

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SENTİNEL-2 VE LANDSAT-8 UYDU GÖRÜNTÜLERİ İLE ARAZİ
ÖRTÜSÜ/KULLANIMI HARİTALARININ KARŞILAŞTIRILMASI

GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

FURKAN GÖKHAN CESUR

MAYIS 2019

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SENTİNEL-2 VE LANDSAT-8 UYDU GÖRÜNTÜLERİ İLE ARAZİ
ÖRTÜSÜ/KULLANIMI HARTILARININ KARŞILAŞTIRILMASI

GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Furkan Gökhan CESUR

DANIŞMAN: Doç. Dr. Saygın ABDİKAN

ZONGULDAK

Mayıs 2019

KABUL:

Furkan Gökhan CESUR tarafından hazırlanan “Sentinel-2 ve Landsat-8 Uydu Görüntüleri ile Arazi Örtüsü/Kullanımı Haritalarının Karşılaştırılması” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalında Yüksek Lisans/Doktora Tezi olarak oybirliğiyle/oyçokluğuyla kabul edilmiştir. 22/05/2019

Danışman: Doç. Dr. Saygın ABDİKAN

Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü



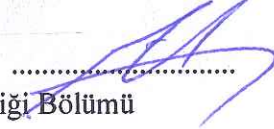
Üye: Dr. Öğr. Üyesi Aycan Murat MARANGOZ

Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü



Üye: Doç. Dr. Ayhan ATEŞOĞLU

Bartın Üniversitesi, Mühendislik Fakültesi, Orman Mühendisliği Bölümü



ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

..../..../20....



Prof. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Furkan Gökhan CESUR



ÖZET

Yüksek Lisans Tezi

SENTİNEL-2 VE LANDSAT-8 UYDU GÖRÜNTÜLERİ İLE ARAZİ ÖRTÜSÜ/KULLANIMI HARİTALARININ OLUŞTURULMASI

Furkan Gökhan CESUR

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Geomatik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Saygın ABDİKAN

Mayıs 2019, 71 sayfa

Arazi örtüsü kullanım verisi, tarım politikalarının, doğal afetlerin ve kentsel planlamanın sürdürülebilir yönetiminde mekansal analizlerin yürütülebilmesi için temel bilgi olarak kullanılmaktadır. Arazilerin güncel bilgisine ulaşmanın en etkin yolu olarak uzaktan algılama son on yılda özellikle veriye hızlı erişim sağlaması açısından dikkat çekmektedir. Yeryüzünün iyi bir şekilde yorumlanabilmesi, problemlere etkin çözüm yollarının üretilmesine veya mevcut durumlarının iyileştirilmesine katkı sağlamaktadır. Arazi örtüsü kullanım haritalarının üretiminde, literatür araştırmaları sonucunda; uydu görüntülerinin sahip olduğu çözünürlük değerlerinin, sınıflandırma aşamasında tercih edilen yöntemlerin ve sınıflandırmaya destek verecek indekslerin etkili olduğu görülmektedir. Bu çalışmada Sentinel-2 ve Landsat-8 uydu görüntüleri kullanılarak üretilen çeşitli bitki indekslerinin görüntü sınıflandırma doğruluğuna olan katkısı araştırılmıştır. Çalışma yapılacak bölge Bakırçay havzası olarak seçilmiştir. 7 adet sınıf seçilerek destek vektör makineleri yöntemi ile sınıflandırma işlemleri yapılmıştır. Sınıflandırma işlemleri piksel tabanlı ve kontrollü sınıflandırma yöntemi ile yürütülmüştür.

ÖZET (devam ediyor)

Uydu görüntülerinin genel doğruluklarının kıyaslanması yanı sıra sınıflandırma işleminde ele alınan 7 ayrı sınıfın da doğruluk değerleri irdelenmiştir.

Anahtar Kelimeler: Arazi kullanım haritası, destek vektör makineleri, bitki indeksi, Sentinel-2, Landsat-8.

Bilim Kodu: 616.02.04



ABSTRACT

M.Sc. Thesis

COMPARISON OF LAND COVER/USAGE MAPS WITH SENTINEL-2 AND LANDSAT-8 SATELLITE IMAGES

Furkan Gökhan CESUR

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Geomatics Engineering**

Thesis Advisor: Assoc. Prof. Dr. Saygın ABDİKAN

May 2019, 71 pages

Land-use data is utilized as the basic information for conducting spatial analysis in the sustainable management of agricultural policies, natural disasters and urban planning. Specifically, in the last decade, remote sensing with quick data access stands out as one of the most effective ways to reach the current information of the land. Good understanding of the earth/land contributes to the production of effective solutions to problems or to the improvement of their current situation. As a result of the literature review in the production of land-use maps; It is seen that the resolution values of the satellite images, the preferred methods during the classification stage and the indices to support the classification are found effective. In this study, the contribution of various plant indices produced by using Sentinel-2 and Landsat-8 satellite images towards image classification accuracy is investigated. The study area was chosen as Bakırçay basin. 7 classes were selected and classified by support vector machines methodology. Classification was carried out with pixel based and controlled classification method. In addition to comparing the general accuracy of satellite images, the accuracy values of 7 different classes discussed in the classification process are examined.

ABSTRACT (continued)

Key words: Land-use map, support vector machines, vegetation index, Sentinel-2, Landsat-8.

Science Code: 616.02.04



TEŐEKKÜR

Yüksek lisans tez danışmalđımı üstlenerek, bu konuda hiçbir yardımını esirgemeyen Tez danışmanım Sayın Doç. Dr. Saygın ABDİKAN'a

Hayatımın her döneminde olduđu gibi Yüksek Lisans Tez yazımı konusunda da beni destekleyen sevgili aileme

Sevgi ve Teşekkürlerimle...



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	v
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xv
BÖLÜM 1 GİRİŞ	1
1.1 LİTERATÜR ÖZETİ	1
1.2 TEZİN AMACI	3
BÖLÜM 2 UZAKTAN ALGILAMANIN TEMELLERİ.....	5
2.1 GÖRÜNTÜ İŞLEME	6
2.2 UYDU SİSTEMLERİ.....	6
2.2.1 Mekansal Çözünürlük	8
2.2.2 Spektral Çözünürlük	8
2.2.3 Radyometrik Çözünürlük.....	9
2.2.4 Zamansal Çözünürlük	10
BÖLÜM 3 YÖNTEM	11
3.1 ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ SINIFLANDIRMA YÖNTEMLERİ ...	11
3.1.1 Destek Vektör Makineleri.....	13
3.1.1.1 Doğrusal Olan Veriler İçin DVM.....	13

3.1.1.2 Doğrusal Olmayan Veriler İçin DVM.....	15
3.2 SINIFLANDIRMA SONUÇLARININ DOĞULUK ANALİZİ.....	18
3.3 BİTKİ İNDEKSLERİ	19
BÖLÜM 4 UYGULAMA	21
4.1 ÇALIŞMA ALANI.....	21
4.2 KULLANILAN VERİLERİ	23
4.2.1 Kullanılan İndeksler.....	25
4.2.2 Eğitim Ve Test Verileri.....	26
4.3 SINIFLANDIRMA VE DOĞRULUK ANALİZLERİ	30
BÖLÜM 5 BULGULAR.....	55
BÖLÜM 6 SONUÇ VE ÖNERİLER.....	63
KAYNAKLAR.....	65
ÖZGEÇMİŞ	71

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Aktif ve pasif algılama sistemi.....	7
Şekil 2.2 Mekansal çözünürlük kavramı. (a) 0,5 metre, (b) 1 metre, (c) 2,5 metre, (d) 5 metre, (e) 10 metre, (f) 20 metre çözünürlüklü görüntüler	8
Şekil 2.3 Bir görüntüye ait 1, 2, 4 ve 8 bitlik çözünürlük farkları	10
Şekil 3.1 Sınıflandırma yöntemleri.	12
Şekil 3.2 Parametrik ve parametrik olmayan sınıflandırma yöntemleri.....	12
Şekil 3.3 Doğrusal olarak ayrılabilen sınıflara ait DVM ve optimum hiperdüzlem.	14
Şekil 3.4 Doğrusal olmayan DVM'na ait optimum hiperdüzlem.	15
Şekil 4.1 İzmir İlinin Türkiye haritası üzerinde ki konumu	22
Şekil 4.2 Çalışma bölgesi.	22
Şekil 4.3 Çalışma bölgesinin doğal renkli Sentinel-2 görüntüsü.	26
Şekil 4.4 Sentinel-2 uydu görüntüsü üzerinden seçilmiş eğitim verileri örneği.	28
Şekil 4.5 Sentinel-2 uydu görüntüsü üzerinden seçilmiş test verileri örneği.	29
Şekil 4.6 Sentinel-2 uydu görüntüsünün 4, 9 ve 11. bantları ile açılmış görüntüsü.....	30
Şekil 4.7 Landsat-8 uydusunun orijinal bantları ile sınıflandırılmış genel görüntü	31
Şekil 4.8 Landsat-8 uydusunun orijinal bantları ile sınıflandırılmış 1/100.000 ölçekli görüntü.....	32
Şekil 4.9 Sentinel-2 uydusunun orijinal bantları ile sınıflandırma işlemi sonucu ortaya çıkan genel görüntü.....	34
Şekil 4.10 Sentinel-2 uydusunun orijinal bantları ile sınıflandırılmış 1/100.000 ölçekli görüntü.....	35
Şekil 4.11 Landsat-8 bantları ve BNDVI indeksi ile yapılan sınıflandırma görüntüsü.	37
Şekil 4.12 Sentinel-2 bantları ve BNDVI indeksi ile yapılan sınıflandırma görüntüsü.	39
Şekil 4.13 Landsat-8 bantları ve GNDVI indeksi ile yapılan sınıflandırma görüntüsü.	41
Şekil 4.14 Sentinel-2 bantları ve GNDVI indeksi ile yapılan sınıflandırılmış görüntüsü.....	43
Şekil 4.15 Landsat-8 bantları ve NDVI1 indeksi ile yapılan sınıflandırma görüntüsü.	45



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 2.1 Bazı uydulara ait zamansal çözünürlükler.	10
Çizelge 3.1 Kernel türleri ve ifadeleri.	17
Çizelge 3.2 Kernel fonksiyonları parametreleri.	17
Çizelge 4.1 Sentinel-2 uydusuna ait bantlar, çözünürlükler ve dalga boyu değerleri.	23
Çizelge 4.2 Landsat-8 uydusuna ait bantlar, bantlara ait çözünürlükler ve dalga boyları.	24
Çizelge 4.3 Çalışmada tercih edilen, dalga boyu değerleri birbirine yakın bantlar.	25
Çizelge 4.4 Bitki indeksleri ve formülleri.	25
Çizelge 4.5 Eğitim ve test verilerine ait sayısal değerler.	27
Çizelge 4.6 Landsat-8 uydusunun orijinal bantlı sınıflandırma sonucu ortaya çıkan hata matrisi.	33
Çizelge 4.7 Landsat-8 uydusunun orijinal bantları ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	33
Çizelge 4.8 Sentinel-2 uydusunun orijinal bantlarla yapılan sınıflandırma sonucu ortaya çıkan hata matrisi.	36
Çizelge 4.9 Sentinel-2 uydusunun orijinal bantlar ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	36
Çizelge 4.10 Landsat-8 bantları ve BNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.	38
Çizelge 4.11 Landsat-8 uydusunun BNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	38
Çizelge 4.12 Sentinel-2 bantları ve BNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.	40
Çizelge 4.13 Sentinel-2 uydusunun BNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	40
Çizelge 4.14 Landsat-8 bantları ve GNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.	42
Çizelge 4.15 Landsat-8 uydusunun GNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	42
Çizelge 4.16 Sentinel-2 bantları ve GNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.	44
Çizelge 4.17 Sentinel-2 uydusunun GNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.	44
Çizelge 4.18 Landsat-8 bantları ve NDVI indeksi ile yapılan sınıflandırmanın hata matrisi.	46

ÇİZELGELER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Çizelge 4.19 Landsat-8 uydusunun NDVI1 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	46
Çizelge 4.20 Sentinel-2 bantları ve NDVI1 indeksi ile yapılan sınıflandırmanın hata matrisi.....	47
Çizelge 4.21 Sentinel-2 uydusunun NDVI1 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	47
Çizelge 4.22 Landsat-8 bantları ve NDVI2 indeksi ile yapılan sınıflandırmanın hata matrisi.....	48
Çizelge 4.23 Landsat-8 uydusunun NDVI2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	48
Çizelge 4.24 Sentinel-2 bantları ve NDVI2 indeksi ile yapılan sınıflandırmanın hata matrisi.....	49
Çizelge 4.25 Sentinel-2 uydusunun NDVI2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	49
Çizelge 4.26 Sentinel-2 bantları ve NDVIre1 indeksi ile yapılan sınıflandırmanın hata matrisi.....	50
Çizelge 4.27 Sentinel-2 uydusunun NDVIre1 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	50
Çizelge 4.28 Sentinel-2 bantları ve NDVIre2 indeksi ile yapılan sınıflandırmanın hata matrisi.....	51
Çizelge 4.29 Sentinel-2 uydusunun NDVIre2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	51
Çizelge 4.30 Sentinel-2 bantları ve NDVIre3 indeksi ile yapılan sınıflandırmanın hata matrisi.....	52
Çizelge 4.31 Sentinel-2 uydusunun NDVIre3 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.....	52
Çizelge 5.1 İndekslerin genel doğruluklara katkıları.	55
Çizelge 5.2 Genel doğruluk oranları ve indeks katkıları.....	56
Çizelge 5.3 Yerleşim yeri sınıfı için indeks etkileri.....	56
Çizelge 5.4 Mutlak tarım sınıfı için indeks etkileri.....	57
Çizelge 5.5 Dikili alan sınıfı için indeks etkileri.....	58
Çizelge 5.6 Mera sınıfı için indeks etkileri.	58
Çizelge 5.7 Marjinal tarım için indeks etkileri.....	59
Çizelge 5.8 Orman sınıfı için indeks etkileri.....	60
Çizelge 5.9 Su yüzeyi sınıfı için indeks etkileri.....	60

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

w	: Hiperdüzlem normali
b	: Hiperdüzlemin orjinden uzaklığı
x_i	: Hiperdüzlem üzerindeki bir nokta
$f(x)$: x bilinmeyenli fonksiyon
$f(x) = \text{sign}$: Karar fonksiyonu
λ_i, i	: Lagrange çarpanları
ξ_i	: Yapay değişken
C	: Düzenleme parametresi
$K(x, x_i)$: Kernel fonksiyonları
d	: Polinom derecesi
b	: Bias parametresi
γ	: Gamma parametresi
κ	: Kappa
N	: Matrisin içerdiği toplam gözlem sayısı
r	: Hata matrisindeki satır sayısı
x_{ii}	: i satır ve i sütunundaki gözlemlerin sayısı
x_{i+}	: i satırındaki gözlemlerin toplamı
x_{+i}	: i sütunundaki gözlemlerin toplamı

KISALTMALAR

BNDVI	: Blue Normalized Difference Vegetation Index
DVM	: Destek Vektör Makineleri
EÇB	: En Çok Benzerlik
EKU	: En Kısa Uzaklık
ESA	: European Space Agency

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

GNDVI	: Green Normalized Difference Vegetation Index
KA	: Karar Ağaçları
MO	: Maksimum Olabilirlik
NDRE	: Normalized Difference Red Edge
NDVI	: Normalized Difference Vegetation Index
NDVIRE	: Normalized Difference Vegetation Index Red Edge
RO	: Rastgele Orman
YSA	: Yapay Sinir Ağları



BÖLÜM 1

GİRİŞ

1.1 LİTERATÜR ÖZETİ

Yeryüzü üzerinde birçok obje gerek beşeri gerekse doğal sebeplerden dolayı değişimler göstermektedir. Bu değişimlerin gözlenmesi için birçok yöntem geliştirilmiştir. Gelişen teknoloji; insanların daha hızlı ve fiziksel temas olmaksızın gözlem yapma kabiliyetini arttırmıştır [1].

Uzaktan algılama teknolojisi de yeryüzündeki objelerin takibi için kullanılan yöntemlerden biridir. Bu takibin kullanıldığı en önemli alanlardan biri tarımdır. Hızla artan dünya nüfusu karşısında doğal kaynaklarımızın tükenmesi kaçılmaz bir son olarak görülmektedir. Artan nüfus beraberinde beslenme ihtiyacındaki artışı da getirmektedir. Bu yüzden insanların arazi üzerinde, üretim yaptıkları tarım ürünleri ile ilgili istatistiklere ihtiyacı vardır. Bu teknolojiyle beraber arazinin tematik haritaları üretilmekte ve kıyaslamalar yapılabilmektedir. Söz konusu teknolojinin arazi üzerinde ki objeleri ayırma konusunda ki kabiliyeti daha hassas çalışabilmesi ile ilişkilidir. Uydu görüntülerindeki hassas çalışma kabiliyeti bazı kriterlere bağlıdır. Bunlar; spektral çözünürlük, mekansal çözünürlük, radyometrik çözünürlük ve zamansal çözünürlüktür [2, 3].

Bunların yanında, yapılan çalışmalarla geliştirilen matematiksel formüller ile beraber, oluşturulan tematik haritaların gerçek objelere en yakın sınıflandırma sonuçları vermesi amaçlanmıştır. Tematik harita oluşturma aşamasında birçok farklı yöntem kullanılmakta ve doğruluk değerleri sürekli olarak geliştirilmeye çalışılmaktadır. Sınıflandırma işlemlerinin doğruluğunu arttırmak için, çalışmalara katkı vermesi düşünülen birçok metot denenmiştir. Bunlar; uydu görüntüleri, uyduların bant özellikleri, sınıflandırma doğruluğunu arttırdığı düşünülen indeksler, matematiksel algoritmalara, sınıflandırma verileri vb. etkenlerdir. Sınıflandırma işlemlerinde başlıca iki yaklaşım vardır. Bunlar; kontrollü sınıflandırma ve

kontROLSÜZ sınıflandırmadır. KontROLSÜZ sınıflandırma; kullanıcı etkisi olmaksızın, piksellerin benzer özellik gösteren görüntü üzerindeki objelere atanması prensibiyle çalışmaktadır. Kontrollü sınıflandırma ise; yeryüzünde konumu ve özellikleri bilinen objelerin, sınıflandırma sonrasında test verisi olarak işleme sokulması prensibine dayanmaktadır [4]. Sınıflandırma işlemlerinde, matematiksel formüllerle otomatik olarak ayırma işlemi yapan yöntemler vardır. Bunlara birkaç örnek verilecek olursa; Destek Vektör Makineleri, Maksimum Benzerlik, Paralelkenar Yöntemi, En Kısa Uzaklık Yöntemi bu ifadeye örnek olarak verilebilir. Kavzaoğlu ve Çölkesen (2009), arazinin tematik harita üretilmesiyle ilgili Destek Vektör Makineleri (DVM) ve En Çok Benzerlik (EÇB) sınıflandırma yöntemlerini test etmişlerdir [5]. Dixon ve Candede (2008) arazi üzerinde seçilen sınıflar için tematik harita üretimiyle ilgili Yapay Sinir Ağları (YSA), DVM ve EÇB yöntemlerini LANDSAT TM görüntüsü üzerinde test etmişlerdir [6].

Srivastava vd. (2012), arazi örtüsü sınıflandırma işlemleriyle ilgili DVM, YSA ve EÇB yöntemlerini test etmişlerdir. Bu matematiksel formülleri kullanmak için Landsat TM ve ETM+ uydu görüntülerini kullanmışlardır. Test sonuçlarında ise Lineer Kerneli en iyi sonuçları vermiştir [7]. Petropoulos vd. (2012), sınıflandırma işlemleri için DVM ve YSA metotlarını test etmişlerdir [8]. Bahis geçen çalışmalarda DVM yönteminin üstün sonuçlar vereceği görülmüştür. Bunlar dışında yeryüzü objelerinin görüntü üzerinden daha hassas sınıflandırılması için bazı indeksler tespit edilmiştir. Bunlara örnek verilecek olursa; NDVI, GNDVI, NDVI_{re1}, BNDVI indeksler gösterilebilir. Schuster vd. (2012), tematik harita üretimiyle alakalı olarak DVM yöntemi kullanarak RapidEye uydu görüntüsünün kırmızı kenar bantının sınıflandırmaya olan katkısını araştırmıştır [9].

Eitel vd. (2011), ağaçlarda erken stresin tespiti için RapidEye uydu görüntüsünün kırmızı kenar bantının etkisini araştırmıştır [10]. Löw vd. (2013), RapidEye uydu görüntüsü kullanarak DVM ve Rastgele Orman (RO) yöntemlerini denemişlerdir [11]. Üstüner (2013), çalışmasında RapidEye ve SPOT uydu görüntülerini kullanarak DVM ve EÇB metotlarını kullanmıştır. Özellikle RapidEye uydusunu seçilmesinin en önemli sebebinin kırmızı-kenar bantları olduğundan bahsetmektedir. Çalışmaları sonucunda kırmızı-kenar bantlara sahip olan RapidEye uydu görüntüsünün, SPOT uydu görüntüsünün %14 daha yüksek sınıflandırma doğruluğu verdiğini tespit etmiştir [12]. Delen (2017), RapidEye uydu görüntüsünü nesne tabanlı ve piksel tabanlı sınıflandırma işlemine sokmuştur. Çalışmasının ilk bölümünde uydu görüntülerini indeks eklemeyen halde sınıflandırma işlemine sokmuş ve nesne tabanlı

sınıflandırma ile piksel tabanlı sınıflandırma işlemini karşılaştırmış, nesne tabanlı sınıflandırmadan %1,07 değerinde daha iyi sonuç elde etmiştir. Daha sonra çalışmasına bitki örtüsü indekslerinden NDVI, GNDVI ve NDRE kullanmıştır. İndeks ekleyerek yaptığı çalışmasının sınıflandırma sonuçlarında ise; GNDVI indeksinin en iyi sonucu verdiğini tespit etmiştir [13]. Kalem (2014), Göktürk-2, Spot-5 ve Landsat-8 uydu görüntülerini kullanarak sınıflandırma işlemi yapmıştır. İşlemler sonrasında Landsat-8 uydu görüntüsüyle yapılan sınıflandırmanın doğruluk değerinin daha yüksek olduğu tespit edilmiştir. Landsat-8 uydusunun yüksek doğrulukta sonuç vermesi, daha çok bant bilgisine sahip olduğunda ilişkilendirilmiştir [14]. Narin vd. (2018), çalışmalarında Sentinel-2A uydu görüntüsü üzerinden sınıflandırma işlemleri yapılmıştır. İşlemler sırasında maksimum olabilirlik (MO), DVM ve YSA metotları denenmiştir. Bu işlemler kıyaslandığında ise en iyi sonucu YSA ağırları vermiştir [15].

1.2 TEZİN AMACI

Çalışma bölgesinde yapılacak olan sınıflandırma işlemi için literatürde daha yüksek doğrulukta sonuçlar verdiğinden bahsedilen yöntemler denenmiştir. Landsat-8 ve Sentinel-2 uydu görüntüleri kullanılmıştır. Uydu görüntülerinin sınıflandırılması için piksel tabanlı kontrollü sınıflandırma işlemi yapılmış, sınıflandırma metodu için, katkısının daha yüksek olacağı tahmin edilen DVM yöntemi tercih edilmiştir. Sınıflandırma işlemi sonrasında; Landsat-8 ve Sentinel-2 uydu görüntülerinin her ikisi içinde sınıflandırma genel doğrulukları belirlenmiştir. Genel doğruluğun ve seçilen sınıfların doğruluğunun artması için bazı yöntemler kullanılmıştır. Bitki türlerinde daha hassas sonuçlar veren normalize edilmiş fark bitki indeksleri ve kırmızı kenar indeksleri kullanılmıştır. İndekslerin etkileri genel doğruluklarla ve sınıf bazında doğruluklarla değerlendirilmiştir. Çalışma öncesinde yapılan araştırmalar sonucunda, kırmızı kenar bantlarının, çalışmada kullanılan uyduların orijinal bantlarının doğruluklarından daha iyi sonuç vermesi amaçlanmıştır. Genel doğruluğun düşmesi durumlarında ise; özellikle kırmızı kenar bantlarının sınıf bazında, hangi sınıfa olumlu katkı yaptığı araştırılmış, bitki türleri üzerindeki olumlu sonuçları irdelenmiştir

Bu tez çalışmasında hipotez aşağıdaki maddeler şeklinde kurulmuştur;

Sentinel-2 ve Landsat-8 uydu görüntüleri DVM sınıflandırma yöntemi kullanılarak arazi kullanımını ile ilgili uygulamalarda kullanılabilir ve tatminkâr sonuçlar sunabilir.

Kullanılan orjinal bantlar ile birlikte eklenen bitki indeksleri arasındaki korelasyon ile ilişkili olarak sınıflandırma doğruluğu her zaman artmayabilir.

Sentinel-2 uydusuna ait Kırmızı-kenar bantları ile oluşturulan bitki indeksleri sınıflandırma doğruluğunu artırabilir.



BÖLÜM 2

UZAKTAN ALGILAMANIN TEMELLERİ

Her toplum sürekli bir deęişim içerisinde ve farklı ihtiyaçlarla karşı karşıya bulunmaktadır. Tüm bu ihtiyaçlara ve deęişimlere baęlı olarak bunların çözümünde birçok farklı meslek çalışmalar yürütmektedir. Her ne kadar mesleklerin yöntemleri ve ana temaları birbirlerinden farklı olsa da, elde edilen tüm sonuçlar, insanlığın ihtiyaçlarının karşılanması için birbirleriyle baęlantılı olarak deęerlendirilmekte ve sonuca kavuşturulmaktadır. Yeryüzündeki deęişimlerin incelenmesi, bu deęişimlere baęlı olarak gerekli tedbirlerin alınması ve iyileştirilmelerin yapılabilmesi için daha geniş bir perspektif bakış açısı saęlayan en etkili yöntemlerden biride uzaktan algılama yöntemidir. Uzaktan algılama yöntemi tüm bu sorunlara sunduęu eşsiz çözümlerle en çok tercih edilen metot olarak karşımıza çıkmaktadır.

Uzaktan algılama yeryüzünden belli uzaklıkta olan platformlara yerleştirilmiş ölçüm aletleri yardımıyla, yeryüzünde bulunan nesnelere hakkında bilgi sahibi olma sanatıdır. Uzaktan algılama teknolojisi keşfedildięi zamanlar sadece askeri amaçla kullanılmaktaydı. Zamanla insanların ihtiyaçlarına cevap verecek şekilde konfigüre edilerek çeşitli amaçlar kapsamında kullanılmaya başlandı.

Uzaktan algılama teknolojisi; yeryüzünde ki doğal kaynakların azalması, insan nüfusunun artması, doğal felaketler ve yeni yerleşim yerlerinin incelenmesi için son derece hızlı ve etkin bir planlama yapılmasına olanak saęlamaktadır.

Uzaktan algılamanın yararlarını özetlemek gerekirse:

- Tarım yapılan bölgelerde, tarım ürünlerinin gelişiminin, üretim alanının ve zamanla deęişiminin incelenmesini saęlar
- Meteorolojik verilerle hava durumu tahmini saęlar
- Dünya üzerindeki ısı dağılımının takibini saęlar
- Nüfusa yönelik yapılan çalışmalarda, şehirleşme ve çarpık kentleşmenin takibini saęlar

- Sayısal arazi modellerin ortaya çıkarılmasını sağlar
- Denizlerde ki kirliliğin incelenmesini ve sürekli hareket halinde olan buzulların gözlemlenmesini sağlar.

2.1 GÖRÜNTÜ İŞLEME

Uzaktan algılama görüntüleri, uydu veya uçaklara takılan algılayıcılardan elde edilmektedir. Elde edilen görüntülerin daha iyi yorumlanması ve çalışmalarda etkin bir biçimde kullanılabilmesi için ilk olarak ön işlemeye tabi tutulur. Elde edilen ilk görüntüler yani ham görüntüler radyometrik ve geometrik hatalar içermektedir. Öncelikle bu hataların düzeltilmesi gerekmektedir. Görüntü işleme ve analiz operasyonları 4 başlık altında toplanabilmektedir.


- Ön işleme
- Görüntü iyileştirme
- Görüntü dönüşümü
- Görüntü sınıflandırma

Ön işleme; uydu görüntüleri üzerindeki verilerde ki bozuklukların giderilmesi için bir takım çalışmalar yapılması olarak tavsif edilmektedir. Bu çalışmalar 2 başlık altında değerlendirilmektedir. Bunlar radyometrik düzeltme ve geometrik düzeltme olarak adlandırılmaktadır. Görüntü iyileştirme; kullanıcının uydu görüntüsü üzerinde yapacağı çalışmaya ait özel durumların kendini daha belirgin hale getirmesi için yani kullanıcının duyu organları ile daha rahat fark edebilmesi için filtreler kullanarak görüntüyü farklı renklerle üretmesidir. Görüntü dönüşümü; Spektral bantlı görüntülerin, çalışmalara ait özellikleri meydana çıkaracak şekilde sınıflandırma aşaması olarak tarif edilebilmektedir [16].

2.2 UYDU SİSTEMLERİ

Uzaktan algılama; yeryüzü hakkında edinilmek istenen bilgilerin, herhangi fiziksel temas olmadan elde edilmesi olarak tarif edilebilmektedir. Bilgileri fiziksel temas olmaksızın elde edebildiğimiz bu sistemlerin 2 adet çalışma normu bulunmaktadır. Bu normlar aktif sistemler ve pasif sistemler olarak 2'ye ayrılmaktadır (Şekil 2.1). Aktif sistemler; çalışmanın yapılacağı bölgeye, sistem üzerinden gönderdiği elektromanyetik dalga sinyallerinin objelere çarparak

meydana getirdiđi enerjiyi algılayarak alıřmaktadır. Pasif sistemler ise; aktif sistemlerin aksine, kendi zerinden elektromanyetik dalga gndermek yerine, gneř ıřınlarından yararlanarak, gneře ıřınlarının objeler zerinden yansımalarını algılayarak alıřma yapmaktadır.




řekil 2.1 Aktif ve pasif algılama sistemi [17].

Uzaktan algılama sistemlerinde diđer bir nemli konuda znrlk kavramıdır. Uzaktan algılama sistemleri ile yapılan alıřmalar ve literatr incelendiđinde znrlk ile ilgili karřımıza birden fazla tanım ıkmaktadır. Tm bu alıřmalar ve literatr incelenip karma ve basit bir tanım yapmak gerekir ise uzaktan algılamada znrlk kavramı iin basite; kullanıcının arařtırma blgesinden elde ettiđi grntlerin zerindeki ayrıntıları fark edebilmesi yani grnt zerindeki nansları ayırt etme kabiliyeti olarak tanımlanabilmektedir. Bir grnty meydana getiren temel tařlar piksellerdir. Grnt oluřması iin iin onlarca, binlerce piksel bir araya gelmektedir. X ve y koordinatları ile tanımlı gridlerin her birine piksel adı verilir [18]. Bu her pikselin kendine ait deđerleri vardır ve bu deđerler yeryzndeki ayrıntıları meydana getirmektedir. Bu ayrıntıların kullanıcıya aktarılmasına ise znrlk denilmektedir. Uzaktan algılamada meknsal, spektral, radyometrik ve zamansal znrlk olmak zere drt farklı znrlk vardır [19].

2.2.1 Mekansal Çözünürlük

Mekansal çözünürlük geometrik olarak ayırt edilebilecek en küçük obje boyutudur. Görüntü piksellerin birleşmesinden oluşmaktadır ve görüntüyü oluşturan her pikselin arazi üzerinde tekil olarak kapladığı alan olarak ifade edilmektedir. Mekansal çözünürlüğün yüksek olması, görüntülerin çözünürlük değeri sayısal olarak daha küçük olması demektir. Örneğin; Şekil 2.2’de aynı çalışma alanına ait görüntüler yer almaktadır. Çözünürlük değeri bir birinden farklı olan bu altı görüntünün çözünürlük değerleri 0,5 metre, ile 20 metre arasında değişmektedir. Mekansal çözünürlüğün tanımından da anlaşılacağı üzere, sayısal değeri küçük olan yani 0,5 metre çözünürlüğü barındıran görüntünün çözünürlüğü daha yüksek olarak karşımıza çıkmaktadır. Çözünürlüğün yüksek olması kullanıcıya daha iyi ayırt etme ve görüntüyü yorumlama gücü katmaktadır [20].



Şekil 2.2 Mekansal çözünürlük kavramı. (a) 0,5 metre, (b) 1 metre, (c) 2,5 metre, (d) 5 metre, (e) 10 metre, (f) 20 metre çözünürlüklü görüntüler [21].


2.2.2 Spektral Çözünürlük

Çalışma bölgesini oluşturan objelerin kendine ait bir takım özellikleri vardır. Bu özelliklerden bazıları yayılma, geçirgenlik ve yansımadır. Uzaktan algılama sistemleri, sayılan bu

özelliklerde ki farklılıkları algılayabilecek şekilde tasarlanmışlardır. Bu özelliklerin tümüne birden spektral çözünürlük denilmektedir. Uydu sistemleri yeryüzü üzerindeki farklı dalga boylarını kaydedebilmektedir. Sistemin kayıt altına alabildiği birbirinden farklı ne kadar dalga boyu var ise spektral çözünürlüğü de buna bağlı olarak doğru orantılı şekilde artmaktadır. Spektral çözünürlük için daha teknik bir tanımlama yapılması gerekir ise de kısaca; spektral çözünürlük, uzaktan algılama sisteminin algılayıcısının elektromanyetik spektrumda kayıt altına alabildiği dalga genişliği ve bant sayısı olarak karışımına çıkmaktadır [22]. Bant genişliği daraldıkça yani daha küçük aralıklarda algılama yapmaya başladıkça çözünürlüğü artmaktadır. Kısaca; spektral çözünürlüğün yüksek olması kayıt altına alınabilen farklı dalga boylarının sayısına, farklı dalga boylarının sistem tarafından fark edilip kayıt altına alınabilmesi de bant genişliğinin dar olmasına bağlı olarak karşımıza çıkmaktadır. Örneğin; $0,08 \mu m$ spektral aralığa sahip bir uzaktan algılama sisteminin spektral çözünürlüğü, $0,10 \mu m$ spektral aralığa sahip bir uzaktan algılama sisteminin çözünürlüğünden daha iyi sonuçlar vermektedir. Bunu dışında spektral çözünürlük tanımında geçen bant sayısı da çözünürlük için ayırt edici bir unsurdur. Örneğin; 7 bant ile algılama yapan Landsat-TM algılayıcısı, 36 bant ile algılama yapan MODIS algılayıcısından daha düşük spektral çözünürlüğe sahiptir [23].

2.2.3 Radyometrik Çözünürlük

Elektromanyetik enerjideki farklılıklar radyometrik çözünürlüğü oluşturmaktadır. Bu farklılıkları algılama yeteneğine radyometrik çözünürlük denilmektedir. Görüntüyü oluşturan her bir pikselin yeryüzünde karşılık geldiği gerçek bir obje vardır. Bu objelerin her biri kendine has elektromanyetik enerji yaymaktadırlar ve bu objelerin yaydığı yaydığı ışığı algılayıcıların kaydetmesiyle radyometrik çözünürlük oluşmaktadır. Bu ışık değeri gri renk değeri olarak kayıt altına alınmaktadır. Bu renk değerine ise bit denilmektedir. Bit değeri ne kadar yüksek olursa radyometrik çözünürlükte o kadar yüksek olmaktadır çünkü görüntüyü oluşturan piksellerin alabileceği renk sayısı ne kadar fazla olur ise mevcut görüntü o kadar gerçeğe yakın hale gelmektedir. Örneğin; 1 bit derinliğe sahip bir görüntü 2 adet renk alabilirken 8 bit renk değerine sahip bir görüntü 256 adet renk alabilmektedir. Şekil 2.3'te dört farklı bit değerine sahip görüntüler yer almaktadır. Bit sayısı 8 olan görüntünün renk çeşitliliği, bit sayısı 1 olan görüntüden çok daha yüksek olarak görülmektedir. Kullanıcı iki görüntü arasındaki farkı bariz olarak algılayabilmektedir. Dolayısıyla bit sayısı yüksek olan görüntüler bit sayısı düşük olan görüntülerden radyometrik çözünürlük olarak daha yüksektir [24].



Şekil 2.3 Bir görüntüye ait 1, 2, 4 ve 8 bitlik çözünürlük farkları [25].

2.2.4 Zamansal Çözünürlük

Zamansal çözünürlük, çalışma için elde edilen görüntülerin zaman periyotları ile ifade edilmektedir. Çalışmanın türüne göre zaman periyotları tercih edilmektedir. Örneğin bir okyanus veya bir deniz kenarındaki su kirliliğinin zamanla takibi için yıllar geçen bir takip gerekmektedir ve ya sadece denizin bir bölgesi üzerinde petrol saçılmalarının tespiti için daha kısa zamanlı periyotlar gerekebilir. Kısacası çalışmanın türüne göre periyotlar gün, ay, yıl veya mevsim gibi seçilmektedir. Bu çalışmaların sağlıklı olabilmesi için optimum zaman periyotları seçilmelidir [26]. Çizelge 2.1’de bazı uydulara ait zamansal çözünürlükler yer almaktadır.

Çizelge 2.1 Bazı uydulara ait zamansal çözünürlükler.

Algılayıcı	Zamansal çözünürlük (gün)
ASTER	16
LANDSAT-5 TM	16
LANDSAT-7 ETM+	16
SPOT-4 HRV	26
SPOT-6 HRG	2-3
RapidEye	1
EOI Hyperion	16

BÖLÜM 3

YÖNTEM

3.1 ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ SINIFLANDIRMA YÖNTEMLERİ

Uzaktan algılama görüntülerinin ham hali üzerinde yorum yapmak oldukça güçtür. Uydu görüntüleri üzerinde yorum yapma kabiliyeti ancak sınıflandırma yaparak mümkün olmaktadır. Sınıflandırma işlemi ikiye ayrılmaktadır. Bunlardan biri nesne tabanlı sınıflandırma diğeri ise piksel tabanlı sınıflandırmadır. Nesne tabanlı sınıflandırmada, sınıflandırma nesnelere üzerinden yapılır ve bu işlem için daha önceden oluşturulan segmentler kullanılır. Bu segmentler ise görüntü üzerinde belirli bir gri değeri arasında kalan bölgeleri temsil eder. Piksel tabanlı sınıflandırma ise tüm pikseller özelliklerine göre otomatik sınıflandırılmaktadır [27].

Piksel tabanlı sınıflandırma işlemi de kontrollü ve kontrolsüz sınıflandırma olarak 2'ye ayrılmaktadır (Şekil 3.1). Kontrollü sınıflandırmada, kullanıcı çalışma yapacağı bölgeye ait görüntü üzerinde sınıfları kendi seçmektedir. Kendinin belirlediği bu sınıflar için daha önceden temin ettiği tematik bilgilerden yardım almaktadır. Tematik haritalar sayesinde arazi üzerinde nerede hangi özellikte obje var bilmektedir. Kontrolsüz sınıflandırma da ise, kontrollü sınıflandırmanın temel yapı taşı olan tematik bilgiler mevcut değildir. Bu sebeple kullanıcı arazi üzerinde nerede hangi özellikte obje var bilememektedir. Buna bağlı olarak kendi sınıflandırma segmentlerine karar verilemeyeceğinden görüntüyü oluşturan pikseller çeşitli fonksiyonlar yardımıyla ve program desteğiyle otomatik olarak sınıflandırılmaktadır [28].


Kontrollü sınıflandırma parametrik olan ve parametrik olmayan yöntemler olarak iki şekilde ele alınmaktadır. Parametrik olan yöntemler ve parametrik olmayan yöntemleri birbirinden ayıran özellik ise verinin istatistiksel dağılımı ile ilgili bilginin elde olup olmadığıdır. İstatistiksel bilginin olmadığı durumlara parametrik olmayan, istatistiksel bilginin olduğu durumlara ise parametrik olan yöntemler denilmektedir [29]. Bir başka tanımla ise parametrik algoritmalar genellikle normal dağılım olmak üzere istatistiksel dağılımın belirli bir sınıfını varsaymaktadır.

Parametrik olmayan algoritmalar is istatistiksel dağılım hakkında varsayım yapmamaktadır. Şekil 3.2’de parametrik ve parametrik olmayan yöntemler gösterilmiştir.



Şekil 3.1 Sınıflandırma yöntemleri.

Parametrik olan sınıflandırma yöntemlerine En Kısa Uzaklık (EKU) ve En Çok Benzerlik (EÇB) yöntemi örnek verilebilmektedir, Karar Ağaçları (KA), Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ise parametrik olmayan sınıflandırma yöntemlerine örnek olarak gösterilebilir [30].



Şekil 3.2 Parametrik ve parametrik olmayan sınıflandırma yöntemleri.

En Çok Benzerlik (EÇB) yönteminde görüntü üzerindeki piksellerin birbirlerinin sınıfına ait olma olasılığı üzerinden işlemektedir. Bu yöntemin uygulanışının kolay olması diğer sınıflandırma yöntemlerine göre daha çok tercih edilmesine sebebiyet vermektedir [31]. Yapay Sinir Ağları (YSA) ve Karar Ağaçları (KA) ise parametrik olmayan yöntemler arasında en pratik olanlar olduğu için çalışmalarda sıkça kullanılmaktadır. YA yönteminde sistem; gelen verili alır, toplar ve kıyaslama işlemi sonucuna göre diğer birimlere gönderir [32]. Parametrik olmayan yöntemler arasında bulunan KA'nın çalışma prensibinde ise, çalışma bölgesinde yapılacak sınıflandırmaya ait kullanıcının elindeki verilerle ağaç oluşturması ve bu verileri ağaca uygulanması yer almaktadır. Uygulamada, karar ağaçları üzerine oluşturulan ve yöntemin tahmin gücünü arttıran kural zincirine bağlı olarak sınıflandırma işlemi yapılmaktadır

[33]. YSA'nın çalışmalarda tercih edilmesinin sebebi ise yapısının parametrik olmayışı ve bunun sayesinde oluşan ağında lineer olmaması olarak yansımaktadır ve bu özellikte problemlere karşı etkin çözüm olanağı sağlamaktadır [34].

3.1.1 Destek Vektör Makineleri

Destek vektör makineleri (DVM) uzaktan algılama çalışmalarında sıkça kullanılan yöntemlerden biridir. DVM yöntemi kontrollü sınıflandırma yöntemleri arasında yer almaktadır [35]. DVM yöntemi, 2 ayrı sınıfa ait verileri birbirinden ayırmak için optimum hiperdüzlem belirlemektedir. Hiperdüzlem olarak bahsedilen bu düzlemin, sınıflar arası sınırının maksimum olması istenir. Yani sınıflara ilişkin en uygun düzlemi bulmalı ve hepsini kapsamalıdır. Bu sınıflandırma yöntemi ilk gün yüzüne çıktığında birbirinden doğrusal olarak ayrılabilen 2 ayrı sınıf üzerinde ayırıştırma yapmaya yönelik çalışmalarda kullanılmıştır. Daha sonradan 2'den fazla sınıfta içinde bulunduğu ve birbirinde doğrusal olarak ayrılamayan sınıflandırma işlemlerinde de kullanılmaya başlanmıştır [36].

3.1.1.1 Doğrusal Olan Veriler İçin DVM

Uzaktan algılama görüntüleri sınıflandırma işlemlerinde etkin rol oynatan destek vektör makineleri yönteminde $\{+1,-1\}$ şeklinde etiketler ile gösterilen sınıfların karar fonksiyonlar ile birbirinden ayrılması amaçlanmaktadır. Bu sınıfları birbirinden ayırabilecek en optimum düzeleme de hiperdüzlem denilmektedir [37].

Hiperdüzlem

$$w \cdot x_i + b = 0 \quad (3.1)$$

olarak ifade edilmektedir.

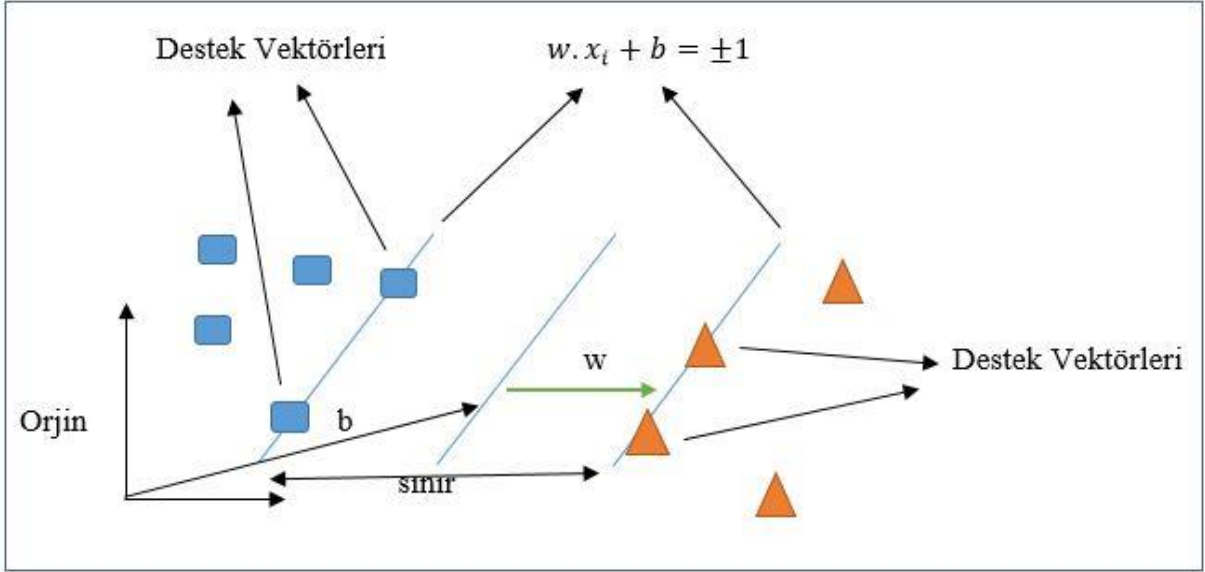
w : Hiperdüzlem normalini

b : Hiperdüzlemin orjinden uzaklığını

x_i : Hiperdüzlem üzerindeki noktayı

İfade etmektedir.

Şekil 3.3'te doğrusal olarak ayrılabilen sınıflara ait DVM ve optimum hiperdüzlem gösterilmektedir.



Şekil 3.3 Doğrusal olarak ayrılabilen sınıflara ait DVM ve optimum hiperdüzlem.

$$w \cdot x_i + b \geq +1, y = +1 \text{ için} \quad (3.1a)$$

$$w \cdot x_i + b \leq -1, y = -1 \text{ için} \quad (3.1b)$$

olarak tanımlanmaktadır.

Bu her iki eşitsizlik bir hale getirildiğinde ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0, y_i \in \{1, -1\} \quad (3.1c)$$

şeklinde ifade edilmektedir.

Tüm formüllerle optimum hiperdüzlem belirlemektedir. Destek vektör makinelerine adını veren destek vektörler sınırı oluşturan elemanlar olarak tarif edilmişlerdir [38].

Bu eşitliklerden yola çıkarak maksimum sınırın belirlenmesi aşamasına geçilmelidir. Sınırların maksimuma çıkarılması için sınır genişliği olan $\|w\|$ ifadesini minimuma getirilmesi gerekmektedir [39].

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (3.1d)$$

Langrange denklemleri kullanılarak çözülen bu problemde ise karşımıza çıkacak fonksiyon;

$$f(x) = \text{sign}(\sum_{i=1}^r \lambda_i \cdot y_i(x \cdot x_i) + b) \quad (3.1e)$$

şeklinde olur. $\lambda_i, i=1,2,3,\dots,r$ Lagrange çarpanlarını oluşturmaktadır.

3.1.1.2 Doğrusal Olmayan Veriler İçin DVM

Elde edilen uydu görüntüleri üzerinde sınıfların karışık olduğu, doğrusal olarak ayıramadığı pek çok veri ile karşılaşmaktadır. Doğrusal olarak ayıramayan bu verilerin sınıflandırılması için yapay olarak üretilen bir değişken eklenmelidir. Doğrusal olmayan DVM’de problemler ile başa çıkabilmek için bir ξ değişkeninin formüllere dahil edilmesi gerekmektedir. Bu ifade lineer olarak ayrılabilen DVM sisteminde ki optimum hiperdüzlem formülleri ile birleştirildiği takdirde;

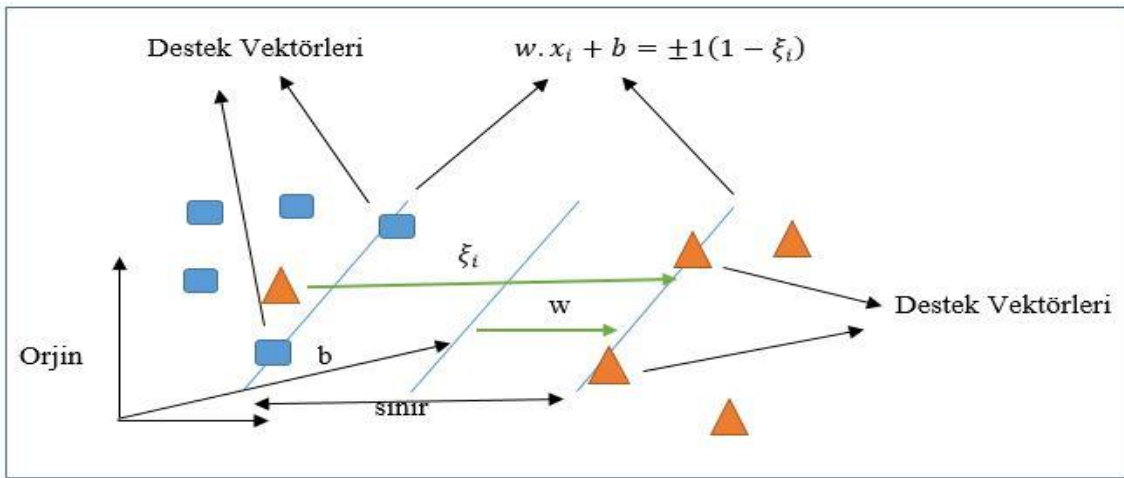
$$w^T x_i + b \geq 1 - \xi_i, y_i = +1 \text{ için} \quad (3.2)$$

$$w^T x_i + b \leq -1 + \xi_i, y_i = -1 \text{ için} \quad (3.2a)$$

$$\xi_i \geq 0, \forall i \quad (3.2b)$$

olarak karşımıza çıkacaktır [37, 40].

Şekil 3.4’te doğrusal olmayan DVM’na ait optimum hiperdüzlem yer almaktadır. Doğrusal olan ve doğrusal olmayan DVM’na ait asıl farkı oluşturan sınıfların doğrusal olarak birbirinden ayıramamasının sebebi olan farklı türlerin birbiri içine karışması ve bunun çözümüne yardım edecek ξ değişkeni gösterilmektedir.



Şekil 3.4 Doğrusal olmayan DVM’na ait optimum hiperdüzlem.

Optimum hiperdüzlem için aşağıdaki ifade kullanılmaktadır;

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (3.2c)$$

Doğrusal olmayan sınıfların birbirinden ayrılıp sınıflandırılması için kernel fonksiyonları devreye sokulmaktadır. Kernel fonksiyonlarının asıl amacı verileri yüksek boyutlu uzayda görüntüleyerek sınıflandırılmasını sağlamaktır. Bu özelliği sayesinde verileri doğrusal olarak ayırabilmektedir [30].

Kernel fonksiyonları genel olarak şu şekilde ifade edilmektedir;

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(y_j) \quad (3.2d)$$

Yukarı yer alan kernel fonksiyonlarının genel ifadesini, doğrusal olarak ayrılabilen DVM karar fonksiyonlarında kullanmak istediğimizde;

$f(x) = \text{sign}(\sum_{i=1}^r \lambda_i \cdot y_i(x \cdot x_i) + b)$ şeklinde ifade edilen doğrusal olarak ayrılabilen DVM formülüne Kernel fonksiyonu (K) eklenmelidir. K eklendiği takdirde karşımıza aşağıdaki gibi bir karar fonksiyonu çıkmaktadır.

$$f(x) = \text{sign}(\sum_{i=1}^r \lambda_i \cdot y_i \cdot K(x, x_i) + b) \quad (3.2e)$$

Sınıflandırma işlemlerinin çözümünde çok sayıda Kernel fonksiyonları kullanılabilir. Kernel fonksiyonlarına; sigmoid kerneller, radyal tabanlı kerneller, polinom kernelleri ve lineer (doğrusal) kerneller, Pearson VII (PUK) kerneli ve normalleştirilmiş poligon kernelleri şeklinde örnekler verilebilir. Çizelge 3.1’de kernel türlerine ait formüller, çizelge 3.2’de ise Kernel fonksiyonlarının parametreleri yer almaktadır [30, 39, 40].

Çizelge 3.1 Kernel türleri ve ifadeleri.

Kernel Türü	Matematiksel İfadesi
Pearson VII (PUK) Kerneli	$\frac{1}{\left[1 + \left(\frac{2 \cdot \sqrt{\ x_i - x_j\ ^2 \sqrt{2^{1/\omega}} - 1}}{\sigma}\right)^\omega\right]}$
Lineer (Doğrusal) Kernel	$\mathbf{K}(x_i, x_j) = x_i \cdot x_j$
Polinom Kerneli	$\mathbf{K}(x_i, x_j) = (\gamma(x_i \cdot x_j) + b)^d, \gamma > 0, \delta > 0$
Normalleştirilmiş Polinom Kerneli	$\mathbf{K}(x_i, x_j) = \frac{((x_i \cdot x_j) + 1)^d}{\sqrt{((x_i^2 + 1)^d)((x_j^2 + 1)^d)}}$
Radyal Tabanlı Kernel	$\mathbf{K}(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
Sigmoid Kerneli	$\mathbf{K}(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) - b), \gamma > 0, \delta > 0$

Çizelge 3.2 Kernel fonksiyonları parametreleri.

Kernel Türü	Parametre
Pearson VII (PUK) Kerneli	Pearson Genişliği Parametreleri (σ, ω)
Lineer (Doğrusal) Kernel	Genel Kernel İfadesi
Polinom Kerneli	Polinom Derecesi (d)
Normalleştirilmiş Polinom Kerneli	Polinom Derecesi (d)
Radyal Tabanlı Kernel	Kernel Boyutu (γ)
Sigmoid Kerneli	Kernel Boyutu (γ)

3.2 SINIFLANDIRMA SONUÇLARININ DOĞULUK ANALİZİ

Hata matrisi yeryüzünde ki objelerin sınıflandırma işlemi sonrasında hangisinin ne kadar doğrulukta istenilen sınıfa atandığını satır ve sütunlar dizini ile tespit edilmesini sağlayan bir yöntemdir. Hata matrislerinde 2 çeşit doğruluk söz konusudur. Bunlar kullanıcı doğruluğu ve üretici doğruluğudur. Ayrıca sınıflandırma işlemlerin anlamlı olup olmadığı ise Kappa değeri ile irdelenmektedir.

Üretici doğruluğu; belli bir sınıfı için, o sınıfa doğru atanmış piksel sayısının yine o sınıfa ait tüm piksellere oranı olarak karşımıza çıkmaktadır [41].

Kullanıcı doğruluğu; belli bir sınıf için, o sınıfa doğru atanmış piksel sayısının yine o sınıfa ait yanlış atanmış piksel sayısı ve doğru atanmış toplam piksel sayısına oranı ile bulunur [41].

Genel doğruluk; tüm sınıflar için doğru atanmış piksel sayısının toplam piksel sayısına bölünmesi ile bulunur [41].

Kappa değeri; sınıflandırma işlemlerinin doğrumu yoksa rastgelemi olduğunu gösterir ve 0 ile 1 arasında değer alır. Kappa değeri formülü aşağıdaki gibidir [41].

$$\kappa = \frac{N \times \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (3.3)$$

Burada;

r = hata matrisindeki satır sayısı

x_{ii} = i satır ve i sütunundaki gözlemlerin sayısı (matrisin çapraz bileşenlerindeki değerler)

x_{i+} = i satırındaki gözlemlerin toplamı (matrisin sağında toplam olarak gösterilir)

x_{+i} = i sütunundaki gözlemlerin toplamı (matrisin altında toplam olarak gösterilir)

N = matrisin içerdiği toplam gözlem sayısı

3.3 BİTKİ İNDEKSLERİ

Bitki örtüsü indeksleri çalışmalarda kullanılan yardımcı elemanlardır. Bitki indeksleri çalışma bölgesinde ki bitkilerin yoğunluğu, cinsi ve sağlıklı olup olmadığı gibi bilgileri yansıtmaktadır. Bitkiler yapısı gereği görünür ışığı yani güneş ışığını soğuran bir yapıya sahiptir. Bununla birlikte yakın kızılötesi ışının bir bölümü de yansıtmaktadır.

Bitki örtüsü indekslerinin çalışmalara olan katkısını bir başka şekilde tanımlayacak olursak; bir bitki hakkında bilgi sahibi olabilmek için kırmızı ve kızılötesi bantlar kullanılmalıdır. Kırmızı ve kızılötesi bantlar kullanıldığında, görüntü üzerinde bitki örtüsünün bulunduğu alanlar gözle görülür bir biçimde karşımıza çıkmaktadır. Kızılötesi bant yeşil bitkileri fark edecek özelliklere sahiptir. Yani bitkiye yeşil rengi veren klorofil pigmenti olduğundan, klorofile karşı hassastır sonucuna ulaşılmaktadır. Kırmızı bant ise kızılötesi banta oranla klorofillere daha az hassastır [42].

Kırmızı-kenar bantının ve yakın kızılötesi bantının genel doğruluğu arttırdığı tespit edilmiştir. Kırmızı kenar bantın sınıflandırma doğruluğuna etkisi %0,7 iken yakın kızılötesi bantın sınıflandırma doğruluğuna etkisi %13,24 olarak tespit edilmiştir. Kırmızı-kenar bantın doğruluk oranına daha yüksek derecede katkı sağlaması beklenirken, düşük kalmasının sebebi eğitim ve test verilerinin seçiminden kaynaklı olduğu tespit edilmiştir [43].

RapiEye uydu görüntüsü üzerinden sınıflandırma işlemleri yapılmış olup, sınıflandırma işlemlerine katkıları denenmek üzere NDVI, GNDVI ve NDRE indeksleri denenmiştir. 3 indeks beraber kullanılarak çalışmanın sınıflandırma yöntemlerinden biri olan DVM ile sınıflandırma işlemlerine katkıları %2,1 olarak tespit edilmiştir [44].



BÖLÜM 4

UYGULAMA

Bu bölümde, çalışma alanı olarak İzmir ili sınırlarında bulunan Bakırçay havzası seçilmiştir. Çalışma alanı sınırlarında bulunan nesnelerin bir kaçının sınıflandırılması yapılmıştır. Sınıflandırma çalışması için kontrollü sınıflandırma yöntemi kullanılmıştır. Çalışma için 7 adet sınıf seçilmiştir. Bunlar yerleşim yeri, mutlak tarım, dikili alan, mera, marjinal tarım, orman ve su yüzeyidir. Sınıflandırma işlemi için 2 adet uydu görüntüsü kullanılmıştır. Bu uydular Landsat-8 ve Sentinel-2 uydularıdır. Sınıflandırma işlemine tabi tutulan görüntülerin genel doğrulukları incelenmiş daha sonra uyduların sahip olduğu bantlara ek olarak literatürde sıkça bahsedilen indekslerden birkaçı ile desteklenerek orijinal bantları ile yapılan sınıflandırma sonuçlarına katkılarının olup olmadığı irdelenmiştir. Genel doğruluklarının yanı sıra daha sonradan sınıf bazında doğruluklar incelenerek çalışmada kullanılan indekslerin sınıflara olan katkıları gözlemlenmiştir.


4.1 ÇALIŞMA ALANI

Çalışma alanı olarak seçilen yer Türkiye'nin İzmir İlinin Bergama İlçesi civarında bulunan Bakırçay havzasıdır. İzmir ili yaklaşık olarak 4.28 milyonluk nüfusa ev sahipliği yapmaktadır. İzmir ili her ne kadar sahil turizmi ile anılsa da, deniz kıyısından içerilere doğru ilerledikçe tarımcılık alanının da aktif rol üstlendiği söylenebilir. İzmir ilinin coğrafi yapısı ve iklim şartları sayesinde tarım için oldukça elverişli bir bölgedir. İzmir Ticaret Odası'ndan edinilen bilgiler ışığında; bölgenin %28,5'nin tarım alanlarından oluştuğu söylenebilir. Toplam 3.444.2374 dekarlık tarım arazilerinin %41,4'ü tarla, %28,3'ü zeytin, %11,22'si sebze, %9,56'sı meyve ve %3,9'u bağ alanlarıdır [45]. Şekil 4.1'de İzmir İlinin Türkiye haritası üzerinde ki konumu yer almaktadır.



Şekil 4.1 İzmir İlinin Türkiye haritası üzerinde ki konumu [46].

Çalışma bölgesi Dikili ve Çandarlı bölgesinden başlayıp yaklaşık olarak Ayaskent ve Karalar bölgesine doğru devam etmektedir. Şekil 4.2’de çalışma bölgesi uydu görüntüsü üzerinden gösterilmiştir.



Şekil 4.2 Çalışma bölgesi.

4.2 KULLANILAN VERİLERİ

Çalışmada yapılan kontrollü sınıflandırma işlemleri ve doğruluk analizleri için Sentinel-2 uydusu ve Landsat-8 uydusunun görüntüleri kullanılmıştır. Sentinel-2 uydusu Avrupa Uzay Ajansı (ESA) tarafından 23 Haziran 2015 yılında fırlatılmıştır. Bu uydu yerde yaklaşık 790 km. yükseklikte yörüngeden görüntü sağlamaktadır. Zamansal çözünürlüğü yüksek olan ve 2-3 gün arasında değişmekte olan bu uydunun göze çarpan en önemli özelliklerinden biride şerit genişliğidir. Sentinel-2 uydusu 290 km. şerit genişliğine sahiptir [47]. Sentinel-2 uydusu mekansal çözünürlükleri 10 ile 60 metre arasında değişen 13 banta sahiptir. Ayrıca kırmızı aralığında üç bant içeren türünün ilk sivil optik uydusudur. Sahip olduğu üç adet kırmızı kenar bantları sayesinde bitki incelemelerine ait çalışmalarda etkin rol oynamaktadır. Sentinel-2 uydusuna ait bantlar, çözünürlükler ve dalga boyu değerleri çizelge 4.1’de yer almaktadır [48].

Çizelge 4.1 Sentinel-2 uydusuna ait bantlar, çözünürlükler ve dalga boyu değerleri.

Sentinel-2 Bantları	Çözünürlük (m)	Dalgaboyu (µm)
Bant 1 - Coastal Aerosol (Kıyı)	60	0,433-0,453
Bant 2 – Blue (Mavi)	10	0,458-0,523
Bant 3 – Green (Yeşil)	10	0,543-0,578
Bant 4 – Red (Kırmızı)	10	0,650-0,680
Bant 5 – Vegetation Red-edge (Kırmızı kenar)	20	0,698-0,173
Bant 6 – Vegetation Red-edge (Kırmızı kenar)	20	0,734-0,748
Bant 7 – Vegetation Red-edge (Kırmızı kenar)	20	0,765-0,785
Bant 8 – NIR (Kızılötesi)	10	0,785-0,900
Bant 8A – Vegetation Red-edge (Kırmızı kenar)	20	0,855-0,875
Bant 9 – Water Vapour (Su buharı)	60	0,930-0,950
Bant 10 – SWIR Cirrus	60	1,365-1,385
Bant 11 – SWIR (Kısa dalga kızılötesi)	20	1,565-1,655
Bant 12 – SWIR (Kısa dalga kızılötesi)	20	2,100-2,280

Çalışmada Sentinel-2 uydusuna ait bantlardan çözünürlüğü 10 ve 20 metre olan; bant2, bant3, bant4, bant5, bant6 ve bant7 kullanılmıştır.

Landsat-8 uydusu ise 11 şubat 2013 yılında fırlatılmış olup, 705 km. irtifada yörüngesine yerleşmiştir. 16 gün gibi bir sürede tüm dünya çevresini tarayabilmektedir. Çözünürlükleri 15

metre ve 100 metre arasında deęişen 11 adet banta sahiptir [49]. Çizelge 4.2’de Landsat-8 uydusuna ait bantlar, bantlara ait çözünürlükler ve dalga boyları yer almaktadır.

Çizelge 4.2 Landsat-8 uydusuna ait bantlar, bantlara ait çözünürlükler ve dalga boyları.

Landsat-8 Bantları	Çözünürlük (m)	Dalgaboyu (µm)
Bant 1 – Coastal (Kıyı/Aerosol)	30	0,43-0,45
Bant 2 – Blue (Mavi)	30	0,45-0,51
Bant 3 – Green (Yeşil)	30	0,53-0,59
Bant 4 – Red (Kırmızı)	30	0,63-0,67
Bant 5 – NIR (Kızılötesi)	30	0,85-0,88
Bant 6 – SWIR 1 (Kısa dalga kızılötesi)	30	1,57-1,65
Bant 7 – SWIR 2 (Kısa dalga kızılötesi)	30	2,11-2,29
Bant 8 – Pan (Pankromatik)	15	0,50-0,68
Bant 9 - Cirrus	30	1,36-1,38
Bant 10 – Tırs 1 (Uzun dalga kızılötesi)	30 (100)	10,6-11,19
Bant 11 – Tırs 2 (Uzun dalga kızılötesi)	30 (100)	11,5-12,51

Çalışma esnasında Landsat-8 ve Sentinel-2 uydusunun tüm bantları kullanılmamıştır. Bant tercihleri yapılırken birbirlerine yakın dalga boyu değerleri arasında olmalarına dikkat edilmiştir. Dalga boyu değerleri dikkate alındığında Landsat-8 uydusunun bant2, bant3, bant4, bant5, bant6 ve bant7’si kullanılırken Sentinel-2 uydusunun ise bant2, bant3, bant4, bant8a, bant11 ve bant12’si kullanılmıştır. Çizelge 4.2’de Çalışmada tercih edilen, dalga boyu değerleri birbirine yakın bantlar yer almaktadır.

Bu çalışmada Sentinel-2 ve Landsat-8 uydusu görüntülerinden üretilen indekslerin sınıflandırma doğruluğuna olan katkıları araştırılarak karşılaştırılması amaçlanmıştır. Çalışmanın başında bu iki uydunun daha önceden belirtilen kriterler aralığında seçtiğimiz bantları ile sınıflandırma yapılmış daha sonrada bu bantlara belirtilen indeksler eklenerek genel doğruluğa ve sınıf bazında doğruluğa katkısı analiz edilmiştir. Çizelge 4.3’te kullanılan bantlar ve değerleri yer almaktadır.

Çizelge 4.3 Çalışmada tercih edilen, dalga boyu değerleri birbirine yakın bantlar.

Sentinel-2	Dalgaboyu (µm)	Landsat-8	Dalgaboyu (µm)
Bant2	0,458-0,523	Bant2	0,45-0,51
Bant3	0,543-0,578	Bant3	0,53-0,59
Bant4	0,650-0,680	Bant4	0,63-0,67
Bant8a	0,855-0,875	Bant5	0,85-0,88
Bant11	1,565-1,655	Bant6	1,57-1,65
Bant12	2,100-2,280	Bant7	2,11-2,29


4.2.1 Kullanılan İndeksler

Çalışma yapılacak bölgede uygulanacak kontrollü sınıflandırma işlemi için kullanılacak sınıflar; yerleşim yeri, mutlak tarım, mera, orman, su yüzeyi, marjinal tarım ve dikili alan olmak üzere 7'ye ayrılmaktadır. Yapılacak olan bu çalışmada seçilen orjinal bantlar ile sınıflandırma işlemi yapıp katkısının gözlemlenmesi için kullanılacak indeksler; Sentinel-2 uydusu için NDVI1, NDVI2, BNDVI, GNDVI, NDVIre1, NDVIre2 ve NDVIre3 indeksleridir. Landsat-8 uydusu için kullanılacak indeksler ise NDVI1, NDVI2, BNDVI ve GNDVI'dir. Çizelge 4.4'te literatürde kullanılan bazı bitki indeksleri ve formülleri yer almaktadır.

Çizelge 4.4 Bitki indeksleri ve formülleri.

İNDEKS	SENTINEL-2 FORMÜL	REFERANS	LANDSAT-8 FORMÜL	REFERANS
NDVI1	$\frac{B8a - B4}{B8a + B4}$	Duran (2007)	$\frac{B5 - B4}{B5 + B4}$	
NDVI2	$\frac{B8a - B12}{B8a + B12}$		$\frac{B5 - B7}{B5 + B7}$	
GNDVI	$\frac{B8a - B3}{B8a + B3}$	Gitelson vd. (1996)	$\frac{B5 - B3}{B5 + B3}$	
BNDVI	$\frac{B8a - B2}{B8a + B2}$		$\frac{B5 - B2}{B5 + B2}$	
NDVIre1	$\frac{B8a - B5}{B8a + B5}$	Rouse (1973)		
NDVIre2	$\frac{B8a - B6}{B8a + B6}$			
NDVIre3	$\frac{B8a - B7}{B8a + B7}$			

Şekil 4.3'te çalışma bölgesinin Sentinel-2 uydusunun doğal renkleri ile açılmış görüntüsü yer almaktadır.



Şekil 4.3 Çalışma bölgesinin doğal renkli Sentinel-2 görüntüsü.

Çalışmanın devamında sınıfların fark edilebilmesi için görüntünün daha küçük bir kısmının örnek olarak koyulması tercih edilmiştir.

4.2.2 Eğitim Ve Test Verileri

Kontrollü sınıflandırma işlemlerinin yapılması için kullanıcı tarafından eğitim verileri seçilmiştir. Doğruluk analizinde, 7 sınıf için seçilen eğitim verilerinden bağımsız olarak yine 7 sınıf için test verileri seçilmiştir. Çizelge 4.5'te sınıf bazında seçilen eğitim ve test verilerine ait poligonlar ve bu poligonların içine yerleşmiş olduğu piksel sayıları belirtilmiştir. piksel ve bu


piksellerin içine yerleşmiş olduğu poligon sayıları belirtilmiştir. Çalışmada eğitim verileri için toplam 116 poligon, 4672 piksel kullanılmıştır. Test verileri için ise toplam 148 poligon, 7350 piksel kullanılmıştır.

Çizelge 4.5 Eğitim ve test verilerine ait sayısal değerler.

SINIF	EĞİTİM VERİSİ POLİGON/PIKSEL	TEST VERİSİ POLİGON/PIKSEL
Yerleşim Yeri	7/691	11/1017
Mutlak Tarım	32/1687	44/2667
Dikili Alan	15/295	20/507
Mera	11/347	16/656
Marjinal Tarım	20/532	23/875
Orman	22/735	22/1043
Su Yüzeyi	9/385	12/585
Toplam	116/4672	148/7350


Çalışmada eğitim verileri için toplam 116 poligon, 4672 piksel kullanılmıştır. Test verileri için ise toplam 148 poligon, 7350 piksel kullanılmıştır.

Şekil 4.4'te Sentinel-2 uydu görüntüsü üzerinden, eğitim verisi için seçilmiş birkaç sınıf örneği yer almaktadır.



Şekil 4.4 Sentinel-2 uydu görüntüsü üzerinden seçilmiş eğitim verileri örneği.

Şekil 4.5'te ise Sentinel-2 uydu görüntüsü üzerinden, test verisi için seçilmiş birkaç sınıf örneği yer almaktadır.



Şekil 4.5 Sentinel-2 uydu görüntüsü üzerinden seçilmiş test verileri örneği.

Görüntü üzerinde kırmızı renkli alan yerleşim yeri sınıfı için, sarı renkli alan mutlak tarım sınıfı için, yeşil orman sınıfı için, mavi renkli alan ise su yüzeyi sınıfı için, kahve renkli alanlar ise mera sınıfı seçilmiştir. Sentinel-2 uydu görüntüsünün doğal renkleri ile açılmış bu görüntü üzerinden sınıfların kullanıcı tarafından fark edilmesi oldukça güçtür. Kullanıcının tercihlerinin doğruluğunu arttırmak için uydu görüntüsünün diğer bantları üzerinden tercihler yapılabilmektedir. Böylece sınıfların spektral yansıma değerleri kullanılarak ayırt edilebilirlik sağlanmaktadır. Şekil 4.6'da Sentinel-2 uydusunun 4, 9 ve 11. bantları kullanılarak ayırt edilebilirlik artırılmıştır.



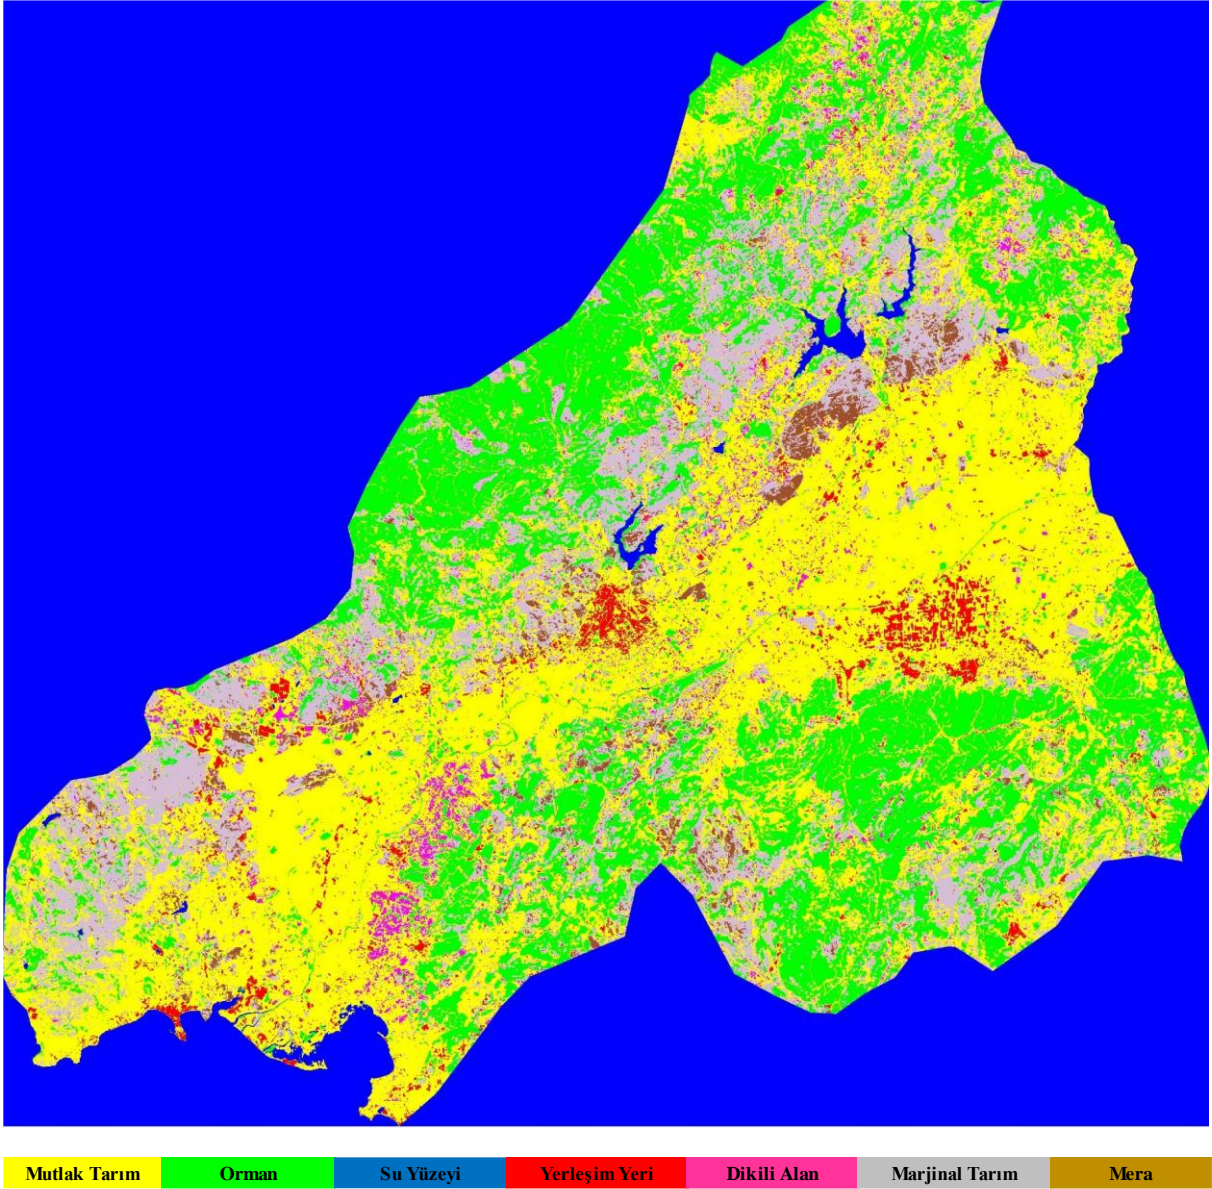
Şekil 4.6 Sentinel-2 uydu görüntüsünün 4, 9 ve 11. bantları ile açılmış görüntüsü.

Şekil 4.6’da sınıflar kendilerini belirgin bir şekilde ortaya koymaktadır. Kullanıcı kendi tercihiğine göre bantların kombinasyonlarını değiştirebilmektedir. Tercih edilen bu görüntü şekil 4.5 ile yaklaşık olarak aynı bölgeyi kapsamaktadır fakat sınıf tercihleri arasında kolay bir şekilde fark edilebilecek renk farkları vardır bu da sınıf tercihlerini kolaylaştırmaktadır.


4.3 SINIFLANDIRMA VE DOĞRULUK ANALİZLERİ

Sınıflandırma işlemine ilk olarak orjinal bantlar ile başlanmıştır. Sentinel-2 uydusu ve Landsat-8 uydusunun seçilen orjinal bantları kullanılarak ayrı ayrı sınıflandırılmıştır. Bununla birlikte, her görüntüye üretilen indeksler ayrı ayrı eklenerek her bir indeksin sınıflandırma doğruluğuna olan katkısı araştırılmıştır. Sınıflandırma doğruluk analizinde işleminin güvenilirliğini test etmek için hata matrisleri eklenmiştir.

Landsat-8 uydusunun seçilen orjinal bantları ile yapılan sınıflandırma sonucu genel görüntüsü şekil 4.7’de, 1/100.000 ölçekli görüntüsü ise şekil 4.8’de gösterilmiştir.



Şekil 4.7 Landsat-8 uydusunun orijinal bantları ile sınıflandırılmış genel görüntü.



Ölçek: 1/100.000



Şekil 4.8 Landsat-8 uydusunun orijinal bantları ile sınıflandırılmış 1/100.000 ölçekli görüntü.

Sınıflandırma sonucu ortaya çıkan hata matrisi çizelge 4.6'da gösterilmiştir.

Çizelge 4.6 Landsat-8 uydusunun orijinal bantlı sınıflandırma sonucu ortaya çıkan hata matrisi

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	952	109	0	0	0	0	0	1061
Mutlak Tarım	60	2557	133	9	1	0	0	2760
Dikili Alan	5	0	359	1	0	0	0	365
Mera	0	0	0	279	120	0	0	399
Marjinal Tarım	0	0	12	367	754	0	0	1133
Orman	0	1	3	0	0	1043	0	1047
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sınıflandırma sonucu yerleşim yeri için seçilen test verilerinden; 1017 pikselin 952'sinin, mutlak tarım için 2667 pikselin 2557'sinin, dikili alan için 507 pikselin 359'nun, mera için 656 pikselin 279'unun, marjinal tarım için 875 pikselin 754'ünün, orman için 1043 pikselin 1043'ünün su yüzeyi için de 585 pikselin 585'inin de doğru sınıfa atandığı tespit edilmiştir.

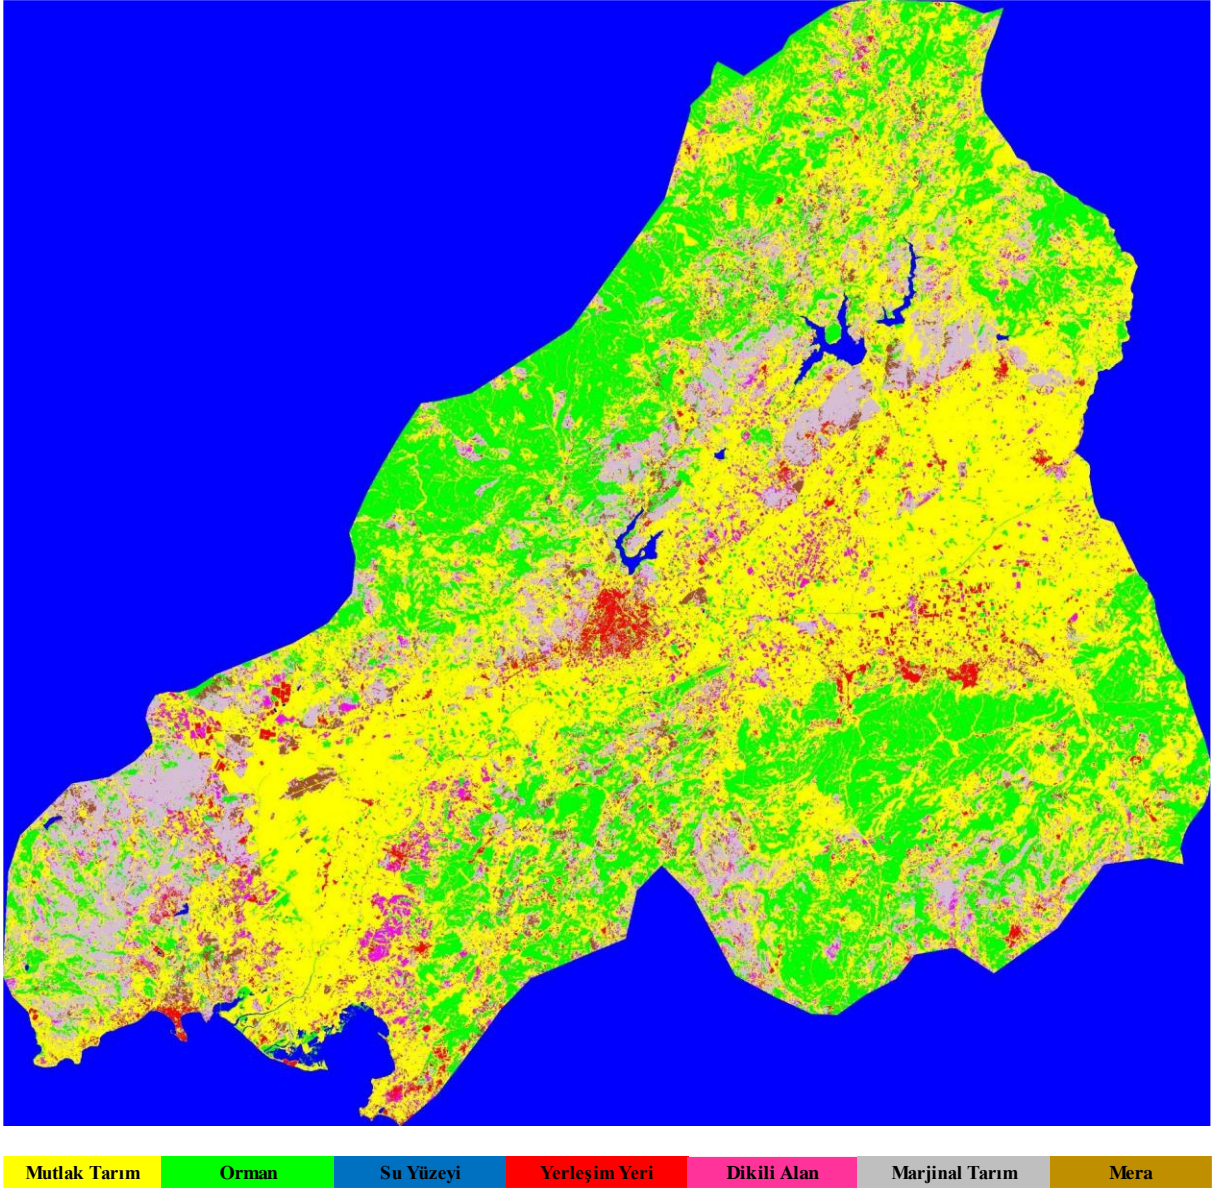
Çizelge 4.7'de Landsat-8 uydusunun orijinal bantları ile gerçekleştirilen sınıflandırma işlemi sonrasında ortaya çıkan genel doğruluk ve kappa değerini gösterilmektedir.

Çizelge 4.7 Landsat-8 uydusunun orijinal bantları ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.


Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.61	89.73	952/1017	952/1061	88.8299 (6529/7350)	0.8587
Mutlak Tarım	95.88	92.64	2557/2667	2557/2760		
Dikili Alan	70.81	98.36	359/507	359/365		
Mera	42.53	69.92	279/656	279/399		
Marjinal Tarım	86.17	66.55	754/875	754/1133		
Orman	100	99.62	1043/1043	1043/1047		
Su Yüzeyi	100	100	585/585	585/585		

Landsat-8 uydusunun orijinal bantları ile yapılan sınıflandırma işlemi sonucunda genel doğruluk %88,82 olarak elde edilmiştir. Öte yandan kappa değeri ise 0,85 olarak belirlenmiştir. Genel doğruluk için hata matrisinin köşegen değerinin toplamının, test verisi toplam piksele oranı ile tespit edilmiştir. Tüm sınıflar incelendiğinde; üretici doğruluğunda dikili alan ve mera sınıfının doğruluğunun düşük olduğu, kullanıcı doğruluğu incelendiğinde ise mera ve marjinal tarım sınıflarının doğruluğunun düşük olduğu göze çarpmaktadır.

Sentinel-2 uydusunun orijinal bantları ile sınıflandırma işlemi sonucu ortaya çıkan genel görüntü şekil 4.9'da, 1/100.000 görüntüsü ise şekil 4.10'da gösterilmektedir.



Şekil 4.9 Sentinel-2 uydusunun orijinal bantları ile sınıflandırma işlemi sonucu ortaya çıkan genel görüntü.



Ölçek: 1/100.000



Şekil 4.10 Sentinel-2 uydusunun orijinal bantları ile sınıflandırılmış 1/100.000 ölçekli görüntü

Sınıflandırma işlemi sonucu ortaya çıkan hata matrisi çizelge 4.8’de belirtilmiştir.

Çizelge 4.8 Sentinel-2 uydusunun orijinal bantlarla yapılan sınıflandırma sonucu ortaya çıkan hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	944	39	0	0	0	0	0	983
Mutlak Tarım	51	2592	74	10	3	19	0	2749
Dikili Alan	22	4	419	4	0	0	0	449
Mera	0	0	0	523	118	0	0	641
Marjinal Tarım	0	0	14	119	754	0	0	887
Orman	0	32	0	0	0	1024	0	1056
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydusunun tüm bantları ile yapılan sınıflandırma sonucu ortaya çıkan hata matrisinde; yerleşim yeri için 1017 pikselim 944'ünün, mutlak tarım için 2667 pikselin 2592'sinin, dikili alan için 507 pikselin 419'unun, mera için 656 pikselin 523'ünün, marjinal tarım için 875 pikselin 754'ünün, orman için 1043 pikselin 1024'ünün, su yüzeyi için ise 585 pikselin 585'inin de doğru sınıfa atandığı tespit edilmiştir.


Çizelge 4.9'da Sentinel-2 uydusunun orijinal bantları ile gerçekleştirilen sınıflandırma işlemi sonrasında ortaya çıkan genel doğruluk ve kappa değerini gösterilmektedir.

Çizelge 4.9 Sentinel-2 uydusunun orijinal bantlar ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	92.82	96.03	944/1017	944/983	93.0748 (6841/7350)	0.9126
Mutlak Tarım	97.19	94.29	2592/2667	2592/2749		
Dikili Alan	82.64	93.32	419/507	419/449		
Mera	79.73	81.59	523/656	523/641		
Marjinal Tarım	86.17	85.01	754/875	754/887		
Orman	98.18	96.97	1024/1043	1024/1056		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydusunun orijinal bantları ile yapılan sınıflandırma işlemi sonucunda genel doğruluk %93,07 çıkmıştır. Kappa değeri ise 0,91 olarak tespit edilmiştir Sınıf bazında doğruluklara bakıldığında ise; üretici doğruluğunda da, kullanıcı doğruluğunda da mera sınıfının doğruluğunun diğer sınıfların doğruluğundan daha düşük çıktığı tespit edilmiştir.

Şekil 4.11'de Landsat-8 uydusunun BNDVI indeksinden yararlanılarak sınıflandırılmış görüntüsü yer almaktadır.



Ölçek: 1/100.000



Şekil 4.11 Landsat-8 bantları ve BNDVI indeksi ile yapılan sınıflandırma görüntüsü.

Sınıflandırma işlemi sonucunda ortaya çıkan hata matrisi çizelge 4.10'da gösterilmiştir.

Çizelge 4.10 Landsat-8 bantları ve BNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	947	121	0	0	0	0	0	1068
Mutlak Tarım	65	2539	123	9	0	0	0	2736
Dikili Alan	5	6	361	2	0	0	0	374
Mera	0	0	1	288	110	0	0	399
Marjinal Tarım	0	0	17	357	764	0	0	1138
Orman	0	1	5	0	1	1043	0	1050
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sınıflandırma işlemi sonucunda; yerleşim yeri için 1017 pikselin 947'si, mutlak tarım için 2677 pikselin 2539'u, dikili alan için 507 pikselin 361'i, mera için 656 pikselin 288'i, marjinal tarım için 875 pikselin 764'ü, orman için 1043 pikselin 1043'ü ve su yüzeyi için ise 585 pikselin 585'inin de doğru sınıflara atandığı tespit edilmiştir.


Çizelge 4.11'de Landsat-8 uydusunun BNDVI indeksi yardımı ile gerçekleştirilen sınıflandırma işlemi sonrasında ortaya çıkan genel doğruluk ve kappa değerini gösterilmektedir.

Çizelge 4.11 Landsat-8 uydusunun BNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.15	88.67	947/1017	947/1068	88.8027 (6527/7350)	0.8585
Mutlak Tarım	95.2	92.8	2539/2667	2539/2736		
Dikili Alan	71.2	96.52	361/507	361/374		
Mera	43.9	72.18	288/656	288/399		
Marjinal Tarım	87.31	67.14	764/875	764/1138		
Orman	100	99.33	1043/1043	1043/1050		
Su Yüzeyi	100	100	585/585	585/585		

Landsat-8 uydusunun BNDVI indeksi yardımıyla sınıflandırılması sonucu ortaya çıkan genel doğruluk oranı %88,80 olarak tespit edilmiştir. Öte yandan kappa değeri 0,85 olarak karşımıza çıkmıştır. Sınıf bazında doğruluklara bakıldığında ise; üretici doğruluğunda, dikili alan sınıfı ve mera sınıfının düşük olduğu tespit edilmiştir. Kullanıcı doğruluğuna bakıldığında ise; mera sınıfı ve marjinal tarım sınıfının düşük olduğu belirlenmiştir.

Şekil 4.12'de Sentinel-2 uydusunun BNDVI indeksi ile sınıflandırma işlemi sonucu ortaya çıkan görüntü yer almaktadır.



Ölçek: 1/100.000



Şekil 4.12 Sentinel-2 bantları ve BNDVI indeksi ile yapılan sınıflandırma görüntüsü.

Çizelge 4.12’de Sentinel-2 uydusunun BNDVI indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.12 Sentinel-2 bantları ve BNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	932	47	0	0	0	0	0	979
Mutlak Tarım	50	2590	115	8	3	27	0	2793
Dikili Alan	35	4	378	7	0	0	0	424
Mera	0	0	2	499	114	0	0	615
Marjinal Tarım	0	0	12	142	756	0	0	910
Orman	0	26	0	0	2	1016	0	1044
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydusunun BNDVI indeksi desteği ile sınıflandırılması sonucu oluşan hata matrisinde sınıflara tek tek bakıldığında; yerleşim yeri 1017 pikselin 932'si, mutlak tarım için 2667 pikselin 2590'ı, dikili alan için 507 pikselin 378'i, mera için 656 pikselin 499'u, marjinal tarım için 875 pikselin 756'sı, orman için 1043 pikselin 1016'sı ve su yüzeyi için 585 pikselin 585'inin doğru sınıflara atandığı tespit edilmiştir.


Çizelge 4.13'te ise Sentinel-2 uydusunun BNDVI destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.13 Sentinel-2 uydusunun BNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	91.64	95.2	932/1017	932/979	91.9184 (6756/7350)	0.8978
Mutlak Tarım	97.11	92.73	2590/2667	2590/2793		
Dikili Alan	74.56	89.15	378/507	378/424		
Mera	76.07	81.14	499/656	499/615		
Marjinal Tarım	86.4	83.08	756/656	756/910		
Orman	94.41	97.32	1016/1043	1016/1044		
Su Yüzeyi	100	100	585/585	585/585		

BNDVI indeksi yardımıyla yapılan sınıflandırma sonucu ortaya çıkan genel doğruluk oranı %91,91 olarak tespit edilmiştir. Kappa değeri ise 0,89 olarak belirlenmiştir. Sınıf bazında doğruluklara bakıldığında ise üretici doğruluğunda dikili alan sınıfı ve mera sınıfının değerlerinin diğerlerine göre düşük çıktığı tespit edilmiştir. Kullanıcı doğruluğuna bakıldığında ise diğer sınıfların doğruluk oranlarına bakış mera ve marjinal tarım sınıfının doğruluk oranının düşük olduğu belirlenmiştir.

Şekil 4.13'da Landsat-8 bantları ve GNDVI indeksi ile yapılan sınıflandırılmış görüntüsü yer almaktadır



Ölçek: 1/100.000

Mutlak Tarım	Orman	Su Yüzeyi	Yerleşim Yeri	Dikili Alan	Marjinal Tarım	Mera
--------------	-------	-----------	---------------	-------------	----------------	------

Şekil 4.13 Landsat-8 bantları ve GNDVI indeksi ile yapılan sınıflandırma görüntüsü.

Çizelge 4.14’te Landsat-8 uydusunun GNDVI indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.14 Landsat-8 bantları ve GNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi
Yerleşim Yeri	954	97	0	0	0	0	0
Mutlak Tarım	54	2569	120	9	0	0	0
Dikili Alan	9	0	364	3	0	0	0
Mera	0	0	3	283	130	0	0
Marjinal Tarım	0	0	15	361	742	0	0
Orman	0	1	5	0	3	1043	0
Su Yüzeyi	0	0	0	0	0	0	585
Toplam	1017	2667	507	656	875	1043	585

Landsat-8 uydusunun GNDVI indeksi desteğiyle yapılan sınıflandırma işlemine ait hata matrisinde; yerleşim yerine ait 1017 pikselin 954'ü, mutlak tarıma ait 2667 pikselin 2569'u, dikili alanın 507 pikselinin 364'ü, meraya ait 656 pikselin 283'ü, marjinal tarıma ait 875 pikselin 130'u, orman sınıfına ait 1043 pikselin 1043'ü, su yüzeyi sınıfının 585 pikselinin 585'i doğru sınıfa atanmıştır.


Çizelge 4.15'te ise Landsat-8 uydusunun GNDVI destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.15 Landsat-8 uydusunun GNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.81	90.77	954/1017	954/1051	88.9796 (6540/7350)	0.8607
Mutlak Tarım	96.33	93.35	2569/2667	2569/2752		
Dikili Alan	71.79	96.81	364/507	364/376		
Mera	43.14	68.03	283/656	283/416		
Marjinal Tarım	84.8	66.37	742/875	742/1118		
Orman	100	99.14	1043/1043	1043/1052		
Su Yüzeyi	100	100	585/585	585/585		

Landsat-8 uydusunun GNDVI indeksi destekli sınıflandırma işleminde genel doğruluk %88,97 olarak tespit edilmiştir. Kappa değeri ise 0,86 olarak karşımıza çıkmaktadır. Öte yandan sınıf bazında doğruluklar değerlendirildiğinde, üretici doğruluğu göz önünde bulundurulduğunda dikili alan ve mera sınıfının doğruluğunun diğer sınıfların doğruluğuna bakışla daha düşük olduğu tespit edilmiştir. Kullanıcı doğruluklarında ise mera ve marjinal tarım sınıflarının doğruluklarının düşük olduğu ortaya çıkmıştır.

Şekil 4.14'te Sentinel-2 uydusunun GNDVI indeksi ile sınıflandırma işlemi sonucu ortaya çıkan görüntü yer almaktadır.



Şekil 4.14 Sentinel-2 bantları ve GNDVI indeksi ile yapılan sınıflandırılmış görüntüsü.

Çizelge 4.16'da Sentinel-2 uydusunun GNDVI indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.16 Sentinel-2 bantları ve GNDVI indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	940	44	0	0	0	0	0	984
Mutlak Tarım	51	2591	103	8	4	34	0	2791
Dikili Alan	26	0	386	1	0	0	0	416
Mera	0	1	2	506	125	0	0	634
Marjinal Tarım	0	1	16	141	744	0	0	902
Orman	0	30	0	0	2	1009	0	1041
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydusunun GNDVI indeksi ile yapılan sınıflandırma işlemine ait hata matrisinde; yerleşim yerine ait 1017 pikselin 940'ının, mutlak tarıma ait 2667 pikselin 2591'inin, dikili alana ait 507 pikselin 386'sının, meraya ait 656 pikselin 506'sının, marjinal tarıma ait 875 pikselin 744'ünün, ormana ait 1043 pikselin 1009'unun ve su yüzeyine ait 585 pikselin 585'inin doğru sınıflara atandığı tespit edilmiştir.


Çizelge 4.17'de ise Sentinel-2 uydusunun GNDVI destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.17 Sentinel-2 uydusunun GNDVI indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	92.43	95.53	940/1017	940/984	91.9864 (6761/7350)	0.8987
Mutlak Tarım	97.15	92.83	2591/2667	2591/2791		
Dikili Alan	76.13	93.46	386/507	386/413		
Mera	77.13	79.81	506/656	506/634		
Marjinal Tarım	85.03	82.48	744/875	744/902		
Orman	96.74	96.93	1009/1043	1009/1041		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydusunun GNDVI indeksi yardımıyla oluşturulan sınıflandırma işlemine ait genel doğruluk değeri %91,98 çıkmıştır. Kappa değeri ise 0,89 olarak belirlenmiştir. Sınıf bazında doğruluklara bakıldığında ise üretici doğruluklarında dikili alan sınıfı ve mera sınıfının doğruluğunun diğer sınıflara oranla düşük kaldığı gözlemlenmiştir. Kullanıcı doğruluklarında ise mera ve marjinal tarım sınıflarının diğer sınıfların doğruluk oranlarının altında kaldığı belirlenmiştir.

Şekil 4.15'te Landsat-8 uydusunun NDVI indeksi ile sınıflandırma işlemi sonucu ortaya çıkan görüntü yer almaktadır.



Ölçek: 1/100.000



Şekil 4.15 Landsat-8 bantları ve NDVI1 indeksi ile yapılan sınıflandırma görüntüsü.

Çizelge 4.18’de Landsat-8 uydusunun NDVI1 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.18 Landsat-8 bantları ve NDVII indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	952	111	0	0	0	0	0	1063
Mutlak Tarım	60	2556	86	9	1	0	0	2712
Dikili Alan	5	0	403	0	0	0	0	408
Mera	0	0	4	299	159	0	0	462
Marjinal Tarım	0	0	9	348	714	0	0	1071
Orman	0	0	5	0	1	1043	0	1049
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Landsat-8 uydusunun NDVII indeksi yardımıyla oluşturulan sınıflandırma işlemi sonucunda oluşan hata matrisinde; yerleşim yerine ait 1017 pikselin 952'sinin, mutlak tarıma ait 2667 pikselin 2556'sının, dikili alana ait 507 pikselin 403'ünün, meraya ait 656 pikselin 299'unun, marjinal tarıma ait 875 pikselin 159'unun, ormana ait 1043 pikselin 1043'ünün ve su yüzeyine ait 585 pikselin 585'inin doğru sınıflara atandığı tespit edilmiştir.

Çizelge 4.19'da ise Landsat-8 uydusunun NDVII destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.19 Landsat-8 uydusunun NDVII indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.61	89.56	952/1017	952/1063	89.1429 (6552/7350)	0.863
Mutlak Tarım	95.84	94.25	2556/2667	2556/2712		
Dikili Alan	79.49	98.77	403/507	403/408		
Mera	45.58	64.72	299/656	299/462		
Marjinal Tarım	81.6	66.67	714/875	714/1071		
Orman	100	99.43	1043/1043	1043/1049		
Su Yüzeyi	100	100	585/585	585/585		

Landsat-8 uydu görüntüsünün NDVII indeksi destekli sınıflandırma işlemi sonrasında genel doğruluk oranı %89,14 olarak tespit edilmiştir. Kappa değeri ise 0,86 olarak karşımıza çıkmaktadır. Doğruluklar sınıf bazında incelendiğinde ise üretici doğruluğunda dikili alan ve mera sınıfı düşük değerde kalmıştır. Kullanıcı doğruluğunda ise mera ve marjinal tarım sınıfı diğer sınıfların doğruluk oranlarına bakış daha düşük kalmıştır.

Görüntüler üzerinde sınıflandırmada ki küçük farklılıklar sebebiyle ayırt etmenin zor olmasından dolayı çalışmanın devamında sadece hata matrisleri ve doğruluk, kappa değerleri tabloları belirtilerek devam edilmiştir.

Çizelge 4.20’de Sentinel-2 uydusunun NDVI1 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.20 Sentinel-2 bantları ve NDVI1 indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	945	47	0	0	0	0	0	992
Mutlak Tarım	54	2585	44	8	3	31	0	2725
Dikili Alan	18	4	448	0	0	0	0	470
Mera	0	0	4	535	131	0	0	670
Marjinal Tarım	0	0	11	113	737	0	0	861
Orman	0	31	0	0	4	1012	0	1047
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydusunun NDVI1 indeksi ile oluşturulan sınıflandırılmış görüntüye ait hata matrisinde; yerleşim yerine ait 1017 pikselin 945’inin, mutlak tarıma ait 2667 pikselin 2585’inin, dikili alana ait 507 pikselin 448’inin, meraya ait 656 pikselin 535’inin, marjinal tarıma ait 875 pikselin 737’sinin, ormana ait 1043 pikselin 1012’sinin ve su yüzeyine ait 585 pikselin 585’inin doğru sınıflara atandığı tespit edilmiştir.

Çizelge 4.21’de Sentinel-2 uydusunun NDVI1 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.21 Sentinel-2 uydusunun NDVI1 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	92.92	95.26	945/1017	945/992	93.1565 (6847/7350)	0.9138
Mutlak Tarım	96.93	94.86	2585/2667	2585/2725		
Dikili Alan	88.36	95.32	448/507	448/470		
Mera	81.55	79.85	535/656	535/670		
Marjinal Tarım	84.23	85.6	737/875	737/861		
Orman	97.03	96.66	1012/1043	1012/1047		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydu görüntüsünün NDVI1 indeksi yardımıyla oluşturulan sınıflandırılma işlemi sonrasında genel doğruluk değeri %93,15 olarak belirlenmiştir. Kappa değeri 0,91’dir. Sınıf bazında bakıldığında da üretici doğruluğu olarak, mera sınıfının diğer sınıfların doğruluklarına oranla daha düşük kaldığı belirlenmiştir. Kullanıcı doğruluklarına bakıldığında ise mera ve marjinal tarım sınıfının diğer sınıfların doğruluk oranlarına göre düşük kaldığı gözlemlenmiştir.

Çizelge 4.22’de Landsat-8 uydusunun NDVI2 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.22 Landsat-8 bantları ve NDVI2 indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	949	114	0	0	0	0	0	1063
Mutlak Tarım	63	2552	107	8	1	0	0	2731
Dikili Alan	5	0	380	2	0	0	0	387
Mera	0	0	1	273	102	0	0	376
Marjinal Tarım	0	0	14	373	772	0	0	1159
Orman	0	1	5	0	0	1043	0	1049
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Landsat-8 uydu görüntüsünün NDVI2 indeksi yardımıyla oluşturulan sınıflandırılmış görüntüye ait hata matrisinde; yerleşim yerine ait 1017 pikselin 949’unun, mutlak tarıma ait 2667 pikselin 2552’sinin, dikili alana ait 507 pikselin 380’inin, meraya ait 656 pikselin 273’ünün, marjinal tarıma ait 875 pikselin 772’sinin, ormana ait 1043 pikselin 1043’ünün ve su yüzeyine ait 585 pikselin 585’inin doğru sınıflara atandığı tespit edilmiştir.

Çizelge 4.23’te Landsat-8 uydusunun NDVI2 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.23 Landsat-8 uydusunun NDVI2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.31	89.28	949/1017	949/1063	89.1701 (6554/7350)	0.8632
Mutlak Tarım	95.69	93.45	2552/2667	2552/2731		
Dikili Alan	74.95	98.19	380/507	380/387		
Mera	41.62	72.61	273/656	273/376		
Marjinal Tarım	88.23	66.61	772/875	772/1159		
Orman	100	99.43	1043/1043	1043/1049		
Su Yüzeyi	100	100	585/585	585/585		

Landsat-8 uydusunun NDVI2 indeksi desteğiyle oluşturulan sınıflandırma işlemine ait genel doğruluk değeri %89,17 olarak belirlenmiştir. Kappa değeri ise 0,86’dir. Sınıf bazında doğruluklar değerlendirildiğinde ise üretici doğruluğunda dikili alan ve mera sınıflarının diğerlerine oranla düşük kaldığı belirlenmiştir. Kullanıcı doğruluğunda ise mera ve marjinal tarım sınıflarının doğruluğunun düşük kaldığı tespit edilmiştir.

Çizelge 4.24'te Sentinel-2 uydusunun NDVI2 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.24 Sentinel-2 bantları ve NDVI2 indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	938	56	1	0	0	0	0	995
Mutlak Tarım	55	2546	65	8	2	3	0	2679
Dikili Alan	24	4	423	5	0	0	0	456
Mera	0	0	4	521	115	0	0	640
Marjinal Tarım	0	0	14	122	758	0	0	894
Orman	0	61	0	0	0	1040	0	1101
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydu görüntüsünün NDVI2 indeksi yardımı ile sınıflandırma işlemi sonucu ortaya çıkan hata matrisinde; yerleşim yerine ait 1017 pikselin 938'i, mutlak tarıma ait 2667 pikselin 2546'sının, dikili alana ait 507 pikselin 423'ü, meraya ait 656 pikselin 521'i, marjinal tarıma ait 875 pikselin 758'i, ormana ait 1043 pikselin 1040'ı ve su yüzeyine ait 585 pikselin 585'i doğru sınıfa atanmıştır.

Çizelge 4.25'te Sentinel-2 uydusunun NDVI2 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.25 Sentinel-2 uydusunun NDVI2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	92.23	94.27	938/1017	938/995	92.6667 (6811/7350)	0.9077
Mutlak Tarım	95.46	95.04	2546/2667	2546/2679		
Dikili Alan	83.43	92.76	423/507	423/456		
Mera	79.42	81.41	521/656	521/640		
Marjinal Tarım	86.63	84.79	758/875	758/894		
Orman	99.71	94.46	1040/1043	1040/1101		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydusu görüntüsünün NDVI2 indeksi yardımıyla yapılan sınıflandırma işlemi sonucunda genel doğruluk oranı %92,66 çıkmıştır. Kappa değeri ise 0,90'dir. Sınıf bazında doğruluklara baktığımızda; üretici doğruluğunda mera ve dikili alan sınıfının doğruluk oranının düşük kaldığı gözlemlenmiştir. Kullanıcı doğruluklarına bakıldığında ise mera ve marjinal tarım sınıfının doğruluğunun diğer sınıflardan düşük kaldığı belirlenmiştir.

Çizelge 4.26’da Sentinel-2 uydusunun NDVIre1 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.26 Sentinel-2 bantları ve NDVIre1 indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	941	46	2	0	0	0	0	989
Mutlak Tarım	53	2570	78	8	1	29	0	2739
Dikili Alan	23	3	412	2	0	0	0	440
Mera	0	0	4	540	144	0	0	688
Marjinal Tarım	0	1	11	106	726	0	0	844
Orman	0	47	0	0	4	1014	0	1065
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydu görüntüsünün NDVIre1 indeksi yardımıyla oluşturulan sınıflandırma sonucu oluşan hata matrisinde; yerleşim yerine ait 1017 pikselin 941’inin, mutlak tarıma ait 2667 pikselin 2570’inin, dikili alana ait 507 pikselin 412’sinin, meraya ait 656 pikselin 540’ının, marjinal tarıma ait 875 pikselin 726’sının, ormana ait 1043 pikselin 1014’ünün ve su yüzeyine ait 585 pikselin 585’inin doğru sınıflara atandığı tespit edilmiştir.

Çizelge 4.27’de Sentinel-2 uydusunun NDVIre1 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve Kappa değeri gösterilmektedir.

Çizelge 4.27 Sentinel-2 uydusunun NDVIre1 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kapa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	92.53	95.15	941/1017	941/989	92.353 (6788/7350)	0.9036
Mutlak Tarım	96.36	93.83	2570/2667	2570/2739		
Dikili Alan	81.26	93.64	412/507	412/440		
Mera	82.32	78.49	540/656	540/688		
Marjinal Tarım	82.97	86.02	726/875	726/844		
Orman	97.22	95.21	1014/1043	1014/1065		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydu görüntüsünün NDVIre1 indeksi destekli sınıflandırma işlemi sonucunda genel doğruluk değeri %92,35 olarak belirlenmiştir. Kappa değeri ise 0,90’dır. Sınıf bazında doğruluklara bakıldığında ise; üretici doğruluğunda dikili alan, mera ve marjinal tarım sınıfının diğer sınıf doğruluk değerlerinden düşük kaldığı gözlemlenmiştir. Üretici doğruluklarında ise; mera ve marjinal tarım sınıfının diğer sınıfların doğruluk değerlerinden düşük kaldığı belirlenmiştir.

Çizelge 4.28’de Sentinel-2 uydusunun NDVIre2 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.28 Sentinel-2 bantları ve NDVIre2 indeksi ile yapılan sınıflandırmanın hata matrisi.

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	957	26	3	0	0	0	0	986
Mutlak Tarım	38	2621	93	4	6	24	0	2786
Dikili Alan	22	9	400	0	0	0	0	431
Mera	0	0	0	537	100	0	0	637
Marjinal Tarım	0	0	11	115	769	0	0	895
Orman	0	11	0	0	0	1019	0	1030
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydu görüntüsünün NDVIre2 indeksi yardımıyla oluşturulan sınıflandırmaya ait hata matrisinde; yerleşim yerine ait 1017 pikselim 957’sinin, mutlak tarıma ait 2667 pikselin 2621’inin, dikili alana ait 507 pikselin 400’ünün, meraya ait 656 pikselin 537’sinin, marjinal tarıma ait 875 pikselin 769’u, ormana ait 1043 pikselin 1019’unun ve su yüzeyine ait 585 pikselin 585’inin doğru sınıfa atandığı tespit edilmiştir.

Çizelge 4.29’da Sentinel-2 uydusunun NDVIre2 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.29 Sentinel-2 uydusunun NDVIre2 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	94.1	97.06	957/1017	957/986	93.7143 (6888/7350)	0.9206
Mutlak Tarım	98.28	94.08	2621/2667	2621/2786		
Dikili Alan	78.9	92.81	400/507	400/431		
Mera	81.86	84.3	537/656	537/637		
Marjinal Tarım	87.89	85.92	769/875	769/895		
Orman	97.7	98.93	1019/1043	1019/1030		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydu görüntüsünün NDVIre2 indeks desteği ile sınıflandırılmış görüntüsüne ait genel doğruluk değeri %93,71’tür. Kappa değer ise 0,92 olarak karşımıza çıkmaktadır. Sınıf bazında doğruluklara baktığımızda ise; üretici doğruluğunda dikili alan, mera ve marjinal tarım

sınıflarının diğer sınıf doğruluklarından aşağıda kaldığı tespit edilmiştir. Kullanıcı doğruluklarında ise mera ve marjinal tarım sınıflarının diğer sınıfların doğruluklarından düşük kaldığı gözlemlenmiştir.

Çizelge 4.30'da Sentinel-2 uydusunun NDVIre3 indeksi desteğiyle oluşturulan sınıflandırma işleminin hata matrisi yer almaktadır.

Çizelge 4.30 Sentinel-2 bantları ve NDVIre3 indeksi ile yapılan sınıflandırmanın hata matrisi

Sınıf	Yerleşim Yeri	Mutlak Tarım	Dikili Alan	Mera	Marjinal Tarım	Orman	Su Yüzeyi	Toplam
Yerleşim Yeri	951	33	2	0	0	0	0	986
Mutlak Tarım	51	2610	55	6	2	21	0	2745
Dikili Alan	15	10	440	1	0	0	0	466
Mera	0	0	0	539	103	0	0	642
Marjinal Tarım	0	0	10	110	770	0	0	890
Orman	0	14	0	0	0	1022	0	1036
Su Yüzeyi	0	0	0	0	0	0	585	585
Toplam	1017	2667	507	656	875	1043	585	7350

Sentinel-2 uydusu görüntüsünün NDVIre3 indeksi yardımıyla oluşturulan sınıflandırılmış görüntünün hata matrisinde; yerleşim yeri için 1017 pikselin 951'inin, mutlak tarım için 2667 pikselin 2610'unun, dikili alan için 507 pikselin 440'ının, mera için 656 parselin 539'u, marjinal tarım için 875 pikselin 770'i, orman için 1043 pikselin 1022'si ve su yüzeyi için 585 pikselin 585'i doğru sınıfa atanmıştır.

Çizelge 4.31'de Sentinel-2 uydusunun NDVIre3 destekli sınıflandırma işlemi sonucu ortaya çıkan genel doğruluk ve kappa değeri gösterilmektedir.

Çizelge 4.31 Sentinel-2 uydusunun NDVIre3 indeksi yardımı ile sınıflandırma sonucu ortaya çıkan genel doğruluk ve kappa değeri.

Sınıf	Üretici Doğ. (%)	Kullanıcı Doğ. (%)	Üretici Doğ. (pixel)	Kullanıcı Doğ. (pixel)	Genel Doğ. (%)	Kappa
Yerleşim Yeri	93.51	96.45	951/1017	951/986	94.1088 (6917/7350)	0.9257
Mutlak Tarım	97.86	95.08	2610/2667	2610/2745		
Dikili Alan	86.79	94.42	440/507	440/466		
Mera	82.16	83.96	539/656	593/642		
Marjinal Tarım	88	86.52	770/875	770/890		
Orman	97.99	98.65	1022/1043	1022/1036		
Su Yüzeyi	100	100	585/585	585/585		

Sentinel-2 uydu görüntüsünün NDVIre3 indeks desteği ile sınıflandırılmış görüntüsüne ait genel doğruluk değeri %94,10'dir. Kappa değeri ise 0,92'dir. Sınıf bazında doğruluklar incelendiğinde; üretici doğruluğu için dikili alan, mera ve marjinal tarım sınıfının diğer

sınıfların doğruluk deęerinden düşük kaldığı tespit edilmiştir. Kullanıcı doğruluęunda ise mera ve marjinal tarım sınıfının düşük kaldığı görölmüştür.

Sınıflandırma işlemleri sırasında Sentinel-2 uydusu için Landsat-8 uydusundan farklı olarak eklenen NDVIre1, NDVIre2 ve NDVIre3 bantlarının amacı genel doğruluęa ve sınıf bazında doğruluklara katkısının gözlemlenmesidir.





BÖLÜM 5

BULGULAR

Bu bölümde Sentinel-2 ve Landsat-8 uydu görüntüsü ile yapılan sınıflandırma işlemleri sonrası sınıf bazında doğruluklar ve indekslerin bu sınıflara olan katkıları belirtilmiştir. Olumlu katkılardan bahsedebilmek için uydu görüntülerinin orjinal bantları ile yapılan sınıflandırma işlemlerinin doğruluk oranından daha yüksek oranda sonuç vermeleri istenmektedir. Bazı indekslerin genel doğruluğa katkısı olmasına rağmen sınıf bazında bakıldığında doğruluk oranını düşürdüğü bölümlerde tespit edilmiştir.

Çizelge 5.1’de sınıflandırılmış görüntülerin genel doğrulukları belirtilmektedir.

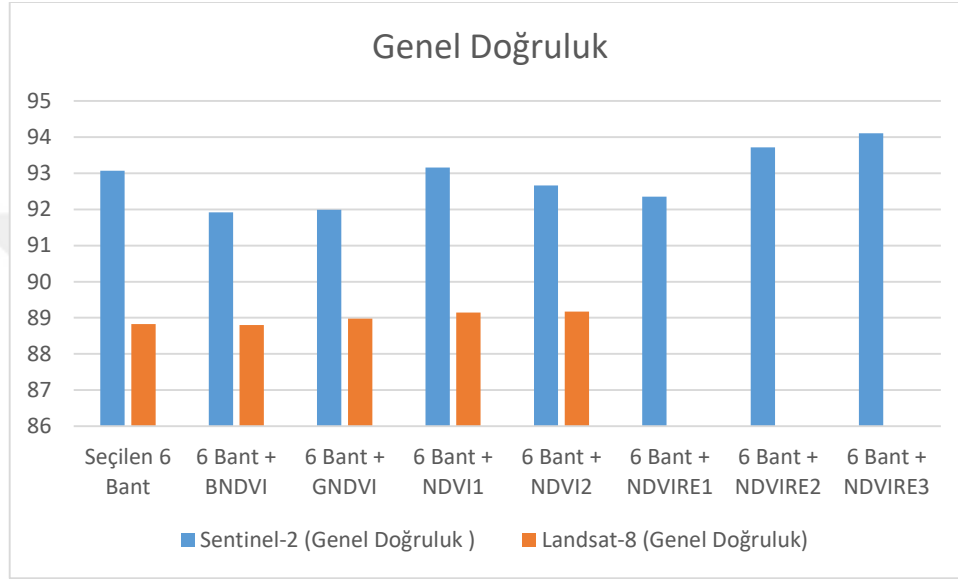
Çizelge 5.1 İndekslerin genel doğruluklara katkıları.

İNDEKSLER	Sentinel-2 (genel doğruluk)	Landsat-8 (genel doğruluk)
Seçilen 6 Bant	93.07	88.82
6 Bant + BNDVI	91.91	88.80
6 Bant + GNDVI	91.98	88.97
6 Bant + NDVI1	93.15	89.14
6 Bant + NDVI2	92.66	89.17
6 Bant + NDVIRE1	92.35	
6 Bant + NDVIRE2	93.71	
6 Bant + NDVIRE3	94.10	

Sınıflandırma işlemleri sonucunda Sentinel-2 uydu görüntüsünün sınıflandırma işlemi sonrasında elde edilen genel doğruluk oranı %93,07 olarak elde edilmiştir. Landsat-8 uydu görüntüsünün sınıflandırma işlemi sonrasında elde edilen genel doğruluk oranı ise %88,82 olarak elde edilmiştir. Hiçbir indeks desteği olmadan yapılan sınıflandırma işlemi sonrasında Sentinel-2 uydu görüntüsünün Landsat-8 uydu görüntüsünün genel sınıflandırma doğruluğundan %4,25 daha doğru sonuç verdiği tespit edilmiştir.

Sentinel-2 uydusu en yüksek genel doğruluğu %94,10 ile NDVIre3 indeksi yardımıyla elde etmiştir. Landsat-8 uydusu ise en yüksek doğruluğu %89,17 ile NDVI2 indeksi ile elde etmiştir. Elde edilen en yüksek doğruluklar arasında ki fark ise %4,93'tür. Landsat-8 uydusunun kırmızı kenar bantları olmadığından fark artmıştır. Çizelge 5.2'de indekslerin katkıları tablo halinde belirtilmiştir.

Çizelge 5.2 Genel doğruluk oranları ve indeks katkıları.



Tüm sınıflar ayrı ayrı incelenip hangi sınıfın hangi indekste doğruluğunun arttığı gözlemlenmiştir. Çizelge 5.3'te yerleşim yeri için indeks etkileri belirtilmiştir.

Çizelge 5.3 Yerleşim yeri sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Yerleşim Yeri	Seçilen 6 Bant	93.61	89.73	92.82	96.03
	6 Bant + BDNVI	93.15	88.67	91.64	95.2
	6 Bant + GNDVI	93.81	90.77	92.43	95.53
	6 Bant + NDVI1	93.61	89.56	92.92	95.26
	6 Bant + NDVI2	93.31	89.28	92.23	94.27
	6 Bant + NDVIre1			92.53	95.15
	6 Bant + NDVIre2			94.1	97.06
	6 Bant + NDVIre3			93.51	96.45

Çizelge 5.3'te yerleşim yeri sınıfı için her iki uydu görüntüsü üzerinde de orijinal bantları ve indeks etkileriyle beraber üretici doğrulukları ve kullanıcı doğrulukları verilmiştir. Landsat-8 uydu görüntüsü üzerinden yapılan sınıflandırma işlemi sonucunda; GNDVI indeksinin hem

üretici doğruluğuna hem de kullanıcı doğruluğuna olumlu katkısı göze çarpmıştır. Öte yandan Sentinel-2 uydu görüntüsünde NDVIre2 ve NDVIre3 bantlarının da hem üretici hem de kullanıcı doğruluğunda olumlu katkısı olmuştur. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu ve üretici doğruluğu GNDVI indeksinde görülmüştür. Sentinel-2 uydu görüntüsü içinse en yüksek kullanıcı doğruluğu ve üretici doğruluğu ise NDVIre2 indeksinde tespit edilmiştir.

Çizelge 5.4'te mutlak tarım sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.4 Mutlak tarım sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Mutlak Tarım	Seçilen 6 Bant	95.88	92.64	97.19	94.29
	6 Bant + BDNVI	95.2	92.8	97.11	92.73
	6 Bant + GNDVI	96.33	93.35	97.15	92.83
	6 Bant + NDVI1	95.84	94.25	96.93	94.86
	6 Bant + NDVI2	95.69	93.45	95.46	95.04
	6 Bant + NDVIre1			96.36	93.83
	6 Bant + NDVIre2			98.28	94.08
	6 Bant + NDVIre3			97.86	95.08

Çizelge 5.4'te mutlak tarım sınıfı için doğruluk değerleri verilmiştir. Landsat-8 uydu görüntüsü için BDNVI, GNDVI, NDVI1 ve NDVI2 indekslerinin kullanıcı doğruluğuna olumlu etki yaptığı, GNDVI indeksinin ayrıca üretici doğruluğuna da olumlu etki yaptığı görülmüştür. Sentinel-2 uydu görüntüsü için ise NDVI1, NDVI2 ve NDVIre3 indekslerinin kullanıcı doğruluğuna olumlu etki yaptığı, NDVIre2 ve NDVIre3 indekslerinin ise üretici doğruluğunda olumlu katkı yaptığı gözlemlenmiştir. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu NDVI1 indeksinde, üretici doğruluğu içinse en yüksek doğruluk değeri GNDVI indeksinde görülmüştür. Sentinel-2 uydu görüntüsü içinse en yüksek kullanıcı doğruluğu NDVIre3 indeksinde, üretici doğruluğunda ise NDVIre2 indeksinde tespit edilmiştir.

Çizelge 5.5'te dikili alan sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.5 Dikili alan sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Dikili Alan	Seçilen 6 Bant	70.81	98.36	82.64	93.32
	6 Bant + BDNVI	71.2	96.52	74.56	89.15
	6 Bant + GNDVI	71.79	96.81	76.13	93.46
	6 Bant + NDVI1	79.49	98.77	88.36	95.32
	6 Bant + NDVI2	74.95	98.19	83.43	92.76
	6 Bant + NDVIRE1			81.26	93.64
	6 Bant + NDVIRE2			78.9	92.81
	6 Bant + NDVIRE3			86.79	94.42

Çizelge 5.5'te Landsat-8 uydu görüntüsü üzerinden yapılan sınıflandırmalarda BDNVI, GNDVI, NDVI1 ve NDVI2 indekslerinin üretici doğruluğunda olumlu katkısı olduğu gözlemlenmiştir. Kullanıcı doğruluğunda ise sadece NDVI1 indeksi olumlu katkı sunmuştur. Sentinel-2 uydu görüntüsü üzerinden sınıflandırma işlemleri için ise; NDVI1, NDVI2 ve NDVI3 indekslerinin üretici doğruluğunda pozitif etkisi görülmüştür. Kullanıcı doğruluğunda ise GNDVI, NDVI1, NDVI1 ve NDVI3 indekslerinin olumlu katkısı göze çarpmıştır. NDVI1 indeksi üretici ve kullanıcı doğruluklarını sırasıyla %5,72 ve %2 oranında artırmıştır. NDVI3 indeksi dikili alan doğrulukları sırasıyla %4,15 ve %1,1 oranında artırmıştır. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu ve üretici doğruluğu NDVI1 indeksinde görülmüştür. Sentinel-2 uydu görüntüsü içinde en yüksek kullanıcı doğruluğu ve üretici doğruluğu NDVI1 indeksinde tespit edilmiştir.

Çizelge 5.6'da mera sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.6 Mera sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Mera	Seçilen 6 Bant	42.53	69.92	79.73	81.59
	6 Bant + BDNVI	43.9	72.18	76.07	81.14
	6 Bant + GNDVI	43.14	68.03	77.13	79.81
	6 Bant + NDVI1	45.58	64.72	81.55	79.85
	6 Bant + NDVI2	41.62	72.61	79.42	81.41
	6 Bant + NDVIRE1			82.32	78.49
	6 Bant + NDVIRE2			81.86	84.3
	6 Bant + NDVIRE3			82.16	83.96

Çizelge 5.6’da Landsat-8 uydu görüntüsü üzerinden sınıflandırma işlemleri sırasında BNDVI, GNDVI ve NDVI1 indekslerinin üretici doğruluğuna, BNDVI ve NDVI2 indekslerinin ise kullanıcı doğruluğuna pozitif katkı yaptığı belirlenmiştir. Sentinel-2 uydu görüntüsü üzerinden yapılan sınıflandırma işlemlerinde ise üretici doğruluklarına NDVI1, NDVIre1, NDVIre2 ve NDVIre3 indekslerinin olumlu katkı sundukları görülmüştür. Kullanıcı doğruluğuna ise sadece NDVIre2 ve NDVIre3 indekslerinin olumlu katkı yaptığı görülmüştür. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu NDVI2 indeksinde, üretici doğruluğu ise NDVI1 indeksinde görülmüştür. Sentinel-2 uydu görüntüsü içinse en yüksek kullanıcı doğruluğu NDVIre2, üretici doğruluğunda ise NDVIre1 indeksinde tespit edilmiştir.

Çizelge 5.7’de Marjinal tarım sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.7 Marjinal tarım için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Marjinal Tarım	Seçilen 6 Bant	86.17	66.55	86.17	85.01
	6 Bant + BDNVI	87.31	67.14	86.4	83.08
	6 Bant + GNDVI	84.8	66.37	85.03	82.48
	6 Bant + NDVI1	81.6	66.67	84.23	85.6
	6 Bant + NDVI2	88.23	66.61	86.63	84.79
	6 Bant + NDVIre1			82.97	86.02
	6 Bant + NDVIre2			87.89	85.92
	6 Bant + NDVIre3			88	86.52

Landsat-8 uydu görüntüsü üzerinden yapılan sınıflandırma işlemlerinde üretici doğruluğuna BNDVI ve NDVI2 indekslerinin olumlu katkı yaptığı, kullanıcı doğruluğunda ise BNDVI, NDVI1 ve NDVI2 indekslerinin olumlu katkı yaptığı görülmüştür. Sentinel-2 uydu görüntüsü üzerinden yapılan sınıflandırma işlemlerinde ise üretici doğruluğuna NDVI2, NDVIre2 ve NDVIre3 indekslerinin pozitif katkı yaptığı görülmüştür. Kullanıcı doğruluğuna ise NDVI1, NDVIre1, NDVIre2 ve NDVIre3 indekslerinin olumlu katkı yaptığı belirlenmiştir. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu BNDVI indeksinde, üretici doğruluğunda ise NDVI2 indeksinde görülmüştür. Sentinel-2 uydu görüntüsü içinse en yüksek kullanıcı doğruluğu ve üretici doğruluğu ise NDVIre3 indeksinde tespit edilmiştir.

Çizelge 5.8’de orman sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.8 Orman sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Orman	Seçilen 6 Bant	100	99.62	98.18	96.97
	6 Bant + BDNVI	100	99.33	94.41	97.32
	6 Bant + GNDVI	100	99.14	96.74	96.93
	6 Bant + NDVI1	100	99.43	97.03	96.66
	6 Bant + NDVI2	100	99.43	99.71	94.46
	6 Bant + NDVIRE1			97.22	95.21
	6 Bant + NDVIRE2			97.7	98.93
	6 Bant + NDVIRE3			97.99	98.65

Landsat-8 uydu görüntüsü üzerinden yapılan sınıflandırma işlemlerinde; üretici doğrulunda bir değişiklik olmazken tüm değerler %100 çıkmıştır. Kullanıcı doğruluğunda ise indekslerin herhangi bir pozitif katkısı görülmemiştir. Sentinel-2 uydu görüntüsü üzerinden yapılan sınıflandırma işlemlerinde ise; üretici doğruluğunda sadece NDVI2 indeksinin olumlu katkısı olmuştur. Kullanıcı doğruluklarında ise; BNDVI, NDVIre2 ve NDVIre3 indekslerinin olumlu katkısı görülmüştür. Landsat-8 uydu görüntüsü için en yüksek kullanıcı doğruluğu orijinal bantları görülmüştür. Üretici doğruluğunda ise tüm değerler maksimumdadır. Sentinel-2 uydu görüntüsü içinse en yüksek kullanıcı doğruluğu NDVIre2 indeksinde, üretici doğruluğu ise NDVI2 indeksinde tespit edilmiştir.

Çizelge 5.9’da su yüzeyi sınıfı için indeks etkileri belirtilmiştir.

Çizelge 5.9 Su yüzeyi sınıfı için indeks etkileri.

Sınıf	İndeks	Landsat-8		Sentinel-2	
		Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu
Su yüzeyi	Seçilen 6 Bant	100	100	100	100
	6 Bant + BDNVI	100	100	100	100
	6 Bant + GNDVI	100	100	100	100
	6 Bant + NDVI1	100	100	100	100
	6 Bant + NDVI2	100	100	100	100
	6 Bant + NDVIRE1			100	100
	6 Bant + NDVIRE2			100	100
	6 Bant + NDVIRE3			100	100

Su yüzeyi için yapılan sınıflandırma işlemlerin tümünde doğruluk oranları %100 çıkmıştır.

Öte yandan, hata matrisleri incelendiğinde; mera ve marjinal tarım sınıfının karıştığı fakat Sentinel-2 uydusunun özellikle kırmızı kenar bantları sayesinde bu iki sınıfta birbirinden yüksek oranda ayrıştığı tespit edilmiştir.





BÖLÜM 6

SONUÇ VE ÖNERİLER

Uzaktan algılama teknolojisi, uzay teknolojilerin gelişmesi ile birlikte hayatımıza girmiştir. Dünyanın hemen her yerinde, birçok çalışma için kullanılmaktadır. Gelişen teknoloji ile birlikte uzaktan algılama teknolojilerin yetenekleri gelişmekte ve buna bağlı olarak çalışmalarda kullanım oranı ve doğru sonuç verme oranları artmaktadır. Deniz kirliliği tespiti, orman tahribatı tespiti, kentleşme yoğunluğu, tarım alanları takibi gibi birçok alanda kullanılmaktadır.

Bu çalışmada güncel arazi kullanım haritasının oluşturulması için Sentinel-2 uydusu ve Landsat-8 uydusunun görüntüleri kullanılmıştır. Uyduların orijinal bantları haricinde katkısı beklenen indekslerde eklenerek doğrulukları değerlendirilmiş ve karşılaştırılmıştır.

Çalışmada sınıflandırma yöntemlerinden piksel tabanlı destek vektör makineleri sınıflandırma yöntemi kullanılmıştır. Sınıflandırmada ele alınan 7 adet sınıf, kendilerine ait spektral özelliklerine göre sınıflandırılmıştır. Landsat-8 uydu görüntüsü üzerinden indeks eklenmeden sınıflandırma yapıldığında % 88,82'lik bir genel doğruluk değeri tespit edilmiştir. Sentinel-2 uydu görüntüsü üzerinden indeks eklenmeden sınıflandırma işlemi yapıldığında ise genel doğruluk oranı % 93,07 çıkmıştır.

Çalışmada, uyduların orijinal bantları yanına bazı indeksler eklenmiştir. Eklenen indekslerin arazi kullanım sınıflarının belirlenmesinde olumlu katkıları olacağı düşünülmüştür. Eklenen indeksler; BNDVI, GNDVI, NDVI1, NDVI2, NDVIre1, NDVIre2 ve NDVIre3 indeksleridir. Sentinel-2 uydu görüntüsü için; NDVI1, NDVIre2 ve NDVIre3 indekslerinin genel doğruluğu arttırdığı gözlemlenmiştir. En iyi sonucu ise % 94,10'luk doğruluk oranıyla NDVIre3 indeksi vermiştir. Landsat-8 uydu görüntüsü içinse; GNDVI, NDVI1 ve NDVI2 indekslerinin genel doğruluğu arttırdığı gözlemlenmiştir. En iyi sonucu ise % 89,17'lik oranıyla NDVI2 indeks vermiştir. Genel anlamda bakıldığında normalize edilmiş fark bitki indeksleri ve kırmızı kenar indekslerin çoğunlukla genel doğruluğu arttırdığı görülmüştür.

Sınıf bazında doğruluk deęerlerine baktığımızda ise; su yüzeyi sınıfı her iki uydu görüntüsü içinde % 100'lük doğruluk oranına ulaşmıştır. Su yüzeyi sınıfı dışında tam doğruluęa en yakın sınıf; Sentinel-2 uydusu için % 99,71'lik oranıyla orman sınıfı olduęu belirlenmiştir. Landsat-8 uydusu içinse % 96,33'lük oranıyla mutlak tarım sınıfıdır.

Sonuç olarak Sentinel-2 ve Landsat-8 uydu görüntüsü piksel tabanlı sınıflandırma işlemiyle sınıflandırılmıştır. Orijinal bantları ile genel doğrulukları kıyaslanmış, buna ek olarak sınıf bazında kıyaslamalar ortaya konmuştur. Sınıflandırma sırasında spektral aralığı bitki türlerinden kolayca ayırt edilebilecek olan su yüzeyi sınıfı; genel doğrulukların ve sınıf bazı doğrulukların hepsinde tam ayrılabilen sınıf olarak karşımıza çıkmıştır. Çalışmada yer alan; mutlak tarım, dikili alan, mera, marjinal tarım ve orman sınıfı gibi bitki türlerinden oluşan sınıfların spektral özelliklerinin birbirine yakın olması negatif etki yaratsa da özellikle kırmızı kenar bantlarında kızılötesi bantlara göre daha iyi sonuç verdiği belirlenmiştir. Kırmızı kenar bantları karşılaştırıldığında B6 ve B7'nin B5'e göre daha fazla sınıfta doğruluęu artırdığı tespit edilmiştir.

KAYNAKLAR

- [1] **Yılmaz M** (2018) Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması İle Nesne-Tabanlı Sınıflandırılması. *Yüksek Lisans Tezi*, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, Ankara, 95 s.
- [2] **Özdoğan M, Woodcock C E** (2006) Resolution Dependent Errors In Remote Sensing Of Cultivated Areas. *Remote Sensing of Environment*, 103 (2): 203-217.
- [3] **Immitzer M, Vuolo F and Atzberger C** (2016) First Experience With Sentinel-2 Data For Crop And Tree Species Classifications In Central Europe. *Remote Sensing*, 8 (3): 166.
- [4] **URL-1** <http://www.irfanakar.com/turkish/sunumlar/UA_CBS/Uzaktan%20Alg%C3%BDlama%20ERDAS%20Bilgi/uydu_goruntulerinin_siniflandirilmesi_dogruluk_analizi.PDF>, Ziyaret tarihi: 08.07.2017.
- [5] **Kavzoglu T, Colkesen I** (2009) A Kernel Functions Analysis For Support Vector Machines For Land Cover Classification. *International Journal of Applied Earth Observation and Geoinformation*, 11 (5): 352-359.
- [6] **Dixon B, Candade N** (2008) Multispectral Land Use Classification Using Neural Networks And Support Vector Machines: One Or The Other, Or Both?. *International Journal of Remote Sensing*, 29 (4): 1185-1206.
- [7] **Srivastava P K, Han D, Rico-Ramirez M A, Bray M, Islam T** (2012) Selection Of Classification Techniques For Land Use/Land Cover Change Investigation. *Advances in Space Research*, 50 (9): 1250-1265.
- [8] **Petropoulos G P, Arvanitis K, Sigrimis N** (2012) Hyperion Hyperspectral Imagery Analysis Combined With Machine Learning Classifiers For Land Use/Cover Mapping. *Expert Systems with Applications*, 39 (3): 3800-3809.
- [9] **Schuster C, Förster M, Kleinschmit B** (2012) Testing The Red Edge Channel For Improving Land-Use Classifications Based On High-Resolution Multi-Spectral Satellite Data. *International Journal of Remote Sensing*, 33 (17): 5583-5599.
- [10] **Eitel J U H, Vierling L A, Litvak M E, Long D S, Schulthess U, Ager A A, Krofchech D J, Stoscheck L** (2011) Broadband, Red-Edge Information From Satellites Improves Early Stress Detection In A New Mexico Conifer Woodland. *Remote Sensing of Environment*, 115 (12): 3640-3646.

KAYNAKLAR (devam ediyor)

- [11] **Löw F, Michel U, Dech S, Conrad C** (2013) Impact Of Feature Selection On The Accuracy And Spatial Uncertainty Of Per-Field Crop Classification Using Support Vector Machines. *ISPRS Journal of Photogrammetry and Remote Sensing*, 85: 102-119.
- [12] **Üstüner M** (2013) Destek Vektör Makineleri Yöntemi İle Arazi Kullanımı Sınıflandırılmasında Kernel Fonksiyonlarına Ait Karşılaştırmalı Parametre Duyarlılık Analizi: Rapideye ve Spot Örneği. *Yüksek Lisans Tezi*, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı, İstanbul, 74 s.
- [13] **Delen A** (2017) Ürün Deseni Belirlenmesinde Farklı Bitki Örtüsü İndekslerinin Etkilerini Piksel ve Nesne Tabanlı Sınıflandırma Örneğinde Analizi. *Yüksek Lisans Tezi*, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı, İstanbul, 80 s.
- [14] **Kalem E** (2014) Piksel ve Nesne Tabanlı Sınıflandırma Açısından GÖKTÜRK 2 Görüntüsünün Değerlendirilmesi: İstanbul Boğazı Örneği. *Yüksek Lisans Tezi*, Hava Harp Okulu Havacılık ve Uzay Teknolojileri Enstitüsü, Uzay Bilimleri Anabilim Dalı, İstanbul, 91 s.
- [15] **Abdikan S, Narin Ö, Delen A** (2018) SENTİNEL-2A Verisi Kullanarak Tarımsal Ürün Deseninin Belirlenmesi. *Uzaktan Algılama-CBS Sempozyumu*, 18-21 Eylül 2018, Eskişehir
- [16] **Çölkesen İ** (2009) Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi. *Yüksek Lisans Tezi*, Gebze Yüksek Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, Gebze, 168 s.
- [17] **URL-2** <<https://haritaonline.blogspot.com/2015/05/aktif-ve-pasif-alglayclar.html>> , Ziyaret tarihi: 20.07.2017
- [18] **Ayhan E** (2003) Harita Mühendisliği, KTÜ Uzaktan Algılama Ders Notları, Karadeniz Teknik Üniversitesi, Trabzon.
- [19] **Yener H, Koç A ve Çoban O** (2005) Uzaktan Algılama Verileri ve Teknik Özellikleri, *Harita Dergisi*, 34-38.
- [20] **Rende F Ş** (2009) Aşamalı Öğrenmeli Destek Vektör Makineleri ile Hiperspektral Görüntülerin Sınıflandırılması. *Yüksek Lisans Tezi*, Gebze İleri Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Gebze, 96 s.
- [21] **URL-3** <http://www.hvkk.tsk.tr/Havacılık_kösesi/Özel_Siteler/Keşif_Uydu_Komutanlığı/Genel_Bilgiler/Çözünürlük_Değeri> , Ziyaret tarihi: 10.06.2018.

KAYNAKLAR (devam ediyor)

- [22] **Gibson, P** (2000) *Introductory Remote Sensing Principles and Concepts*. Routledge, London, 167-170.
- [23] **Akkartal F A** (2007) Denizlerdeki Yağ Tabakasının İzlenmesinde Radar Uydu Görüntülerinin Kullanımı. *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, İstanbul, 159 s.
- [24] **Çölkesen İ** (2009) Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi. *Yüksek Lisans Tezi*, Gebze Yüksek Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, Gebze, 168 s.
- [25] **URL-4** <http://www.hvkk.tsk.tr/Havacılık_köşesi/Özel_Siteler/Keşif_Uydu_Komutanlığı/Genel_Bilgiler/Çözünürlük_Değeri>, Ziyaret tarihi: 25.06.2018.
- [26] **Kayman Ö** (2015) Spektral İndekslerin Arazi Örtüsü/Kullanımı Sınıflandırmasına Etkisi: İstanbul Beylikdüzü İlçesi, Arazi Kullanımı Değişimi. *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, İstanbul, 123 s.
- [27] **Marangoz A M** (2009) Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve CBS Ortamında Bütünleştirilmesi. *Doktora Tezi*, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, İstanbul 133 s.
- [28] **Kansu O** (2006) Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri Analizi. *Yüksek Lisans Tezi*, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, Trabzon, 136 s.
- [29] **Çölkesen İ** (2015) Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme. *Doktora Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, İstanbul, 276 s.
- [30] **Huang C, Davis L S, Townshend R G** (2002) An Assessment Of Support Vector Machines For Land Cover Classification. *International Journal of Remote Sensing*, 23 (4): 725-749.
- [31] **Evsahibioglu N A** (1993) Tübitak Marmara Araştırma Merkezi Uzay Bilimleri Teknolojisi Bölümü Uzaktan Algılama Temel Eğitimi Kurs Notları, 3-7 Mayıs, Gebze.
- [32] **Kavzoglu T, Mather, P M** (2003) The Use of Backpropagating Artificial Neural Networks in Land Cover Classification. *International Journal of Remote Sensing*, 24: 4907-4938.
- [33] **Silahtaroglu G** (2013) *Veri Madenciliği Kavram ve Algoritmaları*, Papatya Yayınevi, 46-59.

KAYNAKLAR (devam ediyor)

- [34] **Safavian S R and Landgrebe D** (1991) A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21 (3): 660–674.
- [35] **Melgani F and Bruzzone L** (2004) Classification Of Hyperspectral Remote Sensing Images With Support Vector Machines. *IEEE Transactions On Geoscience And Remote Sensing*, 42 (8): 1778–1790.
- [36] **Vapnik V N** (1995) *The Nature Of Statistical Learning Theory*. Springer-Verlag, New York, 138-167.
- [37] **Mathur A and Foody G M** (2008) Multiclass And Binary SVM Classification: Implications For Training And Classification Users. *IEEE Geoscience and Remote Sensing Letters*, 5 (2): 241-245.
- [38] **Mathur A and Foody G M** (2008) Crop Classification By Support Vector Machine With Intelligently Selected Training Data For An Operational Application. *International Journal of Remote Sensing*, 29(8): 2227-2240.
- [39] **Song X, Duan Z and Jiang X** (2011) Comparison Of Artificial Neural Networks And Support Vector Machine Classifiers For Land Cover Classification In Northern China Using A SPOT-5 HRG Image. *International Journal Of Remote Sensing*, 33(10): 3301-3320.
- [40] **Yang, X** (2011) Parameterizing Support Vector Machines For Land Cover Classification. *Photogrammetric Engineering And Remote Sensing*, 77 (1): 27–37.
- [41] **Yurtseven H** (2014) Yüksek Çözünürlüklü Uydu Verileri İle Obje Tabanlı Görüntü Analizleri. *Doktora Tezi*, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Orman Mühendisliği Anabilim Dalı, İstanbul, 150 s.
- [42] **UBM** (2001) Köy Hizmetleri Genel Müdürlüğü Toprak Ve Su Kaynakları Ulusal Bilgi Merkezi, Uzaktan Algılama Teknikleri Kullanılarak Arazi Kullanım Sınıfları Tespiti Çalışması, Ankara, 52-53.
- [43] **Abdikan S, Şanlı F, Üstüner M, Esetlili T, Kurucu Y** (2014) Kırmızı-Kenar ve Yakın Kızılötesi Bantlarının Ürün Deseni Sınıflandırma Doğruluğuna Olan Etkisinin Araştırılması: RapidEye Örneği. *Uzaktan Algılama-CBS Sempozyumu*, 14-17 Ekim 2014, İstanbul
- [44] **Abdikan S, Şanlı F ve Üstüner M** (2016) Bitki Örtüsü İndekslerinin Tarımsal Ürün Deseni Tespitindeki Etkisinin Araştırılması. *Uzaktan Algılama-CBS Sempozyumu*, 5-7 Ekim 2016, Adana, 271-274.
- [45] **URL-5** <<http://www.izto.org.tr/tr/izmir-tarim>>, Ziyaret tarihi: 15.08.2018.
- [46] **URL-6** <https://tr.m.wikipedia.org/wiki/Dosya:Latrans-Turkey_location_%C4%B0zmir.svg>, Ziyaret tarihi: 18.08.2018.

KAYNAKLAR (devam ediyor)

[47] URL-7 <<https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-2>>, Ziyaret tarihi: 11.10.2018.

[48] URL-8 <<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/>>, Ziyaret tarihi: 14.12.2018.

[49] URL-9 <<https://eos.com/landsat-8/>>, Ziyaret tarihi: 16.12.2018.





ÖZGEÇMİŞ

Furkan Gökhan CESUR 1989’da Sakarya’nın Adapazarı İlçesinde doğdu. İlk ve orta okulu aynı ilçede tamamladı. Serdivan Anadolu Lisesinden mezun olduktan sonra 2009 yılında Zonguldak Bülent Ecevit Üniversitesi, Geomatik Mühendisliği Bölümünü kazandı. 2013 yılında mezun olarak özel bir firmada harita mühendisi olarak çalışmaya başladı. Askerliğini tamamladıktan sonra, 2014 yılında Sakarya Su ve Kanalizasyon İdaresinde harita mühendisi olarak çalışmaya başladı ve halen aynı işyerinde çalışmaya devam etmektedir.

ADRES BİLGİLERİ

Tel: (+90) 554 232 48 78

E-posta: fgcesur@gmail.com