebilmekte ve bunun sonucu olarak dataların yüksek boyutta doğrusal ayırma işlemini mümkün kılmaktadır. Nihai olarak, kernel fonksiyonundan yararlanılarak doğrusal olarak ayırma işlemi yapılamayan iki sınıfa ait bir sorunun çözülmesi ile ilgili karar ilkesi aşağıdaki biçimde oluşturulabilir [70]:

$$f(x) = \text{sign} \left(\sum_i \alpha_i y_i \phi(x_i) \cdot \phi(x_j) + b \right) \quad (2.10)$$

DVM ile yapılacak bir sınıflandırma prosedürü için yararlanılacak olan kernel fonksiyonu ve bu işlevin sahip olduğu en uygun değişkenlerin tanımlanması esastır.

Literatür incelendiğinde kernel fonksiyonunun en çok kullanıldığı türleri; PUK fonksiyonu, Polinomial, Normalize Edilmiş Polinom kerneli ve Gaussian RBF (Radyal Tabanlı Fonksiyon) kernelidir. Bahsi geçen kernel fonksiyonlarının her biri için bazı değişkenlerin kullanıcı vasıtasıyla belirlenmesi gerekmektedir. PUK kullanımı için iki

adet deęişken belirlenmesi gerekirken, dięer fonksiyonların sınıflandırma yapabilmesi için bir adet deęişkenin tespit edilmesi gerektirmektedir.

Kernel fonksiyonları mukayese edildiğinde Gaussian ve polinomial kernellerin daha anlaşılabilir ve yalın olduęu söylenebilir. Matematiksel anlamda kolay görünse de polinom seviyesindeki yükseliş algoritmada karmaşık bir şekil olmasına sebep olmaktadır. Bunun sonucunda hem işlem zamanını önemli seviyede uzamakta hem de belli bir seviyeden sonra sınıflandırmanın güvenilirliği yani doğruluęu azalmaktadır. Buna rağmen Gaussian kernel boyutu (γ) diye nitelendirilen deęişkendeki yeniliklerin sınıflandırma sonucu üzerine tesirinin daha düşük olduęu gözlemlenmiştir [71]. Normalize edilmiş polinom fonksiyonu data setinin normalize edilmesi yerine polinomial kernelin sahip olduęu matematiksel anlatımın normalleştirilmesi maksadıyla önerilmiştir [72]. Normalize edilmiş polinomial kernelin, polinomial kernelin genelleştirilmesi sonucu oluşmuş bir şekli olduęu ifade edilebilir. Öte yandan, PUK kerneli (σ, ω) iki deęişken olarak tanımlanan Pearson açıklığı ile dięer kernel işlevlerine göre daha kompleks bir matematiksel özellięi elinde bulundurmaktadır. Bahsi geçen iki deęişken sınıflandırmanın güvenilirliğine tesir etmekte olup hangi deęişken ikilisinin optimum netice vereceęi önceden tahmin edilememektedir. Bundan dolayı PUK kernelinden yararlanmaya en elverişli deęişken çiftinin tespit edilmesi elzem bir aşamadır.

Kernel işlevine has deęişkenlerin yanında bütün DVM için “C” yani düzenleme deęişkeninin kullanıcı vasıtasıyla tayin edilmesi gerekir. Bahsi geçen deęişken için lüzum gelen çok büyük veya çok küçük deęerler tespit edilmesi durumunda en uygun hiperdüzlem doğru tayin edilemeyeceğinden gruplandırma doğruluğunda kritik seviyede bir azalma beklenir. Öte yandan $C = \infty$ şeklinde olması halinde DVM modeli yalnızca doğrusal ayrımı sağlanabilen data setleri için uygundur. Bu bilgi ışığında deęişkenler için uygun deęerlerin tayini Destek Vektör Makineleri sınıflandırıcısının başarımını doğrudan tesir eden bir etmen konumundadır. Çoğunlukla deneme ve yanılma yöntemi izlenmesine rağmen, çapraz doğrulama yöntemi muvaffakiyetli sonuçlara erişilmesine imkan tanımaktadır. Çapraz doğrulama yönteminde gaye meydana getirilen sınıflandırma modelinin başarımının tespit edilmesidir. Bu gaye ile data seti iki bölüme ayrılır. Birinci bölüm sınıflandırmaya temel teşkil eden modelin oluşturulmasında eğitim datası şeklinde yararlanılan ve ikinci bölüm modelin başarımının tespit edilmesi maksadıyla test datası olarak işleme tabi tutulur. Eğitim seti ile meydana gelen modelin test data setine tatbik

edilmesi neticesinde doğru sınıflandırılan örneklerin adedi sınıflandırıcının başarımını göz önüne serer. Bundan dolayı çapraz geçerlilik metodu kullanılarak optimum sınıflandırma başarımının temin edildiği kernel değişkenlerinin tespit edilmesi ve sınıflandırmaya temel olacak model oluşturulmuştur.

Kullanılan bu yöntemde en önemli problem kernel fonksiyonunda hangi parametrenin kullanılacağına karar verilmesidir [73].

2.3.3. Rotasyon Orman

Rotasyon Orman, özellik çıkarmaya dayalı sınıflandırma toplulukları üretmek için başarılı bir yöntemdir [10]. Bu yöntemin amacı bir sınıflandırıcı topluluğu içinde bireysel doğruluğu ve üye çeşitliliğini teşvik etmektir [46]. Sınıflandırma için kullanılan Rotasyon Orman algoritması doğrusal bir dönüşüm metodudur ve bir sınıflandırıcı topluluğu içinde yeni bir performans alanı sağlar [11]. Rotasyon Orman algoritması temel çalışma prensibi olarak Rastgele Orman algoritmasına benzer şekilde birçok ağaç algoritması kullanmaktadır. Bununla birlikte veri setini oluşturmak için PCA (Temel Bileşen Analizi) gibi farklı özellik alanı kullanarak Rastgele Orman'dan farklıdır. Bu özellik alanı ile belirlenen alan ile belirlenen eğitim veri kümelerini kullanarak birçok karar ağacı üretilmektedir. Rotasyon Orman kullanarak karar ağaçları eğitimi sırasında eğitim veri seti alt kümelere ayrılır ve her bir alt kümeden seçilen özellik alanı olarak öznelik çıkarılır [53]. Bu özellik sebebiyle Rotasyon Orman algoritması Rastgele Orman'a göre daha iyi bir sınıflandırma doğruluğu sonucu vermektedir [10].

Rotasyon Orman algoritmasına ait ana çalışma ilkesi aşağıdaki gibidir;

A değerinin eğitim data setini, B değerinin data setindeki grup etiketlerini ve F değerinin de nitelik sayısını sembolize ettiğini farz edelim. Eğitim data setinin N tane pikselden meydana geldiği ve n tane arazi kullanımı/örtü sınıfı olduğu varsayılırsa, eğitim data seti (A), $N \times n$ ölçüsünde bir matris şeklindedir. Grup etiketlerini temsil eden B doğrusunun $[1, \dots, n]$ şeklinde olduğu varsayılınsın. Data setinin aşağı yukarı olarak benzer ölçüde K tane alt kümeye ayrılmaktadır. Rotasyon Orman'daki karar ağaçları T sayıda olduğu ve $D_1, \dots, D_T$ şeklinde temsil edildiği kabul edilsin. Rotasyon Orman algoritmasında kullanıcı tanımlı K ve T parametreleri mevcuttur. Bu parametrelerle Rotasyon Orman metoduyla karar ağaçları kullanılarak veri setleri oluşturulur.

1. Basamak: F, K'yı rastgele şekilde altkümelere böler. Altkümelerin her biri $M=n/k$ tane niteliği içermektedir.

2. Basamak: F_{ij} değerinin D_i gruplandırıcısının eğitiminde harcanan sayıda niteliği barındıran alt kümesi ve X_{ij} 'nin X data setinde F_{ij} değerindeki nitelikleri barındıran data seti olduğu varsayılın ve yeni bir eğitim data seti bootstrap yaklaşımı için üretilsin. Data setinin 2/3'ü eğitim verisi için ve 1/3'ü de test verisi için kullanılsın. Bunun sonrasında meydana getirilen data setine esas bileşen transformasyonu oluşturularak ortak değişim matrisi oluşturulur.

3. Basamak: R_i dönüşüm matrisi ortak değişim matrisindeki değerlerden faydalanılarak oluşturulur (Formül 2.11).

$$R_i = \begin{pmatrix} a_{i,1}^{(1)}, a_{i,1}^{(2)}, \dots, a_{i,1}^{(N_1)} & [0] & \dots & [0] \\ [0] & a_{i,2}^{(1)}, a_{i,2}^{(2)}, \dots, a_{i,2}^{(N_2)} & \dots & [0] \\ \vdots & \vdots & \ddots & \vdots \\ [0] & [0] & \dots & a_{i,K}^{(1)}, a_{i,K}^{(2)}, \dots, a_{i,K}^{(N_K)} \end{pmatrix} [10] \quad (2.11)$$

2.4. Kontrol Noktası Tespiti

Çalışmada yanmış ve yanmamış alan olmak üzere iki gruplu sınıflandırma yapılmıştır. “İki Terimli Olasılık Teorisi” kullanılarak ihtiyaç duyulan kontrol noktası miktarı hesaplanmıştır.[74]. Bu teoriye göre;

$$N = Z^2_{\alpha p q} / E^2 \quad [74] \quad (2.12)$$

N: ihtiyaç duyulan örnek sayısı

Z: belirlenen güven düzeyi için Z tablosundan bakılan değer

p: çalışmadan beklenen doğruluk

q = 100 - p

E: kabul edilebilir hatadır [75].

2.5. Doğruluk Analizi

Doğruluk analizi, sınıflandırma işlemi sonrasında oluşan sınıfların doğruluklarını belirlemek amacı ile yapılan işlemdir. Doğruluk analizini basit bir şekilde açıklamak gerekirse referans olarak kullanılan harita veya arazi bilgilerinin sınıflandırılma yapılan

piksel değerleri ile istatistiksel olarak karşılaştırılması ilkesine dayanan bir denetleme usulüdür. Bu usullerden en çok tercih edilenler; genel, kullanıcı ve üretici doğruluğudur [76].

Uzaktan algılanmış görüntülerin sınıflandırılması sonucu güvenilirliklerinin tespit edilmesi amacıyla iki farklı usul yaygın olarak tercih edilmektedir. Bunlar; Hata matrisi ve Kappa katsayısı ile doğruluk analizi ve Chi-Kare (χ^2) testidir.

2.5.1. Hata matrisi ve Kappa katsayısı ile doğruluk analizi

Analizde, kullanıcı belirli noktalara ait sınıfların gerçek değerlerini girer ve bir hata matrisi oluşturulur. Bu matris [sınıf sayısı] x [sınıf sayısı] boyutlarındadır. Yanlışlar, piksellerin hatalı sınıflandırılmasından kaynaklanmaktadır. Çözümlemede hata mertebesi yerine doğruluk mertebesi de araştırılabilir. Bu işlem sonucunda çok miktarda sınıflandırılmamış piksel varsa, eğitim data setlerinin güvenilirliği düşer. Hata matrisi örneği Tablo 2.4. deki gibidir.

Tablo 2.4. Hata matrisi istatistiği örnek uygulaması

Referans Verisi							
Gerçek							
		Sera	Yerleşim	Orman	Su	Toplam	Kullanıcı doğruluğu
Tahmin	Sera	48	5	0	0	53	%90 (48/53)
	Yerleşim	8	19	2	1	30	%64 (19/30)
	Orman	2	5	22	1	30	%74 (22/30)
	Su	0	0	0	55	55	%100 (55/55)
	Toplam	58	29	24	57	168	
	Üretici doğruluğu	%83 (48/58)	%66 (19/29)	%92 (22/24)	%96 (55/57)	Genel Doğruluk= %86 (48+19+22+55) /168	

2.5.1.1. *Kullanıcı doğruluğu (KD- User Accuracy)*

Rastgele bir gruba atanmış pikselin hakikatte o gruba ait olup olmadığını gösterir. Her grup için doğru şekilde sınıflandırılmış nesne veya piksel adedinin, o gruptaki sınıflandırılan yekûn nesne yada piksel adedine oranıdır (Formül 2.13) [77].

$$KD = \frac{\alpha_{ab}}{\sum_{a=1}^N \alpha_{AK}} \quad (2.13)$$

2.5.1.2. *Üretici doğruluğu (ÜD- Producer Accuracy)*

Nesne veya pikselin reel değerinde gruplandırma ihtimalini temsil eder. Her grup için doğru şekilde sınıflandırılmış nesne veya piksel adedinin, o grup için seçilen o yer gerçeğinin tüm piksellerine göre oranıdır (Formül 2.14) [77].

$$\ddot{U}D = \frac{\alpha_{ab}}{\sum_{a=1}^N \alpha_{KA}} \quad (2.14)$$

2.5.1.3. *Komisyon Hataları (KH-Commission Errors)*

Komisyon hataları, bir sınıfta olduğu tahmin edilen ancak o sınıfa ait olmayan değerlerin bir kısmını temsil eder. Bunlar yanlış pozitiflerin bir ölçüsüdür. Her sınıf için yanlış şekilde sınıflandırılmış nesne veya piksel adedinin, o grup için seçilen o zemin gerçeğinin tüm piksellerine göre oranıdır (Formül 2.15).

$$KH = \frac{\alpha_{bb}}{\sum_{b=1}^N \alpha_{KB}} \quad (2.15)$$

2.5.1.4. *İhmal Hataları (İH- Omission Errors)*

Çıkarım hataları bir sınıfa ait olan değerlerin bir kısmını temsil eder, ancak farklı bir sınıfta olduğu tahmin edilir. Onlar yanlış negatiflerin bir ölçüsüdür. Her grup için

yanlış şekilde sınıflandırılmış nesne veya piksel adedinin, o gruptaki sınıflandırılan yekûn nesne ya da piksel adedine aritmetik oranıdır (Formül 2.16).

$$\dot{IH} = \frac{\alpha_{bb}}{\sum_{b=1}^N \alpha_{BK}} \quad (2.16)$$

2.5.1.5. Genel Doğruluk (GD- Overall Accuracy)

Her grup için doğru şekilde sınıflandırılmış nesne veya piksel adedinin, dayanak piksellerinin toplam sayısına bölünmesi ile bulunur. Sınıfların güvenilirliğiyle ilgili genel bir fikir ortaya koyar [77].

$$GD = \frac{\sum_{K=1}^M \alpha_{KK}}{\sum_{i,K=1}^M \alpha_{iK}} = \frac{1}{M} \sum_{K=1}^M \alpha_{KK} \quad (2.17)$$

Temin edilen doğrulukların kıymetlendirilmesi maksadıyla kullanılan öbür kıstas ise hata matrisinin sütun ve satır toplamlarıyla köşegen üstündeki öğeler kullanılarak hesaplanan Kappa değerinin hesaplanmasıdır. Kappa'nın değeri 0 ile 1 aralığındadır. Kappa değerinin güvenilirliği 1'e ne yakın olduğu ile alakalıdır. Değer 1'e yaklaştıkça temin edilen sınıfın güvenilirliği o kadar yüksektir [78].

$$\kappa = \frac{A \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} * x_{+i}}{A^2 - \sum_{i=1}^r x_{i+} * x_{+i}} \quad (2.18)$$

Bu eşitlikte

r: hata matrisindeki toplam sınıf sayısı,

x_{i+}: satır toplamı,

x_{ii}: hata matrisinin köşegen elemanları,

x_{+i}: sütun toplamı,

A: hata matrisindeki toplam piksel adedi olarak nitelendirilir. Kappa değerinden ve hata matrisinden temin edilen neticeler birbirinden farklıdır. Bunun sebebi ikisinin de

farklı deęerler kullanmasıdır. Hata matrisinde yalnızca köşegen öęeleri kullanılırken Kappa deęeri için ise sütun ve satırların ağırlıklı toplamaları kullanılır [79].

Ayrıca Kappa (κ) deęerlendirilirken Tablo 2.5. deki bilgiler kullanılabilir [80].

Tablo 2.5. Kappa deęerlendirme tablosu

Kappa (κ)	Yorum
<0	Hiç uyuşma olmamış
0,0-0,20	Önemsiz uyuşma olmuş
0,21-0,40	Orta derecede uyuşma olmuş
0,41-0,60	İyi derecede uyuşma olmuş
0,61-0,80	Önemli derecede uyuşma olmuş
0,81-1,00	Mükemmel uyuşma olmuş

2.5.2. Ki-Kare (χ^2) testi

χ^2 testi olarak da yazılan ki-kare testi, sıfır hipotezi doğru olduğunda test istatistiğinin örnekleme dağılımının ki-kare dağılımı olduğu herhangi bir istatistiksel hipotez testidir. χ^2 testi, bir ya da birden çok öznitelikte beklenen frekanslar ve gözlenen sıklıklar arasında manalı bir ayrım meydana gelip gelmediğini tespit etmek için uygulanır.


Testin standart uygulamalarında gözlemler, karşılıklı olarak münhasır sınıflara ayrılır ve herhangi bir gözlemin, karşılık gelen sınıfa girme olasılığını veren bazı teori veya sıfır hipotezi vardır. Testin amacı, boş hipotezin doğru olduğunu varsayarak yapılan gözlemlerin ne kadar muhtemel olduğunu deęerlendirmektir.

Ki-kare testleri genellikle karelerdeki toplam hatalardan veya örnek varyansından oluşturulur. Ki-kare dağılımını takip eden test istatistikleri, çoęu durumda merkezi limit teoreminden dolayı geçerli olan, normal olarak dağıtılmış bağımsız veriler varsayımından kaynaklanır. Verilerin bağımsız olduğu boş hipotezini reddetmek için ki-kare testi kullanılabilir.

Ki-Kare İstatistik, iki kategorik olasılık dağılımının ne kadar benzer olduğunun bir ölçütüdür. Eğer iki dağılım aynıysa, ki-kare istatistięi 0'dır, eęer dağılımlar çok farklı ise, bir miktar daha yüksek olacaktır [81-85].

2.6. Uygulama

Yanmış alanların çıkarılmasına ait akış diyagramı Şekil 2.13. deki gibi olup 6 işlem basamağından oluşmaktadır.




Şekil 2.13. Çalışmanın iş akışı

Bu basamaklarda yapılan işlem adımları aşağıdaki gibidir.

2.6.1. Uydu görüntülerinin kaynaştırılması ve füzyon işlemi


Çalışmanın ilk adımında Landsat-8 ve Worldview-2 uydularına ait görüntülere band birleştirme ve füzyon, Göktürk-2 uydusuna ait görüntüye ise band birleştirme işlemi uygulanmıştır. Üç uyduya ait görüntü kaynaştırılması sonucu elde edilen görüntüler Şekil 2.14'teki gibidir.



Şekil 2.14. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait ekran görüntüsü

Füzyon işlemi uygulanan Göktürk-2 uydu görüntüsüne segmentasyon işlemi yapıldıktan sonra görüntüde kaymalar olduğu tespit edildiği için işlem bu uydu için uygulanmamıştır.

Baş döndürücü bir hızda ilerlemekte olan ve yeni tatbik alanları keşfedilen uydu teknolojisi neticesinde değişik çoklu sensör sistemlerinden ve değişik çoklu çözünürlüğe sahip olan görüntü datalarından yararlanılmaktadır. Uydu datalarının optimum niteliklerinin (spektral ve uzaysal) yekpare görüntü datası haline getirilmesini görüntü füzyon teknolojisi sağlamaktadır [86]. Geline bu aşamada Erdas 2014 programında yer alan “HPF Resolution Merge” algoritması kullanılarak pankromatik ve spektral bantların kaynaştırılması sağlanmıştır (Şekil 2.15).




Şekil 2.15. ERDAS 2014 “HPF” ye ait ekran görüntüsü


HPF çözünürlük birleştirme işlevi, yüksek çözünürlüklü pankromatik verileri daha düşük çözünürlüklü çok merkezli verilerle birleştirmeye olanak tanır ve bu da hem mükemmel ayrıntılar hem de orijinal çok-merkezli sahne renklerinin gerçekçi bir gösterimi ile sonuçlanır. İşlem, yüksek çözünürlüklü veriler üzerinde bir Yüksek Geçiş Filtresi (HPF) kullanarak bir kıvrım içerir daha sonra bunu daha düşük çözünürlüklü multispektral verilerle birleştirir (http-7).

2.6.2. İndislerin belirlenmesi


Çalışmanın ikinci aşamasında literatür taranarak bu tip çalışmalarda kullanılan indislerden uygun olanlar belirlenmiştir [27, 65-69]. Bu indisler NDVI, RVI, SAVI, GEMI, AVI ve VI'dır. Bu indisler belirlenirken deneme yanılma yöntemiyle ve eCognition Developer (v.9.0) programında yanmış alanların tek tek yansımalarına bakılarak ve uygun olanlar seçilmiştir. Ayrıca indisler belirlenirken her üç uydu görüntüsünde kullanılabilecek olanlar seçilmiştir (Şekil 2.16, Şekil 2.17 ve Şekil 2.18).



Şekil 2.16. Göktürk-2 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü



Şekil 2.17. Landsat-8 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü



Şekil 2.18. Worldview-2 uydu görüntüsüne uygulanan indislere ait eCognition ekran görüntüsü


Örneğin; bu tip çalışmalara ait literatür araştırıldığında genellikle NBR (Normalized Burn Ratio-Normalize Edilmiş Yanma Şiddeti) indisi kullanılmaktadır [87-90].

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (2.19)$$

Formül 2.19'dan da anlaşılacağı üzere denklemi çözebilmek için SWIR band değerine ihtiyaç vardır. Göktürk-2 ve Worldview-2 uydularında SWIR band değeri olmadığı için bu indis çalışmaya dahil edilmemiştir. Her üç uydu görüntüsünde de aynı indisler kullanılmasının sebebi değişkenleri (indisleri) sabit tutarak uydu performanslarını değerlendirebilmektir.

2.6.3. Görüntü bölütleme (segmentasyon)

Üçüncü aşamada ise, eCognition Developer (v.9.0) programında segmentasyon işlemi yapılmıştır. Bu işlem yapılırken programdaki “Subset Selection” özelliği kullanılarak küçük bir alanda çalışılmıştır (Şekil 2.19).




Şekil 2.19. eCognition “Subset Selection” ekran görüntüsü

Bu özellik sayesinde küçük alanda yapılan çalışma sonucunda kısa sürede optimum parametre değerleri tespit edilmiştir. Tespit edilen parametreler Tablo 2.6. daki gösterilmiştir.

Tablo 2.6. Segmentasyon parametre değerleri

Uydunun Adı	Ölçek Parametresi	Şekil Parametresi	Yoğunluk Parametresi
Göktürk-2	80	0,3	0,7
Landsat-8	100	0,4	0,6
Worldview-2	120	0,3	0,7


Bu belirlenen parametre ve indislerle segmentasyon işlemi gerçekleştirilerek piksellerden nesneler oluşturulmuştur. Elde edilen nesneler şekil dosyası olarak kaydedilmiştir (Şekil 2.20).



Şekil 2.20. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait segmentasyon sonrası ekran görüntüsü

2.6.4. Eğitim ve test verilerinin oluşturulması

Dördüncü aşamada ise; segmentasyon sonrası oluşturulan şekil dosyaları ArcMap 10.3 programının “Clip” özelliği kullanılarak eğitim ve test olarak iki şekil dosyasına ayrılmıştır. Bu işlem her üç uydu görüntüsü için de gerçekleştirilmiştir (Şekil 2.21).




Şekil 2.21. (1) Göktürk-2, (2) Landsat-8 ve (3) Worldview-2 uydularına ait (a) test ve (b) eğitim şekil dosyaları

Bu kesme işlemi yapılırken Kumluca bölgesi eğitim verisi içerisinde ve Adrasan bölgesi ise test verisi içerisinde kalacak şekilde planlanmıştır. Daha sonra eğitim ve test verilerine ait öznetelik tablolarına “Class” alanı eklenmiştir (Şekil 2.22).

AVI	GEMI	GVI	Mean_blue	Mean_green	Mean_NIR1	Mean_red	NDVI	RVI	SAVI	CLASS
716.439976	-17386.700716	0.296742	217.693672	281.612655	285.168539	152.726198	0.302452	1.867188	0.453161	UB
879.322975	-16462.798337	0.230378	272.588099	384.550744	369.41124	240.54281	0.211276	1.53574	0.316654	UB
889.814553	-6337.934563	0.207054	345.604523	525.129204	425.121337	344.971288	0.104078	1.232338	0.156016	UB
775.871187	-12652.043926	0.244596	248.104287	338.978978	318.786686	205.742168	0.215516	1.549447	0.322967	UB
728.745829	-17022.816232	0.287632	214.044644	276.540329	284.047405	152.992751	0.299869	1.856607	0.449289	UB
795.540608	-13253.779807	0.246111	259.794172	362.899566	335.238066	219.551767	0.208523	1.52692	0.312502	UB
1054.812919	-70824.89633	0.35531	205.484899	266.640101	393.596477	126.834732	0.512578	3.103223	0.768129	UB
833.498368	-12653.334395	0.211266	263.958323	373.819985	356.461963	243.418529	0.188443	1.464399	0.282429	UB
952.980865	-40074.598673	0.286923	216.208819	290.412646	361.703827	160.915973	0.384195	2.247781	0.575742	UB
972.315789	-14391.864451	0.278216	372.859649	516.982456	412.447368	291.929825	0.171098	1.412831	0.256465	UB
1231.152542	-7792.567393	0.267089	617.222333	906.785643	613.311067	524.504487	0.07805	1.169315	0.117024	UB
925.037297	-50304.806873	0.357475	199.656523	251.957553	344.17088	119.257335	0.485326	2.885951	0.727204	UB
968.141176	-12763.358583	0.263818	435.470588	630.258824	480.647059	367.129412	0.1339	1.309203	0.200732	UB
716.711964	-21081.07888	0.328453	202.3342	253.611834	273.994798	128.203511	0.362486	2.137186	0.543054	BA
988.34104	-10460.569366	0.212419	344.190751	506.433526	431.797688	328.976879	0.135153	1.312547	0.202596	UB
370.677432	-642.759095	0.316623	228.897597	270.405278	166.264671	140.350532	0.084517	1.184639	0.126569	BA
684.628821	-14120.486989	0.29575	218.654508	276.380426	269.624454	150.214744	0.284418	1.794927	0.426119	BA
444.323857	-1719.6811	0.298548	225.908725	271.453287	188.659216	146.633966	0.125339	1.2866	0.187728	BA
717.709058	-10360.115108	0.23976	238.123606	316.120928	296.197233	193.850067	0.208852	1.527971	0.312958	BA
1168.190365	-2671.525294	0.260538	647.885004	949.869775	609.317016	557.099456	0.044768	1.093731	0.067122	UB
756.608	-14576.554368	0.272699	266.426909	355.189091	324.277091	202.977455	0.230059	1.597602	0.344762	UB
986.977528	-23449.624254	0.200018	261.205312	372.443309	401.985019	248.286347	0.236361	1.619038	0.354269	UB
335.993306	-732.348733	0.331533	210.580245	239.859918	147.941551	120.315918	0.102982	1.229609	0.154185	BA
507.635148	-2836.168144	0.278049	221.672628	270.42224	206.569894	152.757387	0.149759	1.352275	0.224327	BA
894.584833	-28505.189436	0.268908	222.066877	294.877892	339.320533	169.896208	0.332716	1.997223	0.498584	UB
914.496815	-20193.042545	0.217738	253.958066	358.035828	372.840234	230.171444	0.236594	1.619837	0.354597	UB
774.278895	-14484.052934	0.245058	233.551995	310.854756	309.406069	188.486874	0.242862	1.641526	0.363927	UB

Şekil 2.22. Eğitim verisine ait örnek öznetelik tablosu ekran görüntüsü


Eğitim verisinde yanmış alana ait nesneler seçilerek “Class” alanına “Burned Area” (yanmış alan)’ın kısaltması olan “BA” yazılmıştır. Yanmış alan dışındaki diğer alanlara ise tabloda “Unburned” (yanmamış)’ın kısaltması olan “UB” yazılmıştır. Test verisi için ise “Class” alanına “?” yazılmıştır (http-8). Bunun yazılmasındaki amaç ilgili alanın boş kalmasından dolayı oluşabilecek sınıflandırma hatalarını gidermektir. Daha sonra her üç uzaktan algılanmış görüntü için oluşturulan tablolar ArcMap programının “Export” özelliği kullanılarak “csv” uzantılı olarak dışarı alınmıştır. “csv” uzantılı dosyalar sınıflandırma işleminde kullanılacak şekilde düzenlenerek kaydedilmiştir (Şekil 2.23).



Şekil 2.23. ArcMap “Export” sekmesine ait ekran görüntüsü


2.6.5. Kural setlerinin oluşturulması

Beşinci aşamada ise; Weka 3.8.2 programında sınıflandırma işlemi yapılmıştır. Sınıflandırma işlemi için DVM ve Rotasyon Orman yöntemleri seçilmiştir (Şekil 2.24).




Şekil 2.24. (a) DVM ve (b) ROR'a ait Weka kural seti örnek ekran görüntüsü

Her üç uydu görüntüsü için ayrı ayrı eğitim verileri Weka 3.8.2 programında koşturularak optimum değer veren modeller belirlenmiştir. Daha sonra modellerde test verisi çalıştırılmıştır. Elde edilen sonuç Weka 3.8.2 programındaki "Visualize classifier errors" sekmesi kullanılarak "arff" uzantılı dosya olarak kaydedilmiştir (Şekil 2.25).




Şekil 2.25. Visualize Classifier Errors'a ait örnek ekran görüntüsü

Bu dosyalar daha sonra Notepad++ programında açılarak düzenlenmiş ve Şekil 2.26'daki gibi "txt" uzantılı olarak kaydedilmiştir.




Şekil 2.26. (a) "arff" uzantılı dosyanın Notepad ++'da düzenlendikten sonra elde edilen (b) "txt" uzantılı dosyalara ait ekran görüntüsü

Yine her uydu görüntüsü için ayrı ayrı olmak kaydıyla elde edilen sonuç dosyası ve ilgili "test.shp" dosyası ArcMap programında açılmıştır. "Test.shp" ve sonuç dosyası tabloları ArcMap'te birleştirilmiştir (Şekil 2.27).



Şekil 2.27. ArcMap'te birleştirmeye ait ekran görüntüsü


Böylece elde edilen sınıflandırma birleştirilerek hem doğruluk analizi için şekil dosyası hazırlanmış hem de elde edilen sınıflandırmaya ait görsel elde edilerek gözle kontrol edilmiştir (Şekil 2.28).



Şekil 2.28. (1) Göktürk-2, (2) Landsat-8 ve (3) Worlldview-2 uydularının (a) DVM ve (b) ROR sınıflandırmalarına ait görsellerin ekran görüntüsü

2.6.6. Doğruluk analizi

Son aşamada ise kontrol noktalarının oluşturulması ve doğruluk analizi safhası gerçekleştirilmiştir (Şekil 2.29).



Şekil 2.29. (a) Göktürk-2, (b) Landsat-8 ve (c) Worldview-2 uydularına ait kontrol noktalarının ekran görüntüsü

İki sınıflandırma için kaç kontrol noktasına gerek olduğu "İki Terimli Olasılık Teorisine" göre bulunmuştur [91, 92]. Bu teoriye göre;

$$N = Z^2 \cdot p \cdot q / E^2 \quad (2.20)$$

$Z = 2$ (standart normal sapmada genellenmiş değer)

$p = 85$ (istenilen doğruluk oranı)

$q = 100 - p = 15$

$E = 4$ (kabul edilebilir hata)


Formül belirlenen bu değerlere göre tekrar yazılırsa;

$$N = 2^2 \cdot (85 \cdot 15) / 4^2$$

$$N = 319$$


Yapılan bu işlem sonucu %85 doğruluk beklentisi ve %4 kabul edilebilir hata ile güvenilebilir doğruluk için en az 319 kontrol noktasına ihtiyaç vardır. Çalışmada 350 adet kontrol noktası kullanılmıştır. ArcMap programında Adrasan bölgesindeki yangın alanı etrafında şekil dosyası oluşturulmuştur. Bu oluşturulan şekil dosyasına yine ArcMap programından rastgele 250 adet kontrol noktaları atılmıştır. Geri kalan 100 kontrol noktası ise bölgeye rastgele atılmıştır. Böylelikle yapılan sınıflandırmanın doğruluk analizinin güvenilirliğinin artırılması istenmiştir. Test.shp ve sonuç verileri (DVM ve

ROR) ArcMap'te birleştirilmiş ve daha sonra “Feature to raster” işlemi uygulanmıştır (Şekil 2.30).




Şekil 2.30. ArcMap “Feature to raster” özelliğine ait ekran görüntüsü

Daha sonra elde edilen kontrol noktaları ArcMap'te “Extract values to points” yapılarak raster görüntü elde edilmiştir (Şekil 2.31).




Şekil 2.31. ArcMap “Extract values to points” özelliğine ait ekran görüntüsü

Ardından ArcMap programında “Frequency” işlemi uygulanarak kontrol noktalarına karşılık gelen sınıflandırma verileri hesaplanmıştır (Şekil 2.32).



Şekil 2.32. ArcMap “Frequency” özelliğine ait ekran görüntüsü

Yine ArcMap programında “Pivot table” işlemi uygulanarak her iki sınıflandırma için hata matrisleri oluşturulmuştur (Şekil 2.33).



Şekil 2.33. ArcMap “Pivot table” özelliğine ait ekran görüntüsü

Son olarak elde edilen hata matrisleri kullanılarak kullanıcı, üretici, toplam doğruluk, komisyon ve ihmal hataları ve Kappa analizleri yapılmıştır. Elde edilen sonuçlar Tablo 2.7. deki gibidir.

Tablo 2.7. Doğruluk analizi sonuçları

Uydunun Adı	Sınıflandırma Yöntemi	Kullanıcı Doğruluğu	Üretici Doğruluğu	İhmal Hataları	Komisyon Hataları	Kappa	Toplam Doğruluk
Göktürk-2	DVM	86,93	78,70	11,83	13,07	0,68	0,84
	ROR	79,08	79,83	20,92	20,92	0,63	0,82
Landsat-8	DVM	75,46	89,78	29,20	24,54	0,69	0,85
	ROR	76,07	89,21	28,06	23,93	0,69	0,85
Worldview-2	DVM	93,38	94,63	6,71	6,62	0,90	0,95
	ROR	86,75	97,76	14,93	13,25	0,86	0,93

3. SONUÇ, TARTIŞMA VE ÖNERİLER

3.1. Sonuç

Uzaktan algılanmış görüntülerin sınıflandırılmasında karşılaşılan problemler yüksek konumsal çözünürlüğe sahip uydu görüntüleri ile birlikte daha zorlayıcı bir hal almıştır [93]. Konumsal çözünürlüğün artması yanmış alanları temsil eden ve spektral olarak benzer davranış gösteren pikselleri içeren veri kümelerini ortaya çıkarmıştır. Bu kümeleri ayrı ayrı sınıflandırmak yerine nesne tabanlı sınıflandırma işlemleri kullanılarak yapılan sınıflandırmanın hem doğruluğu arttırılmış hem de işlem süreci kısaltılmıştır. Ayrıca sınıflandırma işlemlerinde Destek Vektör Makineleri ve Rotasyon Orman gibi ileri tekniklerinin uygulanmasıyla birlikte veri madenciliğinin kullanımı da uzaktan algılamada kullanılan yöntemler arasında yerini almıştır. Böylelikle daha kısa sürede daha doğru bir sınıflandırılma elde edilmektedir.

Çalışma sonuçları analiz edildiğinde, yanmış alanların tamamına yakınının otomatik olarak çıkartıldığı görülmüştür. Hem DVM hem de ROR' da elde edilen doğruluk analizleri göstermektedir ki her iki sınıflandırma da yanmış alanların çıkartılması için uygun yöntemlerdir. Elde edilen sınıflandırmanın güvenilirliğine yönelik yapılan doğruluk analizlerine ait sonuçlar Tablo 2.7. deki gibidir. Bu iki sınıflandırılma karşılaştırıldığında DVM'in ROR'ya göre daha başarılı olduğu görülmektedir. Ayrıca bu tür çalışmalar için her üç uydunun da uygun olduğu sonucuna varılmıştır.

3.2. Tartışma

Sınıflandırma sonucu elde edilen görüntüler incelendiğinde 2016 yılındaki yanan alanlar dışındaki bölgelerinde yanmış alan olarak sınıflandırıldığı görülmüştür. Yanlış sınıflandırılan alanların bazılarının eski tarihli yanmış alan olduğu düşünülmektedir. Çalışmanın amacının 2016 yılı Haziran ayında meydana gelen yangın alanını çıkartmak olduğu için eski tarihli yanmış alanlar yanlış sınıflandırılmış olarak kabul edilmiştir. Gerçekte yanmış olmasına rağmen yani doğru sınıflandırılmış veri istediğimiz alan dışında olduğu için hatalı kabul edilmiştir. Bu da çalışmanın doğruluk değerini düşürmüştür.

Çalışmada NBR gibi bu tarz araştırmalarda çok yaygın olarak kullanılan indis kullanılamamıştır. Bunun sebebi belirlenen indislerin her üç uydu için kullanılabilir olmasının istenmesidir. Uydu performanslarının karşılaştırılmasının istenmediği başka bir çalışmada daha etkin sonuçların alınabileceği NBR gibi farklı indisler belirlenebilir

(her uydu için ayrı). Böylelikle her uydu için daha etkin bir sınıflandırma sonucu elde edilebilir.

3.3. Öneriler

Elde edilen sonuçlar göstermiştir ki milli uydumuz olan Göktürk-2'nin bu tarz çalışmalarda iyi sonuçlar verme yeteneğine sahiptir. Fakat literatür araştırıldığında Göktürk-2'nin bu tarz çalışmalarda çok az sayıda kullanıldığı tespit edilmiştir.

Göktürk-2 uydusunun uzaktan algılama üzerine yapılan çalışmalarda kullanılabilirliğinin artırılması daha sonra fırlatılması planlanan milli uyduların sadece askeri ihtiyaçlara göre değil sivil ihtiyaçlara da karşılık veren şekilde tasarlanması sağlanabilir.

Ayrıca Göktürk-2 ve Worldview-2 uyduları için NBR indisi ile ilgili çalışmalar yapılması yanlış alanın bu uydular tarafından uzaktan algılanmış görüntülerinde tespit edilmesi işleminde başarılı sonuçlar vereceği düşünülmektedir.

KAYNAKÇA

- [1] Kramer, H.J., 2002, *Observation of the Earth and its Environment: Survey of Missions and Sensors*. 2002: Springer Science & Business Media.
- [2] Foody, G.M. ve Mathur, A., 2004, *A relative evaluation of multiclass image classification by support vector machines*. IEEE Transactions on geoscience and remote sensing, 2004. **42**(6): p. 1335-1343.
- [3] Anthony, G., Greg, H. ve Tshilidzi, M., 2007, *Classification of images using support vector machines*. arXiv preprint arXiv:0709.3967, 2007.
- [4] Mather, P.M., 1987, *Computer processing of remotely-sensed images—An introduction*. 1987.
- [5] Foody, G.M. ve Mathur, A., 2004, *Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification*. Remote Sensing of Environment, 2004. **93**(1-2): p. 107-117.
- [6] Tu, T.-M., vd. , 2001, *A new look at IHS-like image fusion methods*. Information fusion, 2001. **2**(3): p. 177-186.
- [7] Schowengerdt, R.A., 2006, *Remote sensing: models and methods for image processing*. 2006: Elsevier.
- [8] Cho, M.A. ve Skidmore, A.K., 2006, *A new technique for extracting the red edge position from hyperspectral data: The linear extrapolation method*. Remote sensing of environment, 2006. **101**(2): p. 181-193.
- [9] Huang, C., Davis, L.S. ve Townshend, J.R.G., 2002, *An assessment of support vector machines for land cover classification*. International Journal of Remote Sensing, 2002. **23**(4): p. 725-749.
- [10] Rodriguez, J.J., Kuncheva, L.I. ve Alonso, C.J., 2006, *Rotation forest: A new classifier ensemble method*. IEEE transactions on pattern analysis and machine intelligence, 2006. **28**(10): p. 1619-1630.

- [11] Liu, K.-H. ve Huang, D.-S., 2008, *Cancer classification using rotation forest*. Computers in biology and medicine, 2008. **38**(5): p. 601-610.
- [12] Guo, Y., Jia, X. ve Paull, D., 2018, *Effective Sequential Classifier Training for SVM-Based Multitemporal Remote Sensing Image Classification*. IEEE Transactions on Image Processing, 2018.
- [13] Corinna, C. ve Vladimir, V., 1995, *Support-Vector Networks*. Machine Learning, 20, 273-297 (1995) 1995 Kluwer Academic Publishers, Boston. Manufactured in The Netherlands.
- [14] Joachims, T., 1998. *Text categorization with support vector machines: Learning with many relevant features*. in *European conference on machine learning*. 1998. Springer.
- [15] Jimenez-Munoz, J.C., vd. , 2009, *Comparison Between Fractional Vegetation Cover Retrievals from Vegetation Indices and Spectral Mixture Analysis: Case Study of PROBA/CHRIS Data Over an Agricultural Area*. Sensors (Basel), 2009. **9**(2): p. 768-93.
- [16] Myint, S.W., vd. , 2011, *Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery*. Remote sensing of environment, 2011. **115**(5): p. 1145-1161.
- [17] Gürçan, İ., Teke, M. ve Leloğlu, U.M., 2016, *Göktürk-2 Uydu için Arazi Sınıflandırması Land use/Land cover Classification for Göktürk-2 Satellite Signal Processing and Communication Application Conference (SIU)*, 2016 24th, 2016.
- [18] Mashao, D.J., 2003. *Comparing SVM and GMM on parametric feature-sets*. in *Proceedings of the 14th Annual Symposium of the Pattern Recognition Association of South Africa*. 2003. Citeseer.
- [19] Liu, P., vd. , 2017, *SVM or deep learning? A comparative study on remote sensing image classification*. Soft Computing, 2017. **21**(23): p. 7053-7065.
- [20] Breiman, L., 1998, *Arcing classifier (with discussion and a rejoinder by the author)*. The annals of statistics, 1998. **26**(3): p. 801-849.

- [21] Breiman, L., 1996, *Bagging predictors*. Machine learning, 1996. **24**(2): p. 123-140.
- [22] Breiman, L., 2001, *Random forests*. Machine learning, 2001. **45**(1): p. 5-32.
- [23] Bauer, E. ve Kohavi, R., 1999, *An empirical comparison of voting classification algorithms: Bagging, boosting, and variants*. Machine learning, 1999. **36**(1-2): p. 105-139.
- [24] Kuncheva, L.I. ve Rodríguez, J.J., 2007. *An experimental study on rotation forest ensembles*. in *International workshop on multiple classifier systems*. 2007. Springer.
- [25] Ling, F., vd. , 2015, *Burned-area mapping at the subpixel scale with MODIS images*. IEEE Geoscience and Remote Sensing Letters, 2015. **12**(9): p. 1963-1967.
- [26] Kauth, R.J. ve Thomas, G., 1976. *The tasselled cap--a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat*. in *LARS Symposia*. 1976.
- [27] Tucker, C.J., 1979, *Red and photographic infrared linear combinations for monitoring vegetation*. Remote Sensing of Environment, 1979. **8**(2): p. 127-150.
- [28] Trigg, S. ve Flasse, S., 2001, *An evaluation of different bi-spectral spaces for discriminating burned shrub-savannah*. International Journal of Remote Sensing, 2001. **22**(13): p. 2641-2647.
- [29] Pal, M. ve Mather, P.M., 2005, *Support vector machines for classification in remote sensing*. International Journal of Remote Sensing, 2005. **26**(5): p. 1007-1011.
- [30] Stow, D., Niphadkar, M. ve Kaiser, J., 2005, *MODIS-derived visible atmospherically resistant index for monitoring chaparral moisture content*. International Journal of Remote Sensing, 2005. **26**(17): p. 3867-3873.

- [31] Smith, A.M.S., vd. , 2007, *Production of Landsat ETM+ reference imagery of burned areas within Southern African savannahs: comparison of methods and application to MODIS*. International Journal of Remote Sensing, 2007. **28**(12): p. 2753-2775.
- [32] Oruç, M., Marangoz, A. ve Karakış, S., 2007, *Pan-Sharp Landsat 7 Etm+ Görüntüsü Kullanılarak Piksel-Tabanlı Ve Nesne-Tabanlı Sınıflandırma Yaklaşımlarının Karşılaştırılması, 11. Türkiye Harita Bilimsel ve Teknik Kurultayı, ODTÜ, Ankara, 2007: p. 02-06.*
- [33] Lang, S., 2008, *Object-based image analysis for remote sensing applications: modeling reality–dealing with complexity*, in *Object-based image analysis*. 2008, Springer. p. 3-27.
- [34] Bayburt, S., 2009, *Uydu Görüntülerinin Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması (Doğu Trakya bölgesi örneği)*. 2009, Fen Bilimleri Enstitüsü.
- [35] Çölkesen, İ., 2009, *Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi*. GYTE Mühendislik ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Gebze, 2009.
- [36] Dener, M., Dörterler, M. ve Orman, A., 2009, *Açık Kaynak Kodlu Veri Madenciliği Programları: Weka’da Örnek Uygulama*. Akademik Bilişim, 2009. **9**: p. 11-13.
- [37] Kavzoğlu, T. ve Çölkesen, İ., 2010, *Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması*. Harita Teknolojileri Elektronik Dergisi, 2010. **2**(1): p. 36-45.
- [38] Kalkan, K. ve Maktav, D., 2010, *Nesne Tabanlı Ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (Ikonos Örneği)*. 2010.
- [39] Blaschke, T., 2010, *Object based image analysis for remote sensing*. ISPRS journal of photogrammetry and remote sensing, 2010. **65**(1): p. 2-16.

- [40] Bhaskaran, S., Paramananda, S. ve Ramnarayan, M., 2010, *Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data*. Applied Geography, 2010. **30**(4): p. 650-665.
- [41] Akar, Ö., Güngör, O. ve Akar, A., 2010, *Rastgele Orman Sınıflandırıcısı İle Arazi Kullanım Alanlarının Belirlenmesi*. III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 2010.
- [42] Coşkun, C. ve Baykal, A., 2011, *Veri Madenciliğinde Sınıflandırma Algoritmalarının Bir Örnek Üzerinde Karşılaştırılması*. Akademik Bilişim, Malatya, 2011: p. 51-58.
- [43] Kotsiantis, S., 2011, *Combining bagging, boosting, rotation forest and random subspace methods*. Artificial Intelligence Review, 2011. **35**(3): p. 223-240.
- [44] Tekerek, A., 2011, *Veri Madenciliği Süreçleri ve Açık Kaynak Kodlu Veri Madenciliği Araçları*. Akademik Bilişim'11 - XIII. Akademik Bilişim Konferansı Bildirileri, 2011.
- [45] Erener, A. ve Sarp, G., *Mekânsal Çözünürlüğün ve Görüntü Homojenleştirmesinin Sınıflandırma Doğruluğuna Etkisi*.
- [46] Xia, J., vd. , 2014, *Hyperspectral remote sensing image classification based on rotation forest*. IEEE Geoscience and Remote Sensing Letters, 2014. **11**(1): p. 239-243.
- [47] Küpcü, R., Teke, M. ve Çabuk, A., 2014, *Rasat Ve Göktürk-2 Görüntülerinin Ortorektifikasyon Başarımına Referans Ve Sayısal Yükseklik Modeli Seçiminin Etkisi*. 5. Uzaktan Algılama-Cbs Sempozyumu (UZAL-CBS 2014), 14-17 Ekim 2014, İstanbul, 2014.
- [48] Belgiu, M. ve Drăguț, L., 2014, *Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery*. ISPRS Journal of Photogrammetry and Remote Sensing, 2014. **96**: p. 67-75.

- [49] Kugu, E. ve Kisa, A., 2014. *Forest fire damage assessment using Object Based Image Analysis*. in *Signal Processing and Communications Applications Conference (SIU), 2014 22nd*. 2014. IEEE.
- [50] Bağdatlı, M.C., vd. , 2016, *Görüntü Sınıflandırması Yoluyla Göktürk-2 Görüntüsünden Tarımsal Ürün Deseninin Belirlenmesi: Nevşehir-Sarıhıdır Köyü Kızılırmak Sağ Sahil Bandı Tarım Arazileri Pilot Uygulaması*. 6. UZAKTAN ALGILAMA-CBS SEMPOZYUMU (UZAL-CBS 2016), 5-7 Ekim 2016, Adana, 2016.
- [51] Ergüç, N.D., vd. , 2016, *Landsat Çok-Bantlı Uydu Görüntü Verisinin Veri Madenciliği Yöntemleri Kullanılarak Sınıflandırılması*. 6. UZAKTAN ALGILAMA-CBS SEMPOZYUMU (UZAL-CBS 2016), 2016.
- [52] Teke, M. ve Yardımcı, Y., 2016, *Göktürk-2 Zaman Serisi Görüntüleri ile Ürün Sınıflandırma Crop Classification with Göktürk-2 Time Series Imagery*. Signal Processing and Communication Application Conference (SIU) 2016, 2016.
- [53] Akar, Ö., 2017, *The Rotation Forest algorithm and object-based classification method for land use mapping through UAV images*. Geocarto International, 2017: p. 1-16.
- [54] Özdemir, M., 2017, *Görüntü Keskinleştirme Yöntemlerinin Nesne-Yönelimli Sınıflandırma Açısından Değerlendirilmesi*. Harita Dergisi 2017. **Sayı 158**.
- [55] Çömert, R., vd. , *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*.
- [56] Başak, H. ve Yıldırım, M.A., 2017, *Göktürk-2 Uydu Görüntüsünün Otomatik Detay Çıkarımında Kullanılabilirliğinin Araştırılması "Eskişehir İli Örneği"*. TMMOB Harita ve Kadastro Mühendisleri Odası, 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, 3-6 Mayıs 2017, Ankara., 2017.
- [57] Erdem, F., vd. , 2018, *Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği*. Journal of Geomatics, 2018. **3(2)**: p. 74-81.

- [58] Hong, H., vd. , 2018, *Landslide susceptibility mapping using J48 Decision Tree with AdaBoost, Bagging and Rotation Forest ensembles in the Guangchang area (China)*. CATENA, 2018. **163**: p. 399-413.
- [59] Maxwell, A.E., Warner, T.A. ve Fang, F., 2018, *Implementation of machine-learning classification in remote sensing: an applied review*. International Journal of Remote Sensing, 2018. **39**(9): p. 2784-2817.
- [60] Qian, Y., vd. , 2014, *Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery*. Remote Sensing, 2014. **7**(1): p. 153-168.
- [61] Desclée, B., Bogaert, P. ve Defourny, P., 2006, *Forest change detection by statistical object-based method*. Remote Sensing of Environment, 2006. **102**(1-2): p. 1-11.
- [62] Baatz, M., 2000. *Multi resolution Segmentation: an optimum approach for high quality multi scale image segmentation*. in *Beutrage zum AGIT-Symposium. Salzburg, Heidelberg, 2000*. 2000.
- [63] Sunar, F., 2018, *Digital Görüntü İşleme*. 2018: Anadolu Üniversitesi Yayınları. 174-211.
- [64] Baatz, M., vd. , 2004, *eCognition professional user guide 4*. Definiens Imaging, Munich, 2004.
- [65] Blackburn, G.A., 1998, *Spectral indices for estimating photosynthetic pigment concentrations: A test using senescent tree leaves*. International Journal of Remote Sensing, 1998. **19**(4): p. 657-675.
- [66] Huete, A.R., 1988, *A soil-adjusted vegetation index (SAVI)*. Remote Sensing of Environment, 1988. **25**(3): p. 295-309.
- [67] Pinty, B. ve Verstraete, M., 1992, *GEMI: a non-linear index to monitor global vegetation from satellites*. Vegetatio, 1992. **101**(1): p. 15-20.
- [68] Ashburn, P., 1979, *The vegetative index number and crop identification*. 1979.

- [69] Gitelson, A.A., vd. , 2002, *Novel algorithms for remote estimation of vegetation fraction*. Remote sensing of Environment, 2002. **80**(1): p. 76-87.
- [70] Osuna, E., Freund, R. ve Girosit, F., 1997. *Training support vector machines: an application to face detection*. in *Computer vision and pattern recognition, 1997. Proceedings., 1997 IEEE computer society conference on*. 1997. IEEE.
- [71] Hsu, C.-W., Chang, C.-C. ve Lin, C.J., 2003, *A practical guide to support vector classification*. 2003.
- [72] Graf, A.B. ve Borer, S., 2001. *Normalization in support vector machines*. in *Joint Pattern Recognition Symposium*. 2001. Springer.
- [73] Oommen, T., vd. , 2008, *An objective analysis of support vector machine based classification for remote sensing*. Mathematical geosciences, 2008. **40**(4): p. 409-424.
- [74] Snedecor, G.W., 1967, *Statistical Methods: NY George W. Snedecor and William G. Cochran*. 1967: Iowa State University Press.
- [75] Fitzpatrick-Lins, K., 1981, *Comparison of sampling procedures and data analysis for a land-use and land-cover map*. Photogrammetric Engineering and Remote Sensing, 1981. **47**(3): p. 343-351.
- [76] Yan, G., vd. , 2006, *Comparison of pixel-based and object-oriented image classification approaches—a case study in a coal fire area, Wuda, Inner Mongolia, China*. International Journal of Remote Sensing, 2006. **27**(18): p. 4039-4055.
- [77] Boyacı, D., 2012, *CBS-uzaktan algılama entegrasyonu ve örnek uygulama: Uydu görüntülerinden detay ve otomatik öznelik tespiti*. 2012, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- [78] Lillesand, T., Kiefer, R.W. ve Chipman, J., 2014, *Remote sensing and image interpretation*. 2014: John Wiley & Sons.

- [79] Jensen, J.R., 1996, *Introductory Digital Image Processing: A Remote Sensing Perspective: 3rd (Third) edition*. 1996.
- [80] Landis, J.R. ve Koch, G.G., 1977, *The measurement of observer agreement for categorical data*. biometrics, 1977: p. 159-174.
- [81] Pearson, K., 1900, X. *On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling*. The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 1900. **50**(302): p. 157-175.
- [82] Pearson, K., 1894, *Contributions to the mathematical theory of evolution*. Philosophical Transactions of the Royal Society of London. A, 1894. **185**: p. 71-110.
- [83] Pearson, K., 1895, *Contributions to the mathematical theory of evolution. II. Skew variation in homogeneous material*. Philosophical transactions of the Royal Society of London, 1895. **186**(Part I): p. 343-424.
- [84] Bentler, P.M. ve Bonett, D.G., 1980, *Significance tests and goodness of fit in the analysis of covariance structures*. Psychological bulletin, 1980. **88**(3): p. 588.
- [85] Ryabko, B.Y., Stognienko, V. ve Shokin, Y.I., 2004, *A new test for randomness and its application to some cryptographic problems*. Journal of statistical planning and inference, 2004. **123**(2): p. 365-376.
- [86] Abas, A., Yakar, M. ve Baykan, N., 2015, *Uzaktan algılama sİstemlerİnde görüntü füzyonu*. TUFUAB VIII. Teknik Sempozyumu, 2015.
- [87] Tonbul, H., *Uydu Görüntü Verileri Kullanılarak Orman Yangın Şiddeti Ve Yangın Sonrası Durumun Zamansal Olarak İncelenmesi: Akdeniz Bölgesi Örneđi*. Fen Bilimleri Enstitüsü.
- [88] Loboda, T., O'neal, K. ve Csiszar, I., 2007, *Regionally adaptable dNBR-based algorithm for burned area mapping from MODIS data*. Remote Sensing of Environment, 2007. **109**(4): p. 429-442.

- [89] Roy, D.P., Boschetti, L. ve Trigg, S.N., 2006, *Remote sensing of fire severity: assessing the performance of the normalized burn ratio*. IEEE Geoscience and Remote Sensing Letters, 2006. 3(1): p. 112-116.
- [90] Epting, J., Verbyla, D. ve Sorbel, B., 2005, *Evaluation of remotely sensed indices for assessing burn severity in interior Alaska using Landsat TM and ETM+*. Remote Sensing of Environment, 2005. 96(3-4): p. 328-339.
- [91] Aronoff, S., 1982, *Classification accuracy: a user approach*. Photogrammetric Engineering and Remote Sensing, 1982. 48(8): p. 1299-1307.
- [92] Lucas, I., Frans, J. ve Wel, V., 1994, *Accuracy assessment of satellite derived land cover data: A review*. Photogrammetric Engineering & Remote Sensing, 1994. 60(4): p. 410-432.
- [93] Çölkesen, İ., Yomralıoğlu, T. ve Kavzoğlu, T., 2015, *Obje Tabanlı Sınıflandırmada Bölgeleme Esasına Dayalı Ölçek Parametresi Tespiti: WorldView-2 Uydu Görüntüsü Örneği*. 2015.

İnternet kaynakları:

- http-1 <https://www.ogm.gov.tr/ekutuphane/sayfalar/Istatistikler.aspx> (02.03.2018)
- http-2 <http://www.gisat.cz/content/en/satellite-data/supplied-data/highresolution/satellite/goektuerk-2> (24.05.2018)
- http-3 <https://earthexplorer.usgs.gov/> (02.03.2018)
- http-4 <https://landsat.gsfc.nasa.gov/landsat-8/> (02.03.2018)
- http-5 <https://landsat.gsfc.nasa.gov/landsat-data-continuity-mission/> (25.05.2018)
- http-6 http://www.tdk.gov.tr/index.php?option=com_bts&view=bts (18.04.2018)
- http-7 ftp://jetty.ecn.purdue.edu/jshan/ERDAS_Library (26.04.2018)
- http-8 <https://machinelearningmastery.com/save-machine-learning-model-make-predictions-weka/> (06.07.2018)