



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**JEODEZİ VE COĞRAFI BİLGİ SİSTEMLERİ
ANABİLİM DALI**

**TARIMSAL ALANLARDA IKONOS UYDU GÖRÜNTÜSÜNDEN
NESNE TABANLI ÜRÜN DESENİ TESPİTİ**

YÜKSEK LİSANS TEZİ

Beste TAVUS

DANIŞMAN

Yrd. Doç. Dr. Kamil KARATAŞ

AKSARAY, 2017



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**JEODEZİ VE COĞRAFI BİLGİ SİSTEMLERİ
ANABİLİM DALI**

**TARIMSAL ALANLARDA IKONOS UYDU GÖRÜNTÜSÜNDEN
NESNE TABANLI ÜRÜN DESENİ TESPİTİ**

YÜKSEK LİSANS TEZİ

Beste TAVUS

DANIŞMAN

Yrd. Doç. Dr. Kamil KARATAŞ

AKSARAY, 2017

AKSARAY ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ


ONAY BELGESİ

Aksaray Üniversitesi, Fen Bilimleri Enstitüsü'nün 142332401 numaralı Yüksek Lisans öğrencisi, "Beste TAVUS", ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "TARIMSAL ALANLARDA İKONOS UYDU GÖRÜNTÜSÜNDEN NESNE TABANLI ÜRÜN DESENİ TESPİTİ" başlıklı tezini, aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı: Yrd. Doç. Dr. Kamil KARATAŞ
Aksaray Üniversitesi

Jüri Üyeleri: Prof. Dr. Mustafa TÜRKER
Hacettepe Üniversitesi

Jüri Üyeleri: Prof. Dr. Hacı Murat YILMAZ
Aksaray Üniversitesi



Teslim Tarihi: 07 Kasım 2017

Savunma Tarihi: 01 Aralık 2017

ÖNSÖZ

Günümüzde, uydu görüntülerinin çözünürlükleri artmış ve bu durum, uydu görüntülerinin içerdiği zengin veriden en iyi şekilde yararlanmak için yardımcı veriler ile birlikte farklı yaklaşımlar ile değerlendirilmesi gerekliliğini meydana getirmiştir.

Bu çalışma, Aksaray Üniversitesi Fen Bilimleri Enstitüsü Jeodezi ve Coğrafi Bilgi Sistemleri Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır. Çalışmada, günümüzde, sıklıkla tercih edilen sınıflandırma yöntemlerinden biri olan nesne tabanlı sınıflandırma yöntemi ile yüksek çözünürlüklü uydu görüntüsünden güvenilir ve hızlı bir şekilde veri elde edilmesi ve bu verilerin kullanılabilirliğini belirlemek amacıyla doğruluklarının değerlendirilmesi amaçlanmıştır. Bu amaç doğrultusunda, yüksek çözünürlüklü IKONOS uydu görüntüsü ve oluşturulan yardımcı veriler nesne tabanlı sınıflandırma yöntemi kullanılarak sınıflandırılmıştır. Sınıflandırma sonuçları, yer gerçeği verileri ile kontrol edilerek doğruluk analizi yapılmıştır.

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu ve bu eserleri her kullanışmada alıntı yaparak yararlandığımı belirtir; bunu şerefimle doğrularım.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

Beste TAVUS

İmza

TEŞEKKÜR

Lisans ve yüksek lisans eğitimim boyunca bilgi ve tecrübeleri ile bana destek olan, teşvik ve yönlendirmeleriyle katkı sağlayan danışman hocam Yrd. Doç. Dr. Kamil KARATAŞ'a,

Tez çalışmam süresince, engin bilgileri, yönlendirme ve teşvikleriyle çalışmama büyük katkısı olan saygıdeğer hocam Prof. Dr. Mustafa TÜRKER'e,

Yardımlarını esirgemeyen değerli hocam Prof. Dr. Hacı Murat YILMAZ'a,

Hayatım boyunca yanımda olan ve benim için her türlü fedakârlıkta bulunan annem Emine TAVUS ve babam Cemal TAVUS'a,

Pozitif bakış açısı ve enerjisi ile desteğini her zaman hissettiğim kardeşim Nur TAVUS'a,

Benden desteklerini hiç esirgemeyen teyzem ve dayım başta olmak üzere ailemin diğer fertlerine ve değerli arkadaşlarıma çok teşekkür ederim.

Beste TAVUS

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	i
DOĞRULUK BEYANI.....	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
ÖZET.....	vi
ABSTRACT	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
SİMGELER DİZİNİ	xi
KISALTMALAR DİZİNİ	xii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	3
3. UZAKTAN ALGILAMA	11
3.1 Sayısal Görüntü ve Özellikleri	12
3.2 Görüntü Yorumlama Elemanları	14
3.2.1 Ton	15
3.2.2 Şekil	15
3.2.3 Boyut	15
3.2.4 Desen.....	15
3.2.5 Doku.....	16
3.2.6 Gölge	16
3.2.7 Komşuluk ilişkileri.....	16
4. UZAKTAN ALGILAMADA SINIFLANDIRMA YÖNTEMLERİ.....	17
4.1 Kontrolsüz sınıflandırma.....	19
4.2 Kontrollü sınıflandırma	20
4.2.1 En büyük benzerlik yöntemi	21
4.2.2 En kısa mesafe yöntemi	22
4.2.3 Paralelkenar yöntemi.....	23
4.3 Sınıflandırmada Yardımcı Veri Kullanımı.....	24
4.4 Doku Ölçüm Yöntemleri.....	27
4.4.1 GLCM homojenlik	30
4.4.2 GLCM zıtlık	30
4.4.3 GLCM farklılık	30
4.4.4 GLCM entropi.....	30
4.4.5 GLCM ortalama	31
4.4.6 GLCM varyans.....	31
5. NESNE TABANLI SINIFLANDIRMA	32
5.1 Segmentasyon İşlemi	34
5.2 Definiens eCognition Yazılımında Kullanılan Segmentasyon Algoritmaları..	35
5.2.1 Yukarıdan aşağıya segmentasyon algoritmaları	36

5.2.1.1 Santranç tahtası segmentasyonu.....	36
5.2.1.2 Dörtlü ağaç segmentasyonu	36
5.2.1.3 Kontrast filtreleme segmentasyonu.....	37
5.2.1.4 Kontrast bölme segmentasyonu	38
5.2.2 Aşağıdan yukarıya segmentasyon algoritmaları	39
5.2.2.1 Çok çözünürlüklü segmentasyon	39
5.2.2.2 Çok eşikli segmentasyon.....	42
5.2.2.3 Spektral fark segmentasyonu	43
5.3 Nesne Bazında En Yakın Komşuluk Sınıflandırması	43
5.4 Sınıflandırma Sonuçlarının Değerlendirilmesi	44
6. YÖNTEM.....	47
6.1 Çalışma Alanı.....	47
6.2 Kullanılan Veri ve Yazılımlar	48
6.3 Yöntem.....	51
6.4 Yardımcı Verilerin Oluşturulması.....	53
6.5 Segmentasyon İşlemi	55
6.5.1 ESP yöntemi ile ölçek parametresinin belirlenmesi	57
6.5.2 Deneme yanılma yaklaşımı ile tüm segmentasyon parametrelerinin belirlenmesi	59
6.6 Sınıfların ve Eğitim Verilerinin Belirlenmesi	66
6.7 Segmentlerin Sınıflandırılması ve Sınıflandırma Sonrası İşlemler.....	68
6.8 Sınıflandırılmış Görüntünün Doğruluk Analizi	72
7. SONUÇLAR VE ÖNERİLER	76
KAYNAKLAR	81
ÖZGEÇMİŞ.....	86

ÖZET

TARIMSAL ALANLARDA IKONOS UYDU GÖRÜNTÜSÜNDEN NESNE TABANLI ÜRÜN DESENİ TESPİTİ

Günümüzde uzaktan algılama teknolojileri ve görüntü değerlendirme yöntemlerinin gelişmesi ile birlikte, uzaktan algılama yöntemleri, tarımsal alanlarda ürün deseninin belirlenmesi ve zamana bağlı olarak değişiminin izlenmesi çalışmalarında sıklıkla tercih edilir hâle gelmiştir.

Bu çalışmada keskinleştirilmiş yüksek konumsal çözünürlüklü IKONOS uydu görüntülerinden tarımsal alanlarda ürün deseninin, nesne-tabanlı sınıflandırma tekniği ile yüksek doğrulukla belirlenmesi hedeflenmiştir. Çalışma alanı, Marmara bölgesinde bulunan Bursa ili, Karacabey ilçesinin güneybatısında yer almakta ve yaklaşık 18 km × 13.5 km'lik bir tarım alanını kapsamaktadır. Domates, mısır, biber, buğday, pirinç ve şeker pancarı bölgede yetiştirilen başlıca tarım ürünleridir.

Yöntemde izlenen temel adımlar şu şekildedir; (i) Yapılacak segmentasyon işlemi için uygun parametrelerin belirlenmesi, (ii) Sınıfların belirlenmesi, (iii) Yardımcı verilerin oluşturulması, (iv) Çok çözünürlüklü segmentasyon işlemi, (v) Eğitim alanlarının seçilmesi, (vi) Sınıflandırma işlemi, (vii) Sınıflandırma sonrası işlemler, (viii) Referans parsellerin ağırlık merkezlerinin belirlenmesi ve (ix) Doğruluk analizidir.

Nesne tabanlı sınıflandırmanın segmentasyon basamağında ölçek parametresinin belirlenmesini hızlandırmak ve otomatikleştirmek için ESP-2 (Ölçek Parametre Tahmini) yazılımı kullanılmıştır. Ayrıca, en uygun segmentasyon parametrelerin bulunması amacıyla şekil, bütünlük ve ölçek parametreleri için çeşitli kombinasyonlar denenmiştir. Sınıflandırma doğruluğunu arttırmak amacıyla, literatürde de sıklıkla kullanılmış olan homojenlik, zıtlık, farklılık, ortalama, varyans ve entropi olmak üzere altı adet GLCM doku ölçüm yöntemi belirlenmiştir. Bu yöntemler IKONOS uydu görüntüsünün orijinal bantlarına uygulanarak 24 bantlık ek veri seti elde edilmiştir. Orijinal bantlar ve elde edilen 24 bantlık ek veri seti ile birlikte toplam 29 bant kullanılarak, görüntü sınıflandırması işlemi eCognition yazılımında nesne tabanlı en yakın komşuluk sınıflandırması tekniği ile yapılmıştır. Elde edilen sınıflandırma sonuçları 2212 adet yer gerçeği verisi kullanılarak parsel bazında test edilmiştir. Yapılan doğruluk analizinde sınıflandırma sonuçları ile yer gerçekleri verilerinin %87.48 (toplam doğruluk) oranında uyumlu olduğu görülmüştür.

Anahtar Kelimeler: Segmentasyon, Nesne Tabanlı Sınıflandırma, IKONOS Uydu Görüntüsü, Uzaktan Algılama, Bursa, Karacabey.

ABSTRACT

OBJECT-BASED CROP PATTERN DETECTION FROM IKONOS SATELLITE IMAGES IN AGRICULTURAL AREAS

Nowadays, with the development of remote sensing technologies and image evaluation methods, remote sensing methods have become frequently preferred in studies to determine the crop pattern in agricultural areas and to monitor the change depending in time.

In this study, it is aimed to detection the crop pattern in agricultural areas with high accuracy by using object-based classification technique from high spatial resolution IKONOS satellite images. The study area is located on the South-west of the Karacabey district of the Bursa province in the Marmara region and covers an area of nearly $18 \text{ km} \times 13.5 \text{ km}$. Tomato, corn, pepper, wheat, rice and sugar beet are the main products grown in the region.

The basic steps in the method are as follows; (i) Determining the appropriate parameters for the segmentation, (ii) Defining classes, (iii) Creation of ancillary data, (iv) Multi-resolution segmentation, (v) Selection of training areas, (vi) Classification, (vii) Post classification editing, (viii) Determination of the center of gravity of the reference parcels, (ix) Accuracy assesment.

The ESP-2 (Estimation of Scale Parameter) tool was used to accelerate and automate the determination of the scale parameter in the segmentation step of the object-based classification. Various combinations have been tried for shape and compactness parameters in order to find the optimal segmentation parameters. In order to increase classification accuracy, six GLCM texture measurement methods have been identified, including homogeneity, contrast, dissimilarity, mean, variance, and entropy, which are frequently used in the literature. These methods were applied to the original bands of the IKONOS satellite image and an additional data set of 24 bands was obtained. Using a total of 29 bands together with the original bands and the additional data set of 24 bands, the image classification process was performed using the object-based nearest neighbor classification technique in the eCognition software. The obtained classification results were tested on parcel basis using 2212 ground truth data. In the accuracy assessment performed, it was seen that classification results and ground truth data were coherent with 87.48% (total accuracy).

Keywords: Segmentation, Object-Based Classification, IKONOS Satellite Image, Remote Sensing, Bursa, Karacabey.

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1: Elektromanyetik spektrum (URL-1).	13
Şekil 3.2: Uydu görüntüsünün bilgisayar ortamında sayısal ifadesi.	14
Şekil 3.3: Görüntü yorumlama elemanları.	15
Şekil 3.4: Doku ve desen özellikleri.	16
Şekil 4.1: Görüntü sınıflandırma (URL-3).	17
Şekil 4.2: Görüntü sınıflandırma yöntemleri.	19
Şekil 4.3: Olasılık yoğunluk fonksiyonu (Lillesand vd., 2007).	22
Şekil 4.4: 1m konumsal çözünürlüklü IKONOS uydu görüntüsü (URL-4).	28
Şekil 4.5: Doku özellikleri kullanılmayan sınıflandırma sonucu.	28
Şekil 4.6: Doku özellikleri kullanılarak yapılan sınıflandırma sonucu.	29
Şekil 5.1: Nesne tabanlı sınıflandırma genel işlem akışı.	33
Şekil 5.2: eCognition yazılımında kullanılan segmentasyon algoritmaları.	35
Şekil 5.3: Satranç tahtası segmentasyonu.	36
Şekil 5.4: Dörtlü ağaç segmentasyonu.	37
Şekil 5.5: Dörtlü ağaç segmentasyon yapısı (Definiens User Guide, 2014).	37
Şekil 5.6: Kontrast filtreleme segmentasyonu.	38
Şekil 5.7: Kontrast bölme segmentasyonu.	39
Şekil 5.8: Üç seviyeli hiyerarşik ağ yapısı (Karakış, 2005).	39
Şekil 5.9: Homojenlik şartları (Definiens User Guide, 2014).	42
Şekil 5.10: NN üyelik fonksiyonu (Definiens User Guide, 2014).	44
Şekil 6.1: Çalışma alanının konumu.	47
Şekil 6.2: Çalışma alanı sınırları ve yerleşim merkezleri.	47
Şekil 6.3: Ürünlerin fenolojik özellikleri (Türker ve Özdarıcı, 2011).	48
Şekil 6.4: IKONOS uydu görüntüsü ve yer gerçeği verileri.	50
Şekil 6.5: Yöntem akış diyagramı.	51
Şekil 6.6: NDVI görüntüsü.	54
Şekil 6.7: Sınıflandırma işleminde kullanılan bazı doku bantları.	56
Şekil 6.8: ESP-2 yazılımı parametre ayarlama görüntüsü.	58
Şekil 6.9: Lokal varyans ve değişim oranı grafiği.	58
Şekil 6.10: ESP-2 ile elde edilen segmentasyon seviyeleri.	58
Şekil 6.11: Farklı parametreler sonucunda elde edilen segment sayıları.	60
Şekil 6.12: Ölçek 35. A ₃₅ =Şekil 0.5, Bütünlük 0.3; B ₃₅ =Şekil 0.6, Bütünlük 0.3; C ₃₅ =Şekil 0.7, Bütünlük 0.3; D ₃₅ =Şekil 0.5, Bütünlük 0.4; E ₃₅ =Şekil 0.6, Bütünlük 0.4; F ₃₅ =Şekil 0.7, Bütünlük 0.4; G ₃₅ =Şekil 0.5, Bütünlük 0.5; H ₃₅ =Şekil 0.6, Bütünlük 0.5; I ₃₅ =Şekil 0.7, Bütünlük 0.5.	61
Şekil 6.13: Ölçek 40. A ₄₀ =Şekil 0.5, Bütünlük 0.3; B ₄₀ =Şekil 0.6, Bütünlük 0.3; C ₄₀ =Şekil 0.7, Bütünlük 0.3; D ₄₀ =Şekil 0.5, Bütünlük 0.4; E ₄₀ =Şekil 0.6, Bütünlük 0.4; F ₄₀ =Şekil 0.7, Bütünlük 0.4; G ₄₀ =Şekil 0.5, Bütünlük 0.5; H ₄₀ =Şekil 0.6, Bütünlük 0.5; I ₄₀ =Şekil 0.7, Bütünlük 0.5.	62

Şekil 6.14: Ölçek 45. A ₄₅ =Şekil 0.5, Bütünlük 0.3; B ₄₅ =Şekil 0.6, Bütünlük 0.3; C ₄₅ =Şekil 0.7, Bütünlük 0.3; D ₄₅ =Şekil 0.5, Bütünlük 0.4; E ₄₅ =Şekil 0.6, Bütünlük 0.4; F ₄₅ =Şekil 0.7, Bütünlük 0.4; G ₄₅ =Şekil 0.5, Bütünlük 0.5; H ₄₅ =Şekil 0.6, Bütünlük 0.5; I ₄₅ =Şekil 0.7, Bütünlük 0.5.	63
Şekil 6.15: Ölçek 50. A ₅₀ =Şekil 0.5, Bütünlük 0.3; B ₅₀ =Şekil 0.6, Bütünlük 0.3; C ₅₀ =Şekil 0.7, Bütünlük 0.3; D ₅₀ =Şekil 0.5, Bütünlük 0.4; E ₅₀ =Şekil 0.6, Bütünlük 0.4; F ₅₀ =Şekil 0.7, Bütünlük 0.4; G ₅₀ =Şekil 0.5, Bütünlük 0.5; H ₅₀ =Şekil 0.6, Bütünlük 0.5; I ₅₀ =Şekil 0.7, Bütünlük 0.5.	64
Şekil 6.16: Ölçek parametresi için 40, şekil parametresi için 0.5 ve bütünlük parametresi için 0.3 değerleri kullanılarak gerçekleştirilen segmentasyon sonucu.	65
Şekil 6.17: a: İçinde çoklu ekim yapılmış parsel, b: İçinde kuyu bulunan parsel.	66
Şekil 6.18: Domates ve pirinç sınıflarının ekili olduğu parsellerden örnekler.	66
Şekil 6.19: Çalışma alanında belirlenen sınıflar.	67
Şekil 6.20: Seçilen eğitim alanları.	67
Şekil 6.21: Biber_2 ve Domates_2 sınıflarına ait histogramlar.	68
Şekil 6.22: Biber_2 ve Domates_3 sınıflarına ait histogramlar.	69
Şekil 6.23: Özellik uzayının tanımlanması.	70
Şekil 6.24: Sınıfların seçilmesi.	70
Şekil 6.25: Sınıflandırılmış bir görüntüye çoğunluk filtresi uygulaması (URL-6). ..	71
Şekil 6.26: Sınıflandırılmış bir görüntüye sınır temizleme uygulanması (URL-6)...	71
Şekil 6.27: Nesne-tabanlı yöntemle sınıflandırılmış uydu görüntüsü.	72
Şekil 6.28: Referans parsellerin seçilmesi işlemi.	73
Şekil 6.29: Referans noktalarının parsellerin ağırlık merkezine ötelenmesi.	74
Şekil 6.30: Referans verilerinin dağılımı.	74

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1: Uzaktan algılamanın kullanıldığı bilim dalları ve çalışma alanları (Kavzoğlu ve Çölkesen, 2011).	12
Çizelge 5.1: Kappa katsayısı yorumlama (Landis ve Koch, 1977).....	46
Çizelge 6.1: Parsellerin alanlarına göre dağılımı (Türker ve Özdarıcı, 2011).....	48
Çizelge 6.2: Ikonos uydu özellikleri (URL-5).....	49
Çizelge 6.3: Ikonos görüntü özellikleri (URL-5).	49
Çizelge 6.4: Görüntü nesneleri için tanımlanan özellikler.	53
Çizelge 6.5: Segmentasyon işleminde kullanılan parametre kombinasyonları.	60
Çizelge 6.6: Referans parsel sayıları.	72
Çizelge 6.7: Hata matrisi.	75
Çizelge 6.8: Üretici ve kullanıcı doğrulukları.	75

SİMGELER DİZİNİ

k	Kappa katsayısı
m	Metre
mm	Milimetre
nm	Nanometre
sn	Saniye
t	Transpoze fonksiyonu
μm	Mikrometre

KISALTMALAR DİZİNİ

CBS	Coğrafi Bilgi Sistemleri
ÇKS	Çiftçi Kayıt Sistemi
DN	Sayısal Değer
DVM	Destek Vektör Makineleri
EMS	Elektremanyetik Spektrum
ESP	Estimation Scale Parameter (Ölçek Parametre Tahmini)
GLCM	Gray Level Co-occurrence Matrix (Gri Seviye Eş-oluşum Matrisi)
GST	Jeoistatistiksel Semivariogram Doku
ISODATA	Iterative Self Organizing Data Analysis Technique (Kendini Yöneten Veri Analiz Tekniği)
İHA	İnsansız Hava Aracı
K	Kırmızı Bant
M	Mavi Bant
NDVI	Normalized Difference Vegetation Index (Normalize Edilmiş Fark Bitki İndeksi)
NIR	Near Wave Infrared (Yakın Kızılötesi)
NN	Nesne Bazında En Yakın Komşuluk (NN) Sınıflandırması
SAM	Sayısal Yükseklik Modeli
SOM	Self Organizing Map (Özdüzenleyici Haritalar)
VARI	Visible Atmospherically Resistant Index
Y	Yeşil Bant

1. GİRİŞ

Lillesand vd., (2007), “Uzaktan algılama, gözlem ve inceleme konusu olan obje, alan ya da olgu hakkında, onlarla doğrudan fiziksel bir temas olmadan, çeşitli algılama cihazları kullanılarak elde edilen verinin analiz edilmesi ile bilgi edinilmesi bilimi ve sanatı” (s. 1) olarak tanımlamaktadır. Uzaktan algılama teknolojisinin geniş alanlarda spektral, zamansal ve konumsal çözünürlükte veri sağlaması çeşitli disiplinlerde kullanım alanını önemli ölçüde genişletmiştir. Gün geçtikçe, yer gözlem uydularındaki gelişmeler, uydu sayısının artması, uzaktan algılama sistemlerinin gelişmesi ve yaygınlaşmasıyla beraber yerel ve küresel ölçekte arazi örtüsü/kullanım bilgilerini çok daha kolay, ucuz, hızlı ve güvenilir bir biçimde elde etmek mümkün hâle gelmiştir.

Uzaktan algılama birçok alanda veri elde etme kaynağı olarak kullanılmış ve son zamanlarda farklı görüntü analiz yöntemlerinin de geliştirilmesiyle özellikle arazi örtüsü/kullanımının belirlenmesi çalışmalarında sıklıkla tercih edilen bir kaynak olmuştur. Tarımsal ürün deseninin yüksek doğrulukla belirlenmesi ve zamansal değişiminin izlenmesi, bölgesel ve küresel anlamda sürdürülebilir tarım alanlarının etkin yönetimi için önemli bir gerekliliktir. Bu kapsamda, uzaktan algılama tarım ve bitki örtüsü ile ilgili çalışmalarda önemli bir veri sağlayıcısı olarak birçok çalışmada sıklıkla tercih edilmektedir (Shanahan vd. 2011, Conrad vd. 2010).

Uzaktan algılamada veri elde etmek için en yaygın kullanılan yöntemlerin başında otomatik görüntü sınıflandırma ve öznetelik bilgi çıkarımı gelmektedir. Son yıllarda uydu görüntülerinin konumsal ve spektral çözünürlüklerinin artması ve bilgisayar teknolojisinin gelişmesiyle birlikte yeni sınıflandırma yöntemlerinin/algoritmalarının geliştirilmesi ile görüntülerden daha hızlı ve kolay bir şekilde veri elde edilebilmektedir. Klasik piksel tabanlı sınıflandırma yöntemlerinde, piksellerin sadece gri değeri esas alındığından beklenen sınıflandırma sonuçları elde edilememektedir. Bu durum, bilgi-işlem teknolojilerinin gelişmesiyle birlikte mevcut görüntü sınıflandırma ve analiz yaklaşımlarının geliştirilmesi zorunluluğunu beraberinde getirmiştir. Dolayısıyla, günümüz görüntü işleme ve uzaktan algılama

teknolojilerinde, uzman tecrübesi ve bulanık mantık setlerini kullanan nesne tabanlı sınıflandırma yaklaşımları geliştirilmiş ve zamanla birçok çalışmada tercih edilen bir yöntem haline gelmiştir.

Nesne tabanlı sınıflandırma görüntüyü nesnelere ayırarak analiz eder ve görüntü nesnelerini şekil, renk, ölçü, desen, doku, gölge, içerik, komşuluk gibi özellikleri kullanarak yorumlar ve sınıflandırır. Genel olarak görüntülerde nesneleri birbirinden ayırmak ve yorumlamak için esas alınan özellikler, insanın görüntü algılama becerisi ile benzerlik gösterdiğinden dolayı, nesne tabanlı sınıflandırma doğal bir yöntem olarak yorumlanabilir.

Tarımsal ürün deseninin doğru bir şekilde belirlenmesi; görüntü özellikleri (düşük, orta ve yüksek konumsal çözünürlük; multispektral/hiperspektral), uygun bant seçimi, kullanılan veri analiz yöntemi (piksel tabanlı/nesne tabanlı sınıflandırma), eğitim verilerinin uygunluğu, ürün fenolojisi, çalışma alanının boyutu ve karmaşıklığı vb. etkenlere bağlıdır. Özellikle, arazi örtüsü sınıflarının ayırt edilebilirliğini artırmak amacıyla spektral bilgiye ek olarak ürün karakteristiği ve ekim şekillerinden dolayı oluşan doku özellikleri ve bitki endeksleri gibi yardımcı verilerin kullanılması birçok çalışmada sınıflandırma doğruluğunu arttırdığı görülmüştür (Conrad vd. 2010, Mialhea vd. 2015).

Bu tez çalışmasında, Marmara bölgesinde bulunan Bursa ili, Karacabey ilçesinin güneybatısında yaklaşık 18 km × 13.5 km'lik bir alanda keskinleştirilmiş IKONOS uydu görüntüsü kullanılarak nesne tabanlı sınıflandırma yaklaşımı ile ürün deseninin yüksek doğrulukta belirlenmesi amaçlanmıştır. Bunun için, IKONOS uydu görüntüsünün uygun parametre değerleri ile segmentasyonu yapılmış ve elde edilen segmentlere ait spektral, konumsal ve yapısal bilgiler kullanılarak görüntü sınıflandırılmıştır. Segmentasyon işleminde, ölçek parametresinin otomatik olarak belirlenmesi için ESP-2 yazılımı kullanılmış, şekil ve bütünlük parametreleri için çeşitli kombinasyonlar denenmiştir. Segmentasyon sonucunda elde edilen segmentlerin doku özellikleri sınıflandırma sürecine dâhil edilerek görüntü eCognition yazılımında sınıflandırılmıştır.

Elde edilen sınıflandırma sonuçları 2212 adet yer gerçeği verisi kullanılarak parsel bazında test edilmiştir.

2. LİTERATÜR ÖZETİ

Baatz ve Schape, (2000) tarafından yapılan çalışmada, segmentasyon işleminde önemli rol oynayan heterojenlik kriterinin belirlenmesi için nitel ve nicel ölçütler tanımlanarak, birçok problem ve veri türüne uyarlanabilen evrensel ve yüksek kaliteli bir çözüm önerilmiştir. Çalışmada, farklı veri setlerinin belirlenen parametre değerleriyle çok çözünürlüklü segmentasyonu yapılmıştır. Uygulama sonucunda; farklı veri setleri için çok çözünürlüklü segmentasyon algoritmasının kullanılabilir olduğu ve küçük ölçek parametresi seçiminin sonuçları olumlu yönde etkilediği sonucuna varılmıştır. Ayrıca, çok çözünürlüklü segmentasyonun yüksek doku içeren görüntüler üzerinde başarılı bir şekilde çalıştığı vurgulanmaktadır.

Benz vd., (2004) tarafından yapılan çalışmada, nesne tabanlı görüntü analizinin temel bileşenleri incelenmiş ve bulanık yöntemlerle entegrasyonu sağlanarak standart bir biçimde elde edilecek verilerin, coğrafi bilgi sistemlerine (CBS) aktarılmasında örnek olabilecek bir yöntem önerilmiştir. Segmentasyon işleminde ölçek parametresi değerinin belirlenmesi üzerinde durulmuş ve segment özelliklerinin tanımlanmasında doku ve sınıflar arası ilişkiler kullanılmıştır.

Shackelford ve Davis, (2003) tarafından yapılan çalışmada, piksel tabanlı bulanık sınıflandırma yaklaşımı üzerine kurulu kentsel arazi örtü sınıflarını belirlemek için yüksek çözünürlüklü uydu görüntülerinin nesne tabanlı sınıflandırmasına dayanan bir yaklaşım sunulmuştur. Hem spektral hem de konumsal bilgileri kullanan bulanık piksel tabanlı sınıflandırma yaklaşımı, maksimum olasılık sınıflandırma sonuçlarını %10 - %25 oranında iyileştirmiştir. Daha sonra, bulanık piksel tabanlı sınıflandırma sonuçlarının girdi olarak kullanılması ile segmente edilen görüntü, nesne tabanlı yöntemlerle sınıflandırılmıştır. Bu yöntem kullanılarak yapılan sınıflandırma sonucunda binalar, geçirgen olmayan yüzeyler ve yollar sırası ile %76, %81 ve %99 doğrulukla belirlenmiştir.

Xu vd., (2004) tarafından yapılan çalışmada, yüksek çözünürlüklü QuickBird uydu görüntüsü kullanılarak nesne tabanlı sınıflandırma yapılmıştır. Çok çözünürlüklü segmentasyon ile elde edilen görüntü nesnelerinin alan, şekil, uzunluk, doku özellikleri ve görüntü nesneleri arasındaki ilişkiler tanımlanarak sınıflandırma yapılmıştır. Sınıflandırma sonucunda, binalar ve parsel sınırları iyi derecede tanımlanmış, tarım ürünlerine ve yerleşim alanlarına ilişkin ayrıntılı detaylar elde edilmiştir. Sınıflandırmanın genel doğruluğu %82.7 olarak belirlenirken, tarım ürünler ve orman sınıfları, nadasa bırakılan alanlar ve yol sınıfları, konut ve yol sınıfları arasında hatalı sınıflandırmalar olduğu belirtilmiştir.

Förster ve Kleinschmit, (2005) tarafından yapılan çalışmada ormanlarda biyolojik çeşitliliğin tespiti ve izlenmesi için, yüksek çözünürlüklü QuickBird uydu görüntüsü kullanılarak nesne tabanlı sınıflandırma yapılmıştır. Sınıflandırma sürecinde yükseklik, eğim, toprak tipi gibi veriler yardımcı veri olarak kullanılmıştır. Çalışmada, yüksek çözünürlüklü uydu görüntülerinin orman haritalama ve izleme çalışmalarında güvenilir sonuçlar verdiği ve yardımcı veri kullanımının sınıflandırma sonuçlarını pozitif yönde etkilediği belirtilmiştir.

Brodskeye ve Boruvka, (2006) tarafından yapılan çalışmada, toprak alanları Landsat-7 uydu görüntüsünün nesne tabanlı yöntemler kullanılarak sınıflandırılmasıyla belirlenmiştir. Belirlenen üç tür toprak sınıfının tanımlanması için eCognition yazılımında yapılan nesne tabanlı sınıflandırma sonuçları, arazi verileriyle %72 oranında uyumlu olduğu tespit edilmiştir. Nesne tabanlı bulanık yöntemlerin toprak haritalarının üretilmesinde konumsal desenlerin çıkarılması için uygun bir teknik olduğu vurgulanmıştır. Ayrıca, yöntemin çeşitli raster ve vektör verilerle birlikte değerlendirilmesiyle sonuçların iyileştirilebileceği belirtilmiştir.

Griffith (2006) tarafından yapılan çalışmada, Landsat uydu görüntüsü kullanılarak su, tarım alanı, kırsal bölgeler ve geçirimsiz yüzey sınıfları nesne tabanlı sınıflandırma yöntemiyle belirlenmiştir. Uygun segmentasyon parametreleri ile çok çözünürlüklü segmentasyon yapılmış ve oluşturulan sınıf hiyerarşisi ile Nesne Bazında En Yakın Komşuluk (NN) sınıflandırıcısı kullanılmıştır. Sınıflandırma sonucunda spektral özelliklerinin farklı olmasından dolayı su ve geçirimsiz yüzey sınıflarının iyi bir şekilde ayrıldığı belirtilmiştir.

Carleer ve Wolff, (2006) tarafından yapılan çalışmada, kırsal ve kentsel alanlarda arazi örtüsünü belirlemek için kullanılacak yüksek çözünürlüklü uydu görüntülerinin alan bazlı sınıflandırma yönteminde potansiyeli belirlenmiştir. Kentsel alan için QuickBird uydu görüntüsü, kırsal alan için ise SPOT ve IKONOS uydu görüntüleri eCognition yazılımında segmente edilmiştir. Spektral, morfolojik ve doku özellikleri olmak üzere toplam 47 bantlık veri seti kullanılarak nesne bazında en yakın komşuluk sınıflandırması (NN) yapılmıştır. Sınıflandırma sonucunda, bitki örtüsü sınıfları 0.78, ekili olmayan tarım arazi sınıfları 0.48 ve bitki örtüsü olmayan sınıflar ise 0.82 kappa doğruluğu ile belirlenmiştir. Çalışmanın sonucunda, doku ve morfolojik özelliklerin sınıflandırmada avantaj sağladığı belirtilerek, uygun parametreler ile yapılan segmentasyon işleminin sınıflandırma sonucuna önemli katkıları olduğu vurgulanmıştır.

Mathieu vd., (2007) tarafından yapılan çalışmada, kentsel alanlarda bulunan bitki örtüsü sınıflarının belirlenmesinde IKONOS uydu görüntüsü kullanılarak yapılan nesne tabanlı sınıflandırmanın etkinliği test edilmiştir. Segmentasyon aşamasında uygun parametreler belirlenerek çok çözünürlüklü segmentasyon yapılmıştır. Sınıflandırma işleminde ticari binalar, konut alanları, bitki örtüsü ve su olmak üzere dört ana sınıf belirlenirken, bitki örtüsü sınıfı kendi içinde on adet alt sınıfa ayrılmıştır. Sınıflandırma sonucunda bitki örtüsü sınıfları %77 genel doğrulukla belirlenmiş ve bu yöntemle değerlendirilen yüksek çözünürlüklü uydu görüntülerinin ekolojik olarak önemli sınıfları belirlemede yeterli olduğu vurgulanmıştır.

Kim vd., (2008) tarafından yapılan çalışmada, IKONOS uydu görüntüsüne GLCM (Gray Level Co-Occurrence Matrix – gri düzey eş-oluşum matrisi) ile hesaplanan doku özellikleri eklenerek nesne tabanlı sınıflandırma yöntemi ile yaprak döken, sürekli yeşil kalan ve karışık orman sınıfları belirlenmiştir. Değişik parametreler kullanılarak yapılan segmentasyon sonuçları nesne tabanlı yöntemler ile sınıflandırılmıştır. Sonuçlar, segmentasyon işleminde kullanılan ölçek parametresinin doğrudan sınıflandırma sonucunu etkilediğini göstermiştir. Sınıflandırma sonucunun toplam doğruluğu %79 olarak belirlenirken, GLCM doku özellikleri kullanılarak yapılan nesne tabanlı sınıflandırmanın doğruluğu ise %83'e yükselmiştir.

Castillejo-González vd., (2009) multispektral ve keskinleştirilmiş QuickBird uydu görüntüleri kullanarak beş farklı piksel tabanlı sınıflandırma yöntemi ve nesne

tabanlı yöntemlerin doğruluğuna ilişkin bir çalışma yapmıştır. Piksel tabanlı sınıflandırma yöntemlerinden en doğru sınıflandırıcı en büyük benzerlik algoritması olarak belirlenirken, keskinleştirilmiş uydu görüntüsünün nesne tabanlı analizinin sonucu %4 oranında iyileştirdiği belirtilmiştir.

Lu vd., (2011) tarafından yapılan çalışmada, henüz yapılaşmaya başlayan kırsal bir alanda hem kentsel hem de kırsal bölgelere ait sınıflar QuickBird uydu görüntüsü kullanılarak nesne tabanlı sınıflandırma ile belirlenmiştir. Çalışmada, GLCM'den hesaplanan homejenlik, ortalama, farklılık ve varyans doku özellikleri kullanılarak yapılan nesne tabanlı sınıflandırma sonucunda %88 genel doğruluk elde edilmiştir. Aynı veriler kullanılarak yapılan maksimum benzerlik sınıflandırıcısı ile %75 genel doğruluk elde edilmiştir.

Robertson ve King, (2011) tarafından yapılan çalışmada, 1995 ve 2005 yıllarına ait Landsat uydu görüntülerini kullanarak kullanılarak arazi örtüsü/kullanım değişiminin belirlenmesi için piksel tabanlı ve nesne tabanlı sınıflandırma yöntemleri karşılaştırılmıştır. Çalışma alanında on yıl süresince meydana gelen değişimin, nesne tabanlı sınıflandırma sonuçlarına göre %49.2, piksel tabanlı sınıflandırma sonuçlarına göre %44.4 oranında olduğu belirlenmiştir. Nesne tabanlı sınıflandırma yöntemi ile elde edilen değişim oranınının doğruluğu %70 olarak belirlenmiştir.

Myint vd., (2011) kentsel alan sınıflarını hassas bir şekilde belirlemek için QuickBird görüntüsünün nesne tabanlı sınıflandırmasına dayanan bir çalışma yapmıştır. Segmentasyon işleminde uygun parametreler, farklı parametrelerle yapılan segmentasyon sonuçlarının görsel olarak değerlendirilmesi ile belirlenmiştir. Yeşil alan, ağaç, bina, geçirimsiz yüzeyler, göl, yüzme havuzu ve toprak sınıfları için, NDVI (Normalize Edilmiş Fark Bitki İndeksi) ve farklı bant oranlamaları üzerinden sınıfların ayırt edilmesini sağlayan aralıklar belirlenerek kural tabanlı sınıflandırma yapılmıştır. Nesne tabanlı sınıflandırma yöntemiyle elde edilen genel doğruluk %90.40 iken, en büyük benzerlik sınıflandırıcısı ile elde edilen genel doğruluk ise %67.60 olarak belirlenmiştir.

O'Connell vd., (2015) tarafından yapılan çalışmada, 0.5 m konumsal çözünürlüklü hava fotoğrafı kullanılarak yapılan nesne tabanlı görüntü analizi ile farklı özellikleri içeren üç farklı sınıflandırma modeli önerilmiştir. ESP yazılımı ile ölçek parametresi belirlenmiş ve çok çözünürlüklü segmentasyon ile elde edilen segmentler farklı

özellikler kullanılarak sınıflandırılmıştır. Nesne tabanlı rastgele orman sınıflandırma algoritması ile sınıflandırma sonuçları üç model için sırasıyla %88, %90 ve %86 olarak belirlenmiştir.

Goodin vd., (2015) tarafından yapılan çalışmada, karmaşık tarım arazilerinde Landsat uydu görüntüsü kullanılarak hem arazi örtüsü hem de arazi kullanımını belirlemek için, nesne tabanlı ve piksel tabanlı sınıflandırma sonuçları nicel olarak karşılaştırılmıştır. Yapılan segmentasyon ile oluşan görüntü nesnelerinin kalitesi %60 olarak belirlenmiş ve bu segmentler üzerinden destek vektör makinaları (DVM) algoritmasıyla nesne tabanlı sınıflandırma yapılmıştır. Görüntü nesnelerinin spektral, konumsal ve geometrik özellikleri kullanılarak yapılan nesne tabanlı sınıflandırma sonucunun toplam doğruluk değeri %75 olarak belirlenmiştir. Ancak, bu özelliklerin ayrı ayrı kullanılması ile yapılan nesne tabanlı sınıflandırma sonuçlarının piksel tabanlı yöntemle elde edilen sınıflandırma sonucuyla benzerlik gösterdiği belirtilmiştir.

Singha vd., (2016) tarafından yapılan çalışmada, spektral, konumsal ve fenolojik özelliklerin birlikte kullanılması ile pirinç tarlaları için nesne tabanlı bir görüntü analiz yaklaşımı sunulmaktadır. Çok çözünürlüklü segmentasyon ile elde edilen görüntü nesneleri bitki örtüsü endeksleri kullanılarak NN algoritması ile sınıflandırılmıştır. Önerilen nesne tabanlı görüntü analizi yaklaşımı sonucunda toplam doğruluk %93 olarak belirlenmiştir. Ayrıca, fenolojik özelliklerin kullanılmasının, sınıflandırma doğruluğunu %2-%4 arasında iyileştirdiği belirtilmiştir.

Watmough vd., (2017) tarafından yapılan çalışmada, heterojen yapılı kırsal arazilerin nesne tabanlı yöntemlerle sınıflandırılması için QuickBird ve GeoEye uydu görüntüleri kullanılarak iki aşamalı bir sınıflandırma yaklaşımı sunulmuştur. Bu yaklaşımda, sınıflandırmanın ilk bölümünde, su, yollar ve binalar gibi farklı spektral ve konumsal özelliklere sahip nesnelere odaklanılırken, sınıflamanın ikinci bölümünde ise, benzer özelliklere sahip farklı bitki örtüsü nesnelere odaklanılmıştır. Sınıflandırmanın toplam doğruluğu %90 olarak belirlenirken tarım alanlarının diğer sınıflardan daha düşük doğrulukta olduğu belirlenmiştir.

Bu tez çalışmasının da konusu olan, nesne tabanlı sınıflandırma yöntemleri ile ürün deseninin belirlenmesi ile ilgili literatürde yer alan çalışmalar şunlardır;

Bock vd., (2005) tarafından yapılan çalışmada, iki farklı test alanında, 30m konumsal çözünürlüğe sahip Landsat ve 0.7m konumsal çözünürlüğe sahip QuickBird uydu görüntüleri ve yardımcı veriler kullanılarak nesne tabanlı sınıflandırma yöntemi ile sekiz adet bitki örtüsü sınıfı belirlenmiştir. QuickBird uydu görüntüsü kullanılarak yapılan sınıflandırma sonuçları %81 genel doğrulukla belirlenmiştir. Çalışma sonucunda, düşük doğrulukta bitki örtüsü sınıflarını belirlemek için Landsat uydu görüntüsünün yeterli olduğu, daha yüksek doğrulukta bitki örtüsü sınıflarını belirlemek için ise yüksek çözünürlüklü QuickBird uydu görüntüsünün oldukça iyi performans gösterdiği belirtilmiştir.

Yu vd., (2006) tarafından yapılan çalışmada, DAIS uydu görüntüsü kullanılarak 43 bitki örtüsü sınıfı nesne tabanlı sınıflandırma yöntemiyle belirlenmiştir. Sayısal yükseklik modeli (SYM), eğim ve bakı gibi yardımcı topografik veriler sınıflandırma işleminde yardımcı veriler olarak kullanılmıştır. Yapılan segmentasyon sonucu oluşan her görüntü nesnesi için, spektral, doku, topografik ve geometrik olmak üzere toplam 52 özellik tanımlanarak NN sınıflandırıcısı uygulanmıştır. Çalışma sonucunda, 43 farklı bitki örtüsü sınıfı %60 doğrulukla belirlenmiştir. Ayrıca, eğitim alanlarının büyüklüğü ve belirlenme kalitesi, sınıflandırma işleminde kullanılan yöntemler ve bitki örtüsünün konumsal dağılımının sınıflandırma doğruluğu üzerinde oldukça etkili olduğu vurgulanmıştır.

Conrad vd., (2010) tarafından yapılan çalışmada, keskinleştirilmiş SPOT-5 uydu görüntüsünün segmentasyonu ile güncel parsel sınırları elde edilmiş ve bu parsel sınırları nesne tabanlı sınıflandırma sürecine dâhil edilerek ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) verileri ile altı adet ürün sınıfı belirlenmiştir. Önerilen yaklaşım ile elde edilen sınıflandırma sonucunun toplam doğruluğu %80 olarak belirlenmiştir.

Türker ve Özdarıcı, (2011) tarafından yapılan çalışmada, SPOT4 MS, SPOT5 MS, IKONOS MS, QuickBird MS ve QuickBird PS uydu görüntülerinin nesne tabanlı sınıflandırmasından elde edilen tarımsal ürün haritaları karşılaştırılmıştır. Çalışma alanında belirlenen beş sınıf için vektör formatta bulunan parsel verileri sınıflandırma sürecine dâhil edilmiştir. Ayrıca, nesne tabanlı sınıflandırmada filtre etkisini gözlemlemek amacıyla farklı boyutlarda filtreler kullanılarak sonuçlara olan etkisi analiz edilmiştir. Sonuç olarak, eğer gereken toplam doğruluk %80

civarındaysa en uygun görüntünün SPOT5 MS, fakat %85 civarında ise IKONOS MS, QuickBird MS ve QuickBird PS görüntülerinin kullanılabileceği tespit edilmiştir.

Pena-Barragan vd., (2011) tarafından yapılan bir çalışmada, çok sayıda ürün türünün mevsimlere bağlı olarak değerlendirilmesi için nesne tabanlı görüntü analizi ve karar ağacı algoritmalarını birleştiren ve “Nesneye Dayalı Ürün Tanımlama ve Haritalama” olarak adlandırılan bir yöntem önerilmiştir. Bitkilerin üç farklı büyüme evresinde elde edilen ASTER uydu görüntüsü bantlarından üretilen çeşitli bitki endeksleri ve doku özellikleri kullanılarak 13 ürün sınıfı belirlenmiştir. Sınıflandırmada özellikle doku özellikleri ve NDVI kullanımının sınıflandırma doğruluğuna önemli derecede katkıda bulunduğu belirtilmiştir. Önerilen yöntem ile yapılan sınıflandırma doğruluğu %79 olarak belirlenmiştir.

Koutsias vd., (2011) tarafından yapılan bir çalışmada, tarım alanlarının temel arazi örtüsü/kullanımını oluşturduğu bir çalışma alanında yüksek çözünürlüklü IKONOS ve orta çözünürlüklü ASTER uydu görüntüleri kullanılarak nesne tabanlı sınıflandırma ile bölgede bulunan sekiz sınıf belirlenmiştir. eCognition yazılımında yapılan segmentasyon işleminden sonra segmentler için doku ve bağlamsal özellikler tanımlanarak NN sınıflandırması uygulanmıştır. IKONOS uydu görüntüsü ile yapılan sınıflandırma sonucu %82 toplam doğrulukla belirlenmiştir.

Algancı vd., (2013) tarafından yapılan çalışmada, Şanlıurfa bölgesinde çok tarihli 2.5m, 5m, ve 10m konumsal çözünürlükte Spot-5 ve 30m konumsal çözünürlükte Landsat-5 TM görüntüleri kullanılarak parsel seviyesinde ürün çeşitliliğini analiz etmek için piksel ve nesne tabanlı sınıflandırma yöntemleri karşılaştırılmıştır. Çok çözünürlüklü segmentasyon ve NN sınıflandırması kullanılarak yapılan nesne tabanlı sınıflandırma sonuçları %88 kappa doğruluğu ile belirlenirken, piksel tabanlı sınıflandırma yöntemlerinde en iyi sonuç DVM yönteminde %80 kappa doğruluğu ile belirlenmiştir. Çalışma sonucunda, yüksek çözünürlüklü uydu görüntülerinin nesne tabanlı sınıflandırma yöntemleri kullanılarak parsel ve ürün deseni belirlenmesinde güvenilir sonuçlar verdiğini belirtilmiştir.

Li vd., (2016) tarafından yapılan çalışmada, tarımsal alanlarda yüksek konumsal çözünürlüklü görüntüler kullanılarak, DVM, karar ağacı, NN ve rastgele orman sınıflandırma algoritmalarının da içinde bulunduğu yedi adet farklı nesne tabanlı

sınıflandırma tekniğinin sistematik karşılaştırması yapılmıştır. Bu yedi farklı algoritma, tarım alanı olarak seçilen iki farklı test bölgesinde farklı ölçek parametreleri ile denenmiştir. Her iki çalışma bölgesi için, rastgele orman sınıflandırıcısı kullanılan ölçeklerin hepsinde en yüksek genel doğruluk sağladığı ve tarımsal alanlarda yapılacak çalışmalarda kullanılabilir olduğu belirtilmiştir.

Zhang vd., (2017) tarafından yapılan çalışmada, nesne tabanlı görüntü analizi ile 2011 yılına ait 4 ayrı tarihte elde edilen SPOT-5 görüntüleri kullanılarak, tarım alanları (3 sınıf hâlinde) sınıflandırılmıştır. Sınıflandırmada kullanılmak üzere SPOT-5 görüntüsünden bitki endeksleri, jeostatistiksel semivariogram doku (GST) ve GLCM'den hesaplanan doku özellikleri ve bant yansımaları kullanılarak toplam 440 özellik tanımlanmıştır. Segmentasyon için farklı parametreler denenerek sonuçlar analiz edilmiş ve elde edilen segmentlerin tarım parsellerini iyi bir şekilde tanımladığı belirtilmiştir. Ürünlerin olgunluk dönemi olan Ağustos ayında elde edilen SPOT-5 görüntüsü %94 toplam doğrulukla en iyi sınıflandırma sonucunu sağlamıştır. Ayrıca, ürün türlerinin ayrılmasında bant yansımaları ve GST dayalı doku özelliklerinin, bitki endeksleri ve GLCM'ye dayalı doku özelliklerinden daha etkili olduğu belirtilmiştir.

3. UZAKTAN ALGILAMA

Uzaktan algılama, fiziksel nesneler ve çevreleri hakkında, nesnelerle ve çevreyle temas etmeyen algılayıcı sistemler ile elde edilen görüntü ve enerji desenlerinin sayısal gösteriminden ölçülerek veya yorumlanarak güvenilir bilgi elde etme sanatı, bilimi ve teknolojisi olarak tanımlanmaktadır (Jensen, 2005).

Uzaktan algılama, bilim dünyasında hızla yükselen bir potansiyele sahiptir ve birçok bilim dalında aktif olarak kullanılmaktadır. Gelişen teknoloji ve uzaya gönderilen yeni uydular ile birlikte uzaktan algılama çok daha farklı alanlarda kullanılabilir hâle gelmiştir. Uzaktan algılamanın kullanım alanları Çizelge 3.1’de kısaca verilmiştir.

Uzaktan algılama, yeryüzünün farklı konumsal, spektral, radyometrik ve zamansal çözünürlüklerde görüntülenmesini ve izlenmesini sağlamaktadır. Uzaktan algılama uygulamalarında özellikle arazi örtüsü/kullanımı değişimlerinin belirlenmesi ve sürdürülebilir tarım-çevre uygulamaları için zamansal çözünürlük kavramı büyük önem taşımaktadır (Kavzoğlu ve Çölkesen, 2011).

Uzaktan algılama, bitki türlerinin belirlenmesi, bitki gelişiminin izlenmesi, ürün rekolte tayini, ürün hasar tespiti (kuraklık, hastalık vb.), zirai mücadele, toprak neminin belirlenmesi ve alan bazlı destekleme ödemelerinin belirlenmesi başta olmak üzere daha bir çok tarımsal çalışmada da sıklıkla tercih edilmektedir. Mevcut ürün durumu ve zamana bağlı olarak elde edilen verimin izlenmesi özellikle geleceğe yönelik tarımsal politikalar ve planlamalar açısından önem arz etmektedir (Kavzoğlu ve Çölkesen, 2011).

Uzaktan algılama ayrıca, kullanıcılara zamanında ve en uygun karar verme imkânı da sağlamaktadır. Ayrıca, farklı amaçlar için kullanılan uydu görüntüleri aynı bölgeyi kapsayan değişik ölçeklerdeki çalışmaların aynı zaman diliminde yapılabilmesini, yeryüzünün belirli aralıklarla izlenmesi, kontrolü ve ulaşımı zor bölgelerde çalışabilme imkânı sunması açısından önemli avantajlar sağlanmaktadır (Kavzoğlu ve Çölkesen, 2011).


Çizelge 3.1: Uzaktan algılamanın kullanıldığı bilim dalları ve çalışma alanları (Kavzoğlu ve Çölkesen, 2011).

Bilim Dalı	Çalışma Alanı
Haritacılık	Sayısal arazi modellerinin üretilmesi, Deformasyonların izlenmesi, Topoğrafik harita üretimi vb.
Hidroloji	Su kalitesi analizleri, Su kirliliğinin izlenmesi, Sel haritalaması ve izleme, Buzul hareketlerinin gözlemlenmesi, Gemi atıklarının izlenmesi vb.
Tarım	Arazi kullanımının belirlenmesi, Ürün çeşitliliğinin belirlenmesi, Bitki canlılığının izlenmesi, Bitki gelişiminin izlenmesi, Rekolte tahmini, Toprak nemi ve türünün belirlenmesi vb.
Jeoloji-Maden	Jeolojik yapı araştırmaları, Fay kırıklarının belirlenmesi, Jeotermal ve deprem araştırmaları, Volkanik yapıların izlenmesi, Petrol aramaları, Kayaç tiplerinin tespiti vb.
Ormancılık	Orman türlerinin haritalanması; Ağaç hastalıklarının izlenmesi; Ormansızlaşma ve çölleşmenin izleme, Orman yangınlarının izlenmesi vb.
Çevre	Ekolojik gelişmelerin izlenmesi, Arazi örtüsü veya kullanımının haritalanması, Su kirliliğinin belirlenmesi, Kıyı alanlarındaki değişimlerin izlenmesi, Sanayi alanları ve değişimlerin izlenmesi vb.
Şehircilik Faaliyetleri	Arazi örtüsü ve kullanımının belirlenmesi, Şehirleşmenin izlenmesi, Altyapı çalışmaları, Kaçak yapılaşmanın tespiti, Planlama çalışmaları vb.

3.1 Sayısal Görüntü ve Özellikleri

Günümüzde uzaktan algılama verileri; kameralar ve sensörler bulunduran uçaklar, insansız hava araçları (İHA) ve uydular tarafından temin edilebilmektedir. Uydular, yeryüzündeki nesneler ve bu nesnelerin çevrelerinden gelen elektromanyetik enerjinin miktarını ölçen alıcılardan oluşur. Bu sistemlerde öncelikli olarak nesneler ve çevrelerinden yansıyan/yayılan elektromanyetik enerji ölçülmektedir. Sensörler yeryüzünden yansıyan/yayılan elektromanyetik enerjiyi; elektromanyetik spektrumun (EMS) “spektrum görüntü bölgesi” (spectral image region) olarak adlandırılan

ultraviyole, görünen ve kızılötesi bölgelerinde ölçümlerini kaydetmektedirler. EMS, ışık hızı (3×10^8 m/sn) ile hareket eden ve dalga boyu nanometreden kilometreye kadar uzanan sürekli enerji ortamıdır (Şekil 3.1) (Musaoğlu, 1999). EMS'nin her bir aralığında ilgili yeryüzü özellikleri kaydedilir.



Şekil 3.1: Elektromanyetik spektrum (URL-1).


EMS'nin görünür (visible) bölgesi oldukça küçük olup, insan gözünün spektral duyarlılığı 0.4 μ m- 0.7 μ m (400 nm-700 nm) arasındaki dalga boylarını algılamaktadır. Bu aralıkta yaklaşık 0.4 μ m- 0.5 μ m arası mavi, 0.5 μ m- 0.6 μ m arası yeşil ve 0.6 μ m- 0.7 μ m arasın kırmızı renge karşılık gelen dalga boylarıdır. Ultraviyole (morötesi) aralığı, görünür bölgede mavi bandın yanında bulunmaktadır. Görünür bölgenin bitiminde bulunan kızılötesi dalga boyları sırasıyla; yakın kızılötesi 0,7- 1,3 μ m, orta kızılötesi 1,3- 3 μ m ve termal kızılötesi 3-1 4 μ m dalga boyu arasındadır. Bunların dışında kalan 1 mm-1 m arasındaki daha uzun dalga boyları ise elektromanyetik spektrumun mikrodalga bölgesini oluşturmaktadır (Lillesand vd., 2007).

Özellikle yakın kızılötesi dalga boyu aralığındaki ışınlımlar, bitkilerde bulunan klorofil pigmentine karşı duyarlı olduğu için bitkiler ile diğer nesneler arasındaki ayrımı iyi bir şekilde yansıtır ve bu nedenle çalışmalarda sıklıkla tercih edilmektedir.

Uzaktan algılama ile elde edilen görüntüler yeryüzüne ait çok sayıda bilgi içermektedir. Bu bilgiler, yeryüzünde bulunan nesneler ve çevrelerinden yansıyan elektromanyetik enerjinin yer gözlem uyduları algılayıcıları tarafından algılanıp çeşitli bantlara kaydedilmesi ile sayısal olarak temsil edilmektedir. Bu işlem spektral ölçüm olarak adlandırılmaktadır. Her bir spektral ölçüm değeri bilgisayarlar tarafından sayı dizilerine çevrilir ve satır ve sütun elemanları gri renk değerlerine

karşılık gelecek şekilde matris olarak düzenlenir. Böylelikle, görüntü bantları algılama aralığına göre nesnelerin ilgili özelliklerine ait yansıma değerlerinden oluşur.

Sayısal görüntüyü oluşturan en küçük görüntü elemanına piksel adı verilmektedir. Pikseller, yeryüzünden yansıyan ortalama ışınımı gösteren sayısal değerler olarak ifade edilmektedir (Şekil 3.2). Dolayısıyla görüntüler de $m \times n$ boyutlu piksellerden oluşan bir matris olarak tanımlanmaktadır.




Şekil 3.2: Uydu görüntüsünün bilgisayar ortamında sayısal ifadesi.

Uydu görüntüleri platform ve algılayıcı tipine göre değişiklik gösteren dört tür çözünürlük özelliğine sahiptir. Bunlar; konumsal çözünürlük, spektral çözünürlük, radyometrik çözünürlük ve zamansal çözünürlüktür. Konumsal çözünürlük; yer örneklem aralığı/görüntü içerisindeki nesnelerin ayırt edilebilirlik derecesi, spektral çözünürlük; görüntü bant sayısı, radyometrik çözünürlük; bantlardaki ton sayısı, zamansal çözünürlük ise, görüntü alma sıklığıdır (Lillesand vd., 2007).

3.2 Görüntü Yorumlama Elemanları

Görüntü yorumlama elemanları denildiğinde, nesnelerin algılanmasına ve nesnelerle ilgili bilgilerin çıkarılmasına yardım eden unsurlar akla gelmektedir. Bu unsurlar; konum, ton/rek, boyut, şekil, doku, desen, gölge, yükseklik, hacim, eğim, bakı, durum, ölçü, komşuluk ilişkileri ve mevsimsel koşullardır (Şekil 3.3).



Şekil 3.3: Görüntü yorumlama elemanları.

3.2.1 Ton

Ton, nesne özelliklerinin belirlenmesinde kullanılan temel unsurlardan biridir. Görüntüdeki nesnelerin rengini ve dolaylı olarak parlaklığını ifade eder. Nesnelerin yansıma, yayılma, iletim veya emilim karakteristiklerine göre değişmektedir. Ton özelliği, her nesne için farklı olabileceği gibi aynı nesneye ait ton özelliği çeşitli görüntü bantlarında farklılık göstermektedir (URL-2).

3.2.2 Şekil

Yeryüzünde bulunan pek çok doğal ve insan yapımı nesne, görüntü yorumlamasında kullanılabilecek bazı temel ve özel şekillere sahiptir. Buna göre şekil özellikleri, nesnelerin kendine özgü yapısını veya dış hatlarını yani geometrisini (doğrusal, dairesel, eliptik, radyal, kare, dikdörtgen vb.) tanımlamaktadır (URL-2).

3.2.3 Boyut


Boyut, görüntü üzerindeki bir nesnenin ölçeğe ve çözünürlüğe bağlı fonksiyonudur ve görüntüde bulunan nesnelerin ayırt edilebilmesinde önemli bir özelliktir (Lillesand vd., 2007). Boyut genellikle, analistin aşına olduğu nesnelere bakarak, boyutlarını daha az bildiği nesneleri yorumlamasında etkilidir (URL-2).

3.2.4 Desen

Yeryüzünde nesneler, sistematik, doğrusal, eğrisel ve daha birçok şekilde konumlanış olabilirler. Desen, belirli bir düzen içinde bulunan nesnelerin görülen ayırt edilebilme düzenini belirtir (Şekil 3.4) (URL-2).

3.2.5 Doku

Doku, görüntüdeki ton ve renk özelliklerinin tekrarlanmasıyla oluşur ve görüntüdeki ton değişikliklerini ve düzeni belirtir. Bu özellik boyut, şekil, desen ve gölge özellikleri ile yakından ilişkilidir (Şekil 3.4) (URL-2).



Şekil 3.4: Doku ve desen özellikleri.

3.2.6 Gölge


Gölge, yorumlayıcıya görüntüdeki nesnelerin şekli ve boyutu hakkında bilgi vererek nesnelerin ayrılmasında ve yükseklikleri arasındaki farkların belirlenmesine yardımcı olan bir özelliktir (URL-2).

3.2.7 Komşuluk ilişkileri

Bir nesne genellikle konumu, durumu ve çevre ile ilişkisi ile birlikte değerlendirilir. Dolayısıyla, nesneler komşuluk ilişkilerine göre de anlam kazanabilirler. Burada konum; nesnenin fiziksel (yükseklik, eğim, yüzey örtüsü türü vb.) ve sosyoekonomik (arazinin değeri, su kaynağına yakınlığı) özelliklerini tanımlamaktadır. Durum; nesneleri düzenlenme ve birbirlerine göre yönlendirilme şeklini ifade ederken, ilişki özelliği de; belirli nesnelerin etrafında genelde o nesne ile ilişkili bir özellik bulunması mantığını ifade eder (URL-2).

4. UZAKTAN ALGILAMADA SINIFLANDIRMA YÖNTEMLERİ

Nesnelerin sahip olduğu yapısal karakteristiklere bağlı olarak, elektromanyetik spektrumun farklı bölgelerinde yansıtıkları/yaydıkları ışınımın farklılık göstermektedir (Jensen, 2005). Bu farklılıkların yanında sistemlerin radyometrik ve spektral çözünürlüklerine göre sayısal görüntülerde bulunan her özellik veya nesne, kendine özgü bir sayısal değer ile (Digital Number/DN) ifade edilmektedir. Nesnelerin birbirinden ayırt edilmesi veya tanımlanmasında değişiklik gösteren bu sayısal değerler kullanılarak yapılan gruplandırmalar basit anlamda sınıflandırma işlemi olarak tanımlanmaktadır (Şekil 4.1). Diğer bir ifadeyle sınıflandırma; görüntüyü meydana getiren piksel değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin kullanıcı tarafından belirlenen sınıflara atanması işlemidir (Campbell, 1996). Sınıflandırma işleminin amacı; uydu görüntüsünde bulunan pikselleri spektral özelliklerine göre farklı gruplar altında toplamak ve pikselleri sayısal değerine göre yeryüzünde karşılık geldikleri arazi örtüsü/kullanımı sınıfına atayarak ayırt edilebilirliği ve yorumlanabilirliği arttırmaktır.



Şekil 4.1: Görüntü sınıflandırma (URL-3).

Sınıflandırma işlemi bir tür örüntü tanımlama (pattern recognition) olup, nesnelerin spektral yansıma karakteristiklerine göre otomatik olarak tanımlanması için temelde iki varsayıma dayandırılmaktadır. Bunlar:

- Belirli bir sınıfa ait olan tüm spektral verilerin yansıma değerleri benzer olmalıdır.
- Tüm sınıflar spektral açıdan birbirinden net bir şekilde ayırt edilebilir olmalıdır.

Sınıflandırma işlemi, genel olarak;


- Çalışma amacına ve istenen hassasiyete göre uygun görüntü (algılayıcı ve algılama zamanı) ve spektral bant seçimi,
- Arazi örtüsü/kullanımı sınıf tanımlarının yapılması ve sınıflandırmada kullanmak üzere eğitim/test verilerinin oluşturulması ve istatistiklerin hesaplanması,
- Çalışma amacına göre özellik çıkarımı (şekil, bağlam, doku vb.) ve uygun sınıflandırma algoritmasının seçimi ve uygulanması,
- Doğruluk analizi yapılması ve sınıflandırılmış görüntünün yorumlanması aşamalarından oluşmaktadır.

Eğitim alanları, sınıfların hangi ölçütler yardımıyla tanınip oluşturulacağını belirlemek için sisteme tanıtılan veriler olup, analizi yapan kişi ile veri arasında yakın bir ilişki ve çalışma alanı hakkında referans veri gerektirmektedir. Eğitim alanlarının seçimi, sınıflandırma işleminin başarısını etkileyen önemli bir faktör olduğu için iyi bir şekilde belirlenmesi gerekmektedir. Bundan dolayı eğitim alanı seçiminde; her sınıf için ilgili sınıfı temsil etmesi ve eksiksiz olmasına, sınır (boundary) piksellerden seçilmemesine ve aynı sınıfa ait fakat farklı yansıma özelliği gösteren nesnelerin alt sınıf (sub-class) olarak ayrılmasına dikkat edilmesi gerekmektedir.

Eğitim alanları kullanılarak üretilen istatistik değerleri, piksellerin atanacağı sınıfların istatistiksel karakteristiklerini belirlemek için hesaplanmaktadır. Temel istatistiksel ölçümler; histogram, spektral ayırım/yansıtım grafiği (coincident spectral plot), ortalama değer, minimum ve maksimum değerler, varyans-standart sapma, kovaryans matrisi ve hata matrisi (error-confusion matrix)'dir.

Sınıflandırma sonucunda elde edilen görüntü bir tematik haritadır. Bu tematik harita, bir harita projeksiyonu kullanılarak göre dönüşümü yapıldığında coğrafi bilgi sistemlerinde kullanılabilir (Jensen, 2005).

Uzaktan algılamada birçok görüntü sınıflandırma yöntemi olup bu yöntemler genel olarak piksel tabanlı, nesne tabanlı, denetimli (supervised) ve denetimsiz (unsupervised) olarak gruplandırılabilirler. Kontrollü ve kontrolsüz sınıflandırma yöntemleri kendi içinde birçok yöntemi olup, farklı amaçlar doğrultusunda değişik sınıflandırma tekniği seçilebilmektedir (Şekil 4.2).



Şekil 4.2: Görüntü sınıflandırma yöntemleri.

4.1 Kontrolsüz sınıflandırma

Kontrolsüz sınıflandırma yöntemi, piksellerin kümeleme algoritmaları ile kullanıcı müdahalesi olmaksızın otomatik olarak gruplandırılması temeline dayanmaktadır. Bu açıdan ele alındığında kontrolsüz sınıflandırma yaklaşımında görüntü üzerindeki parlaklık değerlerinin dağılımına ilişkin istatistiksel bir değerlendirme söz konusudur (Jensen, 2005).

Çalışma alanına ait yeterli referans verinin bulunmaması ve çalışma alanına ilişkin ön bilgiye gereksinim duyulan çalışmalarda bu sınıflandırma yöntemi kullanılmaktadır. Ayrıca, büyük çalışma alanlarında ve çok sayıda sınıf içeren

çalıřmalarda iyi bir algoritma kullanımı ile eğitim alanı seçiminde referans olarak kullanılabilir.

Kontrolsüz sınıflandırmada, görüntü öncelikli olarak bir kümeleme algoritmasıyla kullanıcı tarafından belirlenen sayıda kümeye ayrılır. Algoritma başlangıcında, küme merkezleri geçici olarak rastgele belirlenir ve her bir pikselin hangi kümeye dâhil edileceđi piksel ile küme merkezleri arasındaki uzaklıđın hesaplanması ve başlangıçta kabul edilen uzaklık değeri ile karşılaştırılması sonucunda belirlenir. Bu belirlemede en küçük uzaklık değeri esas alınmaktadır. Görüntüdeki tüm piksellerin gruplandırılmasından sonra küme merkezleri tekrar hesaplanarak geçici küme merkezleri n boyutlu uzayda ötelenir ve işlem geçici merkezin konumunda değışim olmayıncaya kadar veya piksel sınıfları değışmeyinceye kadar iteratif olarak devam etmektedir sınıflardır (Lillesand vd., 2007).

Kontrolsüz sınıflandırma sonucu oluşacak sınıflar, spektral sınıflardır. Elde edilen bu spektral sınıfların etiketi, ilgili bölgeye ait topoğrafik haritalar, hava fotoğrafları ve mevcut yardımcı bilgilerle karşılaştırılarak belirlenmektedir. Böylece, oluşan her küme referans veri yardımıyla etiketlenerek sınıflandırma işlemi tamamlanır sınıflardır (Lillesand vd., 2007).

ISODATA (Iterative Self Organizing Data Analysis Technique), K-ortalama, SOM (Self Organizing Map), ardışık kümeleme ve istatistiksel kümeleme algoritmaları en yaygın kullanılanlar arasında yer almaktadır.

4.2 Kontrollü sınıflandırma

Kontrollü sınıflandırma yaklaşımının temel çıkış noktası, benzer parlaklık değerlerine sahip piksellerin belirli bir sınıfa ait olması ve sınıflar arasında belirli bir dereceye kadar ayırım yapılabilmesidir (Lillesand vd., 2007). Kontrollü sınıflandırma yaklaşımında sınıflara ait referans bilgiler mevcuttur ve bunlar eğitim verisi olarak kullanılır. Eğitim alanları kullanılarak pikseller, hesaplanan istatistiksel değerlere göre en yakın olduđu sınıfa atanmaktadır.

Kontrollü sınıflandırma yöntemleri; en büyük benzerlik, en kısa mesafe ve paralelkenar olmak üzere üçe ayrılmaktadır.

4.2.1 En büyük benzerlik yöntemi

En büyük benzerlik yöntemi, kontrollü sınıflandırma yöntemleri arasında en yaygın kullanılan ve en doğru sonucu veren yöntemdir. Bu yöntem temelde, sınıflar için eş olasılık eğrilerinin tanımlanmasına ve sınıflandırılacak piksellerin aitlik olasılığı en yüksek olan sınıfa atanmasına dayanmaktadır. En büyük benzerlik yönteminin etkinliği, spektral sınıflar için ortalama ve kovaryans matrisinin doğru biçimde belirlenmesine bağlıdır. Bu koşul, sınıfların her biri için yeterli miktarda eğitim verisinin bulunmasını gerektirmektedir. Yeterli miktarda eğitim verisi bulunmadığında, yani sınıfların olasılık dağılımlarını doğru bir şekilde tahmin edebilecek veri olmadığında, istenen sınıflandırma doğruluğuna ulaşılamaz (Lillesand vd., 2007). Ayrıca bu yöntemde, her piksel için ayrı ayrı hesaplama yapıldığından dolayı, çalışma alanının büyük olması, sınıf ve bant sayısının fazla olması hesap yükünü ve zamanını artırmaktadır.

Olasılık yoğunluk fonksiyonları her pikselin herhangi bir sınıfa ait olma olasılığını hesaplamak için kullanılan olasılık değerleri değişimini gösteren üç boyutlu grafiklerdir (Şekil 4.3). Burada her pikselin olasılığı;

$$P_c = \{-0.5 \log e \mid Cov_c \mid\} - [0.5(X - \mu^c)^t Cov_c^{-1}(X - \mu^c)] \quad (4.1)$$

formülü ile hesaplanmaktadır. Bu eşitlikte;

P_c : olasılık değerini,

$\mid Cov_c \mid$: c sınıfındaki piksellerin varyans-kovaryans matrisini,


X : aday pikselin ölçüm vektörünü,

μ^c : c sınıfına ait ortalama değerler vektörünü temsil etmektedir.

Burada bilinmeyen bir X pikseli için;

$$P_c \geq P_i \quad \left(\begin{array}{l} i = 1, 3, 4, \dots, m \text{ sınıflar} \\ P_c = c \text{ sınıfının olasılığı} \end{array} \right)$$

şartı sağlanıyorsa, X pikseli olasılığı en yüksek sınıf olan c sınıfına atanır. Sınıflandırma sırasında piksellerin belirlenen sınıflara dâhil olma veya olmama durumunu belirlemek için eşik değerleri kullanılmaktadır. Eğer aday pikselin olasılığı tüm sınıflar için belirlenen eşik değerinin altındaysa piksel bilinmeyen olarak etiketlenir (Lillesand vd., 2007).



Şekil 4.3: Olasılık yoğunluk fonksiyonu (Lillesand vd., 2007).

4.2.2 En kısa mesafe yöntemi

En kısa mesafe yöntemi, varyans-kovaryans değerleri kullanılmadan sadece sınıfların ortalama vektörlerinin kullanılmasına dayanan sınıflandırma yöntemidir. Öncelikle eğitim verilerinden sınıfların ortalamaları belirlenir ve her piksel için tüm sınıf ortalamalarına olan mesafeler hesaplanır. Sınıflandırılacak pikseller bu uzaklıklara göre en yakın olduğu sınıfa atanır. Mesafe hesabı için genellikle Öklid ve Mahalonobis mesafe ölçüm yöntemleri tercih edilmektedir. Öklid uzaklığı;

$$D_{i,j,c} = \sqrt{\sum_{b=1}^n (\mu_{cb} - X_{i,j,b})^2} \quad (4.2)$$

formülü ile hesaplanmaktadır. Bu eşitlikte;

$D_{i,j,c}$: i,j konumundaki pikselin c sınıfının merkezine olan öklid mesafesini,

n : bant sayısını,

b : spektral bant,

c : belirli bir sınıfı,

$X_{i,j,b}$: b bandında i,j konumundaki pikselin parlaklık değerini,

μ_{cb} : c sınıfı için b bandının ortalama vektörünü

temsil etmektedir.

Mahalanobis mesafesi ise, verilerin normal dağılımda olduğunu varsayar ve en kısa mesafe karar kuralına benzemektedir. Ayrıca, Mahalanobis mesafesi hesaplaalarında kovaryans matrisi kullanılmaktadır.

Mahalanobis uzaklığı;

$$D = (X - \mu_c)^t Cov_c^{-1} (X - \mu_c) \quad (4.3)$$

formülü ile hesaplanmaktadır. Bu eşitlikte;

X : piksel parlaklık değerini (ölçüm vektörü),

μ_c : c sınıfı için b bandının ortalama vektörünü,

c : belirli bir sınıfı,

Cov_c^{-1} : c sınıfının kovaryans matrisinin tersini,

t : transpoze fonksiyonunu temsil etmektedir.

Yöntem, sınıflandırılacak aday pikselin, Eşitlik (4.2) ve (4.3) ile hesaplanan uzaklığının en düşük olduğu sınıfa atanması esasına dayanmaktadır.

En kısa mesafe yöntemi, en büyük benzerlik yöntemine göre matematiksel olarak daha basit ve hızlıdır. Bu yöntem sonucunda, kullanıcı tarafından bir eşik değeri belirlenmediği sürece tüm pikseler sınıflandırılır. Ancak kovaryans bilgileri kullanılmadığı için en büyük benzerlik yöntemi kadar esnek değildir sınıflardır (Lillesand vd., 2007).

4.2.3 Paralelkenar yöntemi

Paralelkenar yönteminde sınıfların her bir banttaki en düşük ve en yüksek spektral değerleri belirlenerek bu sınırlar içinde dikdörtgen bölgeler oluşturulur. Daha sonra sınıflandırılacak aday piksel, içerisinde bulunduğu dikdörtgen bölgenin ait olduğu sınıfa atanır. Buna alternatif olarak ortalamanın etrafında standart sapma biriminde belirlenen alt ve üst sınırlar da kullanılabilir (Lillesand vd., 2007).

Paralelkenar yöntemi, bir sınıflandırma kullanıcısından en az bilgiyi gerektiren yöntemdir. Fakat, uygulama açısından hızlı ve kolay olmasına rağmen, sınıfların spektral dağılım bilgisi sınıflandırma işleminde kullanılmaz. Herhangi bir paralelkenar içinde kalmayan pikseller, tanımlanmayan piksel olarak atanmaktadır. Aynı pikselin birden fazla paralelkenar içinde olduğu durumlarda aday pikseller için

çakışan sınıflardan birine rastgele atama işlemi yapılsada bu durum istatistiksel olarak yeterli bulunmamaktadır.

Açıklanan piksel tabanlı sınıflandırma yöntemlerinde genellikle piksellerin spektral bilgileri kullanılmaktadır. Fakat, yüksek çözünürlüklü uydu görüntüleri, piksel tabanlı yöntemlerle sınıflandırıldığında spektral benzerlik ve piksel heterojenliğinden dolayı düşük doğrulukta sonuçlar vermekte ve nesnelerin çıkarımında beklentileri karşılayamamaktadır (Antunes vd., 2003). Bu problemlerin üstesinden gelmek için nesne tabanlı görüntü analizi yöntemleri geliştirilmiştir.

Nesne tabanlı yöntemlerde görüntü öncelikle bir segmentasyon algoritması ile benzer görüntü nesnelere ayrılır ve nesnelerin spektral, dokusal ve hiyerarşik özellikleri kullanılarak sınıflandırma işlemi gerçekleştirilir (Pena-Barragan vd., 2011). Bu tür segmentasyon ve topoloji kullanımı, çözünürlüğe ve çıkarılması düşünülen nesnelerin ölçeğine bağlı olarak yapıldığında daha yüksek doğrulukta sınıflandırma sonuçları sağlamaktadır (Karakuş ve Karabörk, 2016). Nesne tabanlı sınıflandırma işlemi Bölüm 5’de ayrıntılı bir şekilde açıklanmıştır.

4.3 Sınıflandırmada Yardımcı Veri Kullanımı

Günümüzde, uzaktan algılama teknolojileri ve uydu sensörlerinin gelişimine bağlı olarak, uydu görüntülerinin çözünürlüklerinin artması ile birlikte yeryüzünde bulunan nesnelerin gerek konumsal gerekse spektral özellikleri daha detaylı bir şekilde elde edilebilmektedir. Söz konusu uydu görüntüleri yeryüzü nesneleri ile ilgili detaylı bilgiler sağlamasına rağmen, arazi örtü tiplerinin spektral benzerliklerine ve piksellerin farklı arazi tiplerine ait spektral yansıma değerine sahip olmasına bağlı olarak nesnelerin birbirinden ayırt edilmesi ve sınıflandırılmasında önemli problemler ortaya çıkmaktadır. Bu sorunların çözümü için uydu görüntülerinin yardımcı veriler ile birlikte değerlendirilmesi sıklıkla tercih edilen bir yaklaşımdır.

Yardımcı veriler ve görüntü bandı türevleri, sınıflandırma sonuçlarını iyileştirmek ve düzeltmek amacıyla kullanılabilecek konumsal ve konumsal olmayan (öznitelik) verilerdir. Yükseklik, eğim ve toprak nemi gibi çevresel faktörler, yaygın olarak kullanılan yardımcı veriler olarak değerlendirilebilir (Dymond ve Johnson, 2002). Orman, jeoloji, toprak haritaları, eğim ve bakı konumsal yardımcı veriler iken, ürün

rekoltesi, arazi kullanım alanlarının yüz ölçümü vb. veriler ise konumsal olmayan yardımcı verilere örnek gösterilebilir. Bunlarla birlikte, sınıflandırma işlemine bazı özel kısıtlamalar getirmek de mümkündür. Bitkilerin yaşam alanı özelliklerine göre, mevcut çevresel koşullar bazı türlerin konumsal dağılımı için kısıtlayıcı faktörler olabilmektedir. Örneğin, bazı söğüt türleri genellikle bir su kanalı veya topoğrafik çöküntülere yakın olan bölgelerde bulunmaktadır. Bu nedenle, yükseklik, eğim ve suya olan mesafe özellikleri, bu tip ağaçların konumlarının belirlenmesi için kullanılabilir.

Literatürde uydu görüntülerinden elde edilen bitki endeksleri, doku özellikleri ve ana bileşenler en sık kullanılan yardımcı veri setleri arasındadır. Örneğin, Löw vd., (2013) tarımsal ürünlerin tespitinde RapidEye uydu görüntüsünün mevcut spektral bantlarına ek olarak bitki endeksleri, doku özellikleri, ana bileşenler ve semivariogramlardan oluşan 71 adet yardımcı veri setini sınıflandırma işleminde kullanmıştır. Yomralıoğlu ve Çölkesen (2014) WorldView-2 uydu görüntüsü yardımıyla benzer spektral özelliğe sahip doğal ve yapay nesnelerin sınıflandırılmasında, 12 farklı bitki endeksi, ilk iki ana bileşen ve GLCM'den hesaplanan doku özelliklerini yardımcı veri seti olarak kullanmış ve özellikle doku özelliklerinin sınıflandırma doğruluğunu %2,5'e varan bir oranda artırdığını belirtmiştir. Dolayısıyla, multispektral ve hiperspektral görüntülerde sınıflandırma doğruluğunu artırmak için bant oranları ve spektral türevler kullanılabilir (Löw vd., 2013).

Yardımcı veriler sınıflandırmanın farklı aşamalarında kullanılmaktadır. Yardımcı verinin sınıflandırma sürecinde kullanılması sınıflandırma öncesinde, sınıflandırma aşamasında ve sınıflandırma sonrasında olmak üzere üç farklı biçimde yapılabilir. Yardımcı verilerin sınıflandırma işlemine katılımı sırasıyla; tabakalama (stratification), sınıflandırma düzeltilmesi (classifier modification) ve sınıflandırma sonrası iyileştirme (postclassifier sorting) olarak tanımlanmaktadır (Türker, 1999).

Yardımcı verinin sınıflandırma öncesinde kullanımı görüntüyü birbirinden bağımsız bölümlere (strata) ayırmak amacıyla yapılmaktadır. Bu işlemin amacı sınıflandırılacak veri setinin homojenliğini artırmaktır. Burada, yardımcı veriler kullanılarak benzer özellikler taşıyan alanların parçalara ayrılması sağlanmaktadır.

Dolayısıyla, ekolojik özelliklerin bilindiği durumlarda analist, eğim ve yükseklik vb. özellikleri kullanarak çalışma alanını alt bölümlere ayırabilir.

Daha sonra, birbirinden bağımsız olan tabakalar ayrı ayrı sınıflandırılır. Böylece farklı ve çok çeşitli özelliklere sahip bütün bir görüntüyü sınıflandırmak yerine onu daha küçük ve daha az karmaşık parçalara ayırıp sınıflandırmak avantajlı olmaktadır. Bu işlem, sonucun belirli bir oranda iyileşmesini sağlar ve daha sonra bağımsız tabakalar birleştirilip sınıflandırılmış görüntü elde edilir. Görüntü tabakalamasının iki avantajı vardır. Bunlar;

- Görüntü analiz aşamalarında küçük boyutlu veriler ile işlem yapılması büyük çalışma alanlarında avantaj sağlamaktadır.
- Tabaka içi spektral değişim azalması ve her tabakanın bağımsız değerlendirilmesi ile sınıflar arasındaki olası spektral yanılgılardan kaçınılabılır (Türker, 1999).

Sınıflandırma süresinde yardımcı veri kullanımında ise, yardımcı verinin sınıflandırma algoritmasına bu süreçte dâhil edilmesi iki yöntemde gerçekleşmektedir. Birinci yöntemde, yardımcı veriler görüntünün spektral bantlarına ek olarak kullanılmaktadır. Örneğin; uydu görüntüsünün orijinal bantlarına ek olarak sayısal yükseklik modelinden elde edilebilecek eğim ve bakı özellikleri mevcut bantlara eklenerek sınıflandırma sürecine dâhil olabilmektedir. Diğer yöntemde ise, En Büyük Olasılık karar kuralı, yardımcı verilerden çıkarılmış öncül olasılıklar ile iyileştirilmektedir (Türker, 1999). Dolayısıyla, yardımcı verilerden gelen bilgilerin sınıflarla ve görüntü ile ilişkileri mantıksal bir veri seti haline getirilir ve bu veri seti üzerinden görüntü ve yardımcı veriler istenen ağırlıklara göre değerlendirilir.

Yardımcı verinin sınıflandırma sonrasında kullanımı ise; sınıflandırma sonucunda hatalı olarak atanmış bazı piksellerin belirlenmesine ve düzeltilmesine olanak sağlamaktadır.

Ancak, yardımcı verilerle sınıflandırma kalitesini arttırmak isteyen bir analistin dikkat etmesi gereken bazı hususlar bulunmaktadır. Bunlardan ilki; bu verilerin asıl üretim amacının bir sınıflandırma çalışmasının kalitesini arttırmak olmadığıdır. Dolayısıyla, yardımcı veriler belirli amaç ve yöntemlere dayanarak üretilen veriler olduğundan, bazı konumsal, tematik genellemeler ve hatalar barındırabilirler. İkincisi ise; analog formatta depolanan yardımcı verilerin kullanılabilmesi için dönüşüm, sayısallaştırma, yeniden örnekleme gibi birçok işlemin uygulanması gerekliliğidir.

Bu işlemler sırasında ilgilenilen olguların gerçek konumlarında meydana gelebilecek değişiklikler sınıflandırma doğruluğunu olumsuz yönde etkileyecektir. Dolayısıyla, yardımcı veriler kullanılırken bu unsurlar dikkate alınmalı, çalışma sonuçlarını iyileştirebilecek nitelikte ve uygun doğrulukta yardımcı veriler seçilmelidir.

4.4 Doku Ölçüm Yöntemleri


Uzaktan algılamada görüntü yorumlama işlemlerinde görüntülere ait spektral ve konumsal özellikler birlikte değerlendirilmektedirler. Görüntülerin spektral özellikleri görüntüdeki ton değişimlerini ifade ederken, konumsal özellikler mevcut ton değişimlerinin görüntüdeki dağılımlarını ifade etmektedir. Konumsal özellikler görüntü üzerinde iki tür ilişkiyi incelemektedir. Bunlar; görüntü nesnelerinde ve nesneler arasında olabilecek ton değişimleridir. Bu iki konumsal ilişkinin belirlenmesinde genellikle doku özellikleri kullanılmaktadır (Tso ve Mather, 2009). Bu anlamda düzenli bir frekansta tekrar eden desen veya desen kombinasyonu olarak tanımlanan doku ilgili görüntü nesnelerin belirlenmesinde kullanılan önemli bir özelliktir (Haralick vd., 1973).

Spektral örtüşmelerin fazla olduğu, benzer ton ve desene sahip görüntülerde ilgilenilen nesnelerin belirlenmesi için doku özellikleri kullanılabilir. Örneğin, Şekil 4.4'te verilen görüntüden palmye alanının spektral özellikler kullanılarak belirlenmesi oldukça zordur. Bunun için, palmye alanının sahip olduğu doku özelliklerinden yararlanılabilir. Doku özellikleri, görüntü yorumlama veya sınıflandırma işlemlerini kolaylaştırmak amacıyla işlem sürecinde doğrudan kullanılacağı gibi, uydu görüntüsünün mevcut bantlarıyla birlikte yardımcı veri olarak da kullanılabilir.




Şekil 4.4: 1m konumsal çözünürlüklü IKONOS uydu görüntüsü (URL-4).

Şekil 4.4’de verilen IKONOS görüntüsü bantlarının sadece ortalama ve standart sapma değerleri kullanılarak NN yöntemi ile elde edilen sınıflandırma sonucu Şekil 4.5’te görülmektedir. Bu özelliklere ek olarak homojenlik, karşıtlık, farklılık, ortalama, varyans ve entropi olmak üzere 6 farklı doku ölçümü ile yapılan sınıflandırma sonucu ise Şekil 4.6’da görülmektedir. Her iki sınıflandırmada da aynı segmentasyon parametreleri ve sınıflandırma tekniği kullanılmasına rağmen Şekil 4.6’da doku özelliklerinin kullanılmasından dolayı sınıflandırma sonucunun iyileştiği görülmektedir.



Şekil 4.5: Doku özellikleri kullanılmayan sınıflandırma sonucu.



Şekil 4.6: Doku özellikleri kullanılarak yapılan sınıflandırma sonucu.

Genel anlamda doku özellikleri, birinci ve ikinci derece istatistiklere dayalı doku ölçümleri olmak üzere ikiye ayrılır. Birinci derece istatistiklere dayalı yöntemler ortalama, standart sapma ve entropi iken; ikinci derece istatistiklere dayalı yöntemlerde doku özellikleri, gri seviye eş oluşum matrisleri (GLCM) ile hesaplanmaktadır.

İkinci derece istatistiklere dayalı doku ölçümleri, komşu pikseller arasındaki uzaklık ve açı ilişkilerinin bir fonksiyonu olarak tanımlanan GLCM ile hesaplanmaktadır. GLCM, belirli mesafede ve yönde bulunan piksel çiftleri arasında gri seviyesinin eşli oluşma olasılık değerlerini gösteren iki boyutlu bir matristir (Haralick vd., 1973). Pikseller arası gri seviye değişimlerinin belirlenmesinde, mesafe olarak genellikle 3x3 veya 5x5 gibi pencere boyutu kullanılır (Gong vd., 1992). Hesaplama işlemleri desen özelliklerinin yönlerine göre dört yönde (0°, 45°, 90° ve 135°) yapılabilir. Burada, doku özelliklerinin hesaplanmasında kullanılacak bantlar, yönler, filtre boyutu ve hangi ölçme yönteminin uygulanacağı çalışma amacına göre kullanıcı tarafından seçilmelidir.

Haralick vd., (1973) GLCM'den üretilebilecek 32 adet farklı doku hesaplama yöntemi geliştirmiştir. Doku özellikleri olarak adlandırılan bu yöntemler birçok uygulamada kullanılmış ve çoğunlukla başarılı sonuçlar sağlamıştır. Li vd., (2016) çalışmasında en çok kullanılan doku ölçüm yöntemlerinin homojenlik, zıtlık, farklılık, entropi, ortalama ve varyans olduğunu belirtmiştir. Uygulamada kullanılan doku ölçüm yöntemleri aşağıda açıklanmıştır.

4.4.1 GLCM homojenlik

Homojenlik, GLCM'nin elemanlarının köşegen (ana diyagonal) boyunca yoğunlaşma derecesini ölçmektedir ve Ters Diferansiyel Moment olarak da adlandırılmaktadır. Homojenlik ağırlıkları, zıtlık ağırlığının tersiyle çarpılır ve diyagonal uzaklıklarına göre katlanarak azalır. Bu nedenle homojenlik arttıkça zıtlık genellikle azalmaktadır (Haralick vd., 1973).

$$\text{Homojenlik} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (4.4)$$

4.4.2 GLCM zıtlık

Zıtlık, homojenliğin tersidir. Görüntüdeki konumsal varyasyonun bir ölçüsü olan zıtlık, GLCM'de $P_{i,j}$ elemanlarının ana diyagonalden uzaklaşmasıyla daha yüksek değere sahip olmaktadır. Komşu piksel çiftleri arasındaki mesafe arttığında zıtlık değeri de artmaktadır (Haralick vd., 1973).

$$\text{Zıtlık} = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2 \quad (4.5)$$

4.4.3 GLCM farklılık

Zıtlığa benzer, ancak doğrusal olarak artmaktadır. İlgilenilen bölge yüksek bir zıtlık değerine sahipse, farklılık değeri de yüksektir (Haralick vd., 1973).

$$\text{Farklılık} = \sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (4.6)$$

4.4.4 GLCM entropi

Entropi, görüntüdeki rastgelelik veya mevcut düzensizliğin bir ölçüsüdür. GLCM'nin elemanları homojen dağılıma sahipse, entropi değeri de yüksektir. Böylece, Entropi değeri, GLCM'nin tüm elemanları eşit olduğunda, dolayısıyla homojen görüntülerde en yüksek değerini alır (Haralick vd., 1973).

$$\text{Entropi} = \sum_{i,j=0}^{N-1} P_{i,j} \log P_{i,j} \quad (4.7)$$

4.4.5 GLCM ortalama

GLCM ortalama, görüntü penceresindeki tüm piksel değerlerinin basit bir ortalaması değildir. Burada, piksel değerleri belirli bir komşu piksel değeri ile birlikte ortaya çıkma sıklığına bağlıdır (Haralick vd., 1973).

$$\text{Ortalama } (\mu_i) = \sum_{i,j=0}^{N-1} i (P_{i,j}) \Leftrightarrow \text{Ortalama } (\mu_j) = \sum_{i,j=0}^{N-1} j (P_{i,j}) \quad (4.8)$$

4.4.6 GLCM varyans

GLCM'den elde edilen standart sapma değerleri, özellikle referans ve komşu piksel kombinasyonları ile ilgilenir. GLCM içindeki hücre değerlerinin ortalamasına ve dağılımına dayanır. Bu nedenle, orijinal görüntüdeki yansıma değerlerinin basit standart sapma hesabıyla aynı değildir. Standart sapma, ortalamaların etrafındaki değer dağılımının bir ölçüsüdür ve gri seviye değerleri ortalamadan farklı olduğunda varyans değeri artar. Zıtlık ve farklılığa benzemektedir (Haralick vd., 1973).

$$\text{Varyans}(\sigma_i^2) = \sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_i)^2 \Leftrightarrow \text{Varyans}(\sigma_j^2) = \sum_{i,j=0}^{N-1} P_{i,j} (j - \mu_j)^2 \quad (4.9)$$

Yukarıdaki eşitliklerde;

i, j : eş oluşum matrisinin satır ve sütun sayısı,

$P_{i,j}$: eş oluşum matrisinin i, j konumunda bulunan değer,

N : gri seviye sayısı (görüntü 8 bit ise $N=256$),


μ, σ : ortalama ve standart sapmayı temsil etmektedir.

5. NESNE TABANLI SINIFLANDIRMA

Günümüzde uygulanan piksel tabanlı sınıflandırma yöntemlerinde, genellikle sadece görüntüyü oluşturan piksellere ait spektral bilgiden yararlanılmaktadır. Son yıllarda uydu görüntülerinin konumsal çözünürlüklerinde yaşanan gelişmeler ile piksel tabanlı yöntemler yüksek konumsal çözünürlüğe sahip uydu verilerinin sınıflandırılmasında düşük doğrulukta sonuçlar vermektedir (Antunes vd., 2003). Bunun nedeni, görüntülerin yüksek konumsal çözünürlükleri nedeniyle içerdiği zengin verinin, piksel tabanlı sınıflandırma yöntemlerinde tam olarak yansıtılamaması, başka bir deyişle sınıflandırma için sadece spektral bilginin kullanılıyor olmasıdır. Nesneler üzerinden sınıflandırma fikri ise görüntüdeki karakteristik doku, bağlam ve konumsal ilişkilerin diğer klasik yöntemlerde ihmal edilmesinden dolayı ortaya çıkmıştır (Blaschke, 2010).

Nesne tabanlı sınıflandırma işlemi, segmentasyon ve sınıflandırma olmak üzere iki temel adımdan oluşmaktadır. Segmentasyon işleminde, görüntü üzerindeki benzer spektral özelliklere sahip pikseller kullanıcı tarafından belirlenen parametreler ile gruplandırılarak segmentler oluşturulur. Oluşan segmentler, bir sonraki adım olan sınıflandırma aşaması için girdi veri olarak kullanılır. Sınıflandırma işleminde ise nesneler yine kullanıcı tarafından seçilen yöntem ve kurallara göre sınıflara atanmaktadır. Nesne tabanlı sınıflandırma yaklaşımının genel iş akışı Şekil 5.1'de gösterilmektedir.

Segmentasyon ile oluşturulan görüntü nesneleri, sınıflandırmanın sonraki aşamasında girdi olarak değerlendirilir ve yapı, doku, konumsal ilişkiler gibi verilerin de eklenmesiyle sınıflandırılır. Bu tür segmentasyon ve topoloji oluşumu, görüntünün çözünürlüğüne ve her nesneye özgü olan ölçeklere dikkat edilerek yapılmalıdır.



Şekil 5.1: Nesne tabanlı sınıflandırma genel işlem akışı.

Nesne tabanlı yöntemler, klasik piksel tabanlı yöntemlerden farklı olarak bulanık mantık sınıflandırmaya olanak sağladığından dolayı, nesneler birden fazla sınıfa ait olabilmektedir. Bulanık mantıkta, sınıf üyelikleri 0 ile 1 arasında değişen değerler ile tanımlanmaktadır. Burada, 1 değeri pikselin ilgili sınıfa tam üyeliğini temsil ederken, 0 değeri pikselin ilgili sınıfa hiçbir üyeliğinin olmadığını göstermektedir. 0 ile 1 arasında değişen değerler ise büyüklükleri oranında üyeliğin olacağını gösterir (Boyacı, 2012). Ayrıca, nesne tabanlı sınıflandırmada kural tabanlı işlemler sayesinde sınıflandırma ağaçlarının kullanılması ile sınıflar hiyerarşik olarak düzenlenebilir, dolayısıyla tüm sınıf nesneleri alt veya üst sınıfların özelliklerini taşıyabilmektedirler. Nesne tabanlı yöntemlerin en önemli avantajlarından birisi; Bölüm 3.2’de açıklanan görüntü yorumlama elemanlarının tamamının kullanımına olanak sağlamasıdır. Böylece, nesne tabanlı sınıflandırmada spektral bilgiye ek olarak görüntü nesnelerinden elde edilen yapı, doku ve konumsal ilişkiler gibi yardımcı verilerin de kullanılması ile daha doğru sonuçlar elde edilebilmektedir.

Nesne tabanlı sınıflandırmanın, segmentasyon ve sınıflandırma aşamalarında farklı algoritma kullanımına olanak sağlaması bir başka avantajı olarak değerlendirilebilir.

Böylece, bir görüntünün bütün alanlarını aynı algoritmayla değerlendirmek yerine, farklı alanlar için farklı algoritmalar kullanmak çok daha uygun olacağından daha pozitif sonuçlar elde edilecektir.

5.1 Segmentasyon İşlemi

Segmentasyon (görüntü bölütleme) işlemi, nesne tabanlı görüntü analizinin ilk adımı olup ve görüntünün birbirinden farklı alt bölümlere ayrılmasını sağlamaktadır (Baatz vd., 2008). Segmentasyon işleminin amacı, görüntüyü aynı özellikleri yansıtan anlamlı objelere ayırmaktır.

Segmentasyon sonucunda birbirine benzeyen ve tek etikete sahip olan piksellerden oluşan segmentler elde edilir. Böylece görüntü, birbirine bağlı ve çakışmayan gruplara ayrılır. Her segment, spektral, şekil, doku ve bağlam özellikleriyle tanımlanır. Böylece segmentleri oluşturan pikseller, nitelikleri ve özellikleri benzer olan tek bir kümeye sahip olmaktadır. Oluşan segmentler, daha yüksek seviyede sayısal görüntü işleme adımlarının ilk girdi parametreleri olarak kullanılmaktadır.

Yüksek çözünürlüklü görüntülere segmentasyon işlemi uygulanarak sınıf içi spektral varyasyonlar azaltılır ve bu işlem uygun ölçek parametresi ile yapıldığında sınıflandırma ve istatistiksel doğruluğu artırır (Addink, 2007). Nesne tabanlı görüntü analizlerinde, görüntü segmentasyonu genel olarak sınıflandırmanın ön aşaması olarak gerçekleştirir. Segmentasyon, özellik çıkarımı ve nesnelerin belirlenmesinde doğrudan bir etkiye sahip olduğu için sayısal görüntü analizi işlemlerinde önemli bir aşamadır. Bu nedenle nesne tabanlı sınıflandırma, segmentasyon sonucunun kalitesi ile doğrudan ilişkilidir (Radoux ve Defourny, 2008).

Segmentasyon işlemi için birçok yaklaşım bulunmasına rağmen, hâlâ bütün görüntü tiplerine uygulanabilen ve mükemmel sonuçlar sağlayan bir yaklaşım mevcut değildir. Bu nedenle, en uygun segmentasyon algoritmasının ve parametrelerinin seçimi objektif bir segmentasyon kalite analizi ile gerçekleştirilmelidir.

Bu aşamada karşılaşılan en önemli zorluklardan birisi, genellikle ilgilenilen alanların heterojen özellikte olmasıdır. Heterojenlik durumunda belirsizlikler ortaya çıkar ve istenen bilgi doğrudan elde edilemez. Söz konusu sorunlardan etkilenmeyen, kalite ve performansı ilgilendiren gereklilikleri (veri setinin boyutu ve işletim süresi) ve


yeniden üretilebilirliği sağlayabilecek az sayıda yaklaşım bulunmaktadır (Marangoz, 2009).

5.2 Definiens eCognition Yazılımında Kullanılan Segmentasyon Algoritmaları

eCognition yazılımında segmentasyon terimi, yeni görüntü nesneleri oluşturan veya mevcut görüntü nesnelerinin morfolojisini belirli ölçütlere göre değiştiren işlemler olarak tanımlanmaktadır. Bu kapsamda yazılımda yapılan bölütleme, alt bölütleme, birleştirme ve yeniden biçimlendirme işlemi segmentasyon olarak değerlendirilmektedir.

Yazılımda segmentasyon işlemleri, esas aldığı iki temel ilkeye göre adlandırılmıştır (Şekil 5.2). Bu esaslar;

- Segmentleri yukarıdan aşağıya bir yaklaşımla daha küçük parçalara bölme,
- Aşağıdan yukarıya bir yaklaşımla daha büyük nesneler elde etmek için küçük parçaları birleştirmekdir.



Şekil 5.2: eCognition yazılımında kullanılan segmentasyon algoritmaları.

Tüm segmentasyon algoritmalarının artıları ve eksileri mevcuttur. Bu nedenle hangi yöntemlerin hangi görüntüler için uygun olduğu kural seti geliştiriciler tarafından belirlenmelidir.

5.2.1 Yukarıdan aşağıya segmentasyon algoritmaları

Yukarıdan aşağıya segmentasyon algoritmaları temelde, mevcut nesneleri bölerek daha küçük nesneler elde etmek için uygulanmaktadır.

5.2.1.1 Satranç tahtası segmentasyonu

Satranç tahtası segmentasyonu, en basit segmentasyon algoritmasıdır (Şekil 5.3). Görüntüyü eşit kareler halinde segmentlere ya da piksel gruplarına ayıran bu segmentasyon işleminde görüntünün sol üst köşesinde oluşturulan kare referans alınarak görüntü bölünür (Definiens User Guide, 2014).


Satranç tahtası algoritması basit kare nesneler ürettiğinden, genellikle görüntüleri ve resim nesnelerini alt bölümlere ayırmak için kullanılmaktadır.



Şekil 5.3: Satranç tahtası segmentasyonu.

5.2.1.2 Dörtlü ağaç segmentasyonu


Görüntüyü farklı boyutlarda karelere bölerek segmentleri oluşturan segmentasyon işlemidir (Şekil 5.4). Bu nedenle, yukarıdan aşağıya doğru bir segmentasyon algoritmasıdır. Her karede ölçek parametresi ile renk farklılıkları için bir eşik değeri tanımlanabilmektedir. Satranç tahtası segmentasyonundan farkı ise, görüntünün kare ve karenin katlarına bölünmesidir (Definiens User Guide, 2014).



Şekil 5.4: Dörtlü ağaç segmentasyonu.

Dörtlü Ağaç Segmentasyonunda ilk kare oluşturulduktan sonra işlemler, aşağıdaki şekilde devam eder:

- Oluşturulan kare istenen homojenlik şartını sağlamıyorsa, her kare kendi içinde dört küçük kareye bölünür. Dolayısıyla, kare nesnedeki maksimum renk farkı, tanımlanan ölçek değerinden daha büyükse bölünme devam eder.
- Bu işlem, her karede homojenlik şartı sağlanıncaya kadar tekrarlanır (Şekil 5.5).



Şekil 5.5: Dörtlü ağaç segmentasyon yapısı (Definiens User Guide, 2014).


Dörtlü ağaç segmentasyonu sonucunda homojen bölgeler, heterojen bölgelere göre daha büyük segmentler ile temsil edilmektedir.

5.2.1.3 Kontrast filtreleme segmentasyonu

Kontrast filtreleme segmentasyonu, başlangıç bölütlemesi için çok hızlı bir algoritma olup, bazı durumlarda istenen nesneleri tek bir adımda belirleyebilmektedir. Başlangıçta istenen nesnelerden daha küçük segmentler oluşturmadığı için segment sayısı diğer yaklaşımlardan daha azdır. Elde edilen piksel grupları tematik katman

olarak depolanır. Pikseller, birinci katmandaki nesne, ikinci katmandaki nesne ve her iki katmandaki nesne olarak değerlendirilir ya da eşik değeri tarafından elimine edilir. Sonrasında, oluşan tematik katman satranç tahtası segmentasyonu kullanılarak görüntü nesnesine dönüştürülür (Şekil 5.6).


Bazı durumlarda, kontrast filtreleme algoritması genel görüntü analiz performansını iyileştirmek için analizin ilk adımı olarak kullanılmaktadır. (Definiens User Guide, 2014).



Şekil 5.6: Kontrast filtreleme segmentasyonu.

5.2.1.4 Kontrast bölme segmentasyonu

Kontrast bölme segmentasyonu, çok eşikli (multi-threshold) bölütleme yaklaşımına benzemektedir. Görüntüyü karanlık ve parlak görüntü nesnelere ayırır. Algoritma, etki alanındaki her görüntü nesnesi için ayrı ayrı en uygun eşiği belirler ve pikseller bulunduğu kareye belirlenen ölçek parametresi doğrultusunda ya dâhil edilir ya da çıkartılır (Şekil 5.7) (Definiens User Guide, 2014).




Şekil 5.7: Kontrast bölme segmentasyonu.

5.2.2 Aşağıdan yukarıya segmentasyon algoritmaları

Aşağıdan yukarıya segmentasyon algoritmaları, istenen şartlara göre mevcut nesneleri birleştirerek daha büyük nesneler elde etme amacıyla uygulanmaktadır.

5.2.2.1 Çok çözünürlüklü segmentasyon

Aşağıdan yukarıya segmentasyon algoritmaları içerisinde çok çözünürlüklü segmentasyon algoritması sıklıkla tercih edilmektedir (Baatz ve Schape 2000, Benz vd. 2004). Çok çözünürlüklü segmentasyon, bir piksellik nesnelerle ya da görüntü alt nesneleri ile başlayan bir alan birleştirme tekniğidir. Kullanıcı tarafından belirlenmesi gereken segmentasyon parametreleri ile görüntüyü farklı seviyelerde segmentlere ayırır. Böylece tek bir görüntü, her biri farklı nesneleri belirten segmentasyon seviyeleri ile ifade edilebilmektedir (Şekil 5.8).



Şekil 5.8: Üç seviyeli hiyerarşik ağ yapısı (Karakış, 2005).

Johnson (2013) nesne tabanlı sınıflandırmada en önemli sorunlardan birinin segment boyutunu ve homojenliğini etkileyen segmentasyon parametrelerinin belirlenmesi olduğunu vurgulamıştır. İstenenden daha küçük boyutta segment üreten parametreler

kullanıldığında segmentler için hesaplanan şekil ve geometri gibi spektral olmayan bilgilerin sınıflandırma doğruluğuna katkı sağlamayacağını ifade etmiştir. Ayrıca, istenen arazi örtüsü özelliğinden daha büyük boyutta segmentler üreten parametreler, birden fazla sınıfa ait piksellerin bir obje içerisine dâhil edilerek aynı sınıf etiketini almasına neden olmaktadır. Aynı zamanda, istenen arazi örtüsü özelliklerini yansıtmayan segmentlerden hesaplanan spektral olmayan bilgiler (şekil ve geometri gibi) sınıflandırma doğruluğuna katkı sağlamayacaktır. Bundan dolayı, segmentasyon işlemi öncesinde en uygun parametrelerin belirlenmesi önemli bir husustur.

Çok çözünürlüklü segmentasyonda ölçek, şekil ve renk olmak üzere 3 farklı parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Bunlardan en önemlisi ölçek parametresi olarak ifade edilmektedir (Myint vd., 2011). Bunun en önemli nedeni; ölçek parametresinin segmentlerin boyutu üzerinde önemli derecede etkisinin bulunmasıdır. Eğer ölçek parametresi büyük seçilirse; görüntüdeki detaylar kaybolacak ve dolayısıyla segmentler farklı sınıflara ait pikselleri içerecektir. Bu durum özellikle hatalı sınıflandırmalara ve sınıflandırma doğruluğunun azalmasına neden olabilmektedir. Ölçek parametresinin küçük seçilmesi ise, fazla sayıda segment oluşmasına ve dolayısıyla sınıflandırma süresinin artmasında neden olmaktadır.

Heterojenlik kriteri (f);

$$f = W_{color} * \Delta h_{color} + W_{shape} * \Delta h_{shape} \quad \left(\begin{array}{l} W_{color} \in [0,1] \\ W_{shape} \in [0,1] \\ W_{color} + W_{shape} = 1 \end{array} \right) \quad (5.1)$$

formülü ile hesaplanırken, Δh_{color} ve Δh_{shape} parametreleri ise;

$$\Delta h_{shape} = \sum_{k=1}^m W_k * \sigma_k \quad (5.2)$$

$$\Delta h_{color} = \sum_{k=1}^m W_k (n_{mg} * \sigma_{k,mg} - (n_{obj1} * \sigma_{k,obj1} + n_{obj2} * \sigma_{k,obj2})) \quad (5.3)$$

formülleri ile hesaplanmaktadır. Bu eşitliklerde;

m : bant sayısını,

W_{color} , W_{shape} : renk ve şekil parametrelerinin ağırlıkları,

W_k : k bandının ağırlığı,
 n_{mg} : birleştirilen nesnenin piksel sayısı,
 n_{obj1}, n_{obj2} : birinci ve ikinci objenin piksel sayısı,
 σ_k : k bandının standart sapması,
 $obj1, obj2$: birleşimden önceki objeleri temsil etmektedir.

Şekil parametresindeki değişim (Δh_{shape}), yumuşaklık (smoothness) ve bütünlük (compactness) olarak iki farklı parametre ile belirlenir. W_{smooth} ve W_{compt} değerleri;

$$\Delta h_{shape} = W_{compt} * \Delta h_{compt} + W_{smooth} * \Delta h_{smooth} \quad (5.4)$$

$$\Delta h_{smooth} = n_{merge} * \frac{l_{mg}}{b_{mg}} - \left(n_{obj1} * \frac{l_{obj1}}{b_{obj1}} + n_{obj2} * \frac{l_{obj2}}{b_{obj2}} \right) \quad (5.5)$$

$$\Delta h_{compt} = n_{mg} * \frac{l_{mg}}{\sqrt{n_{mg}}} - \left(n_{obj1} * \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} * \frac{l_{obj2}}{\sqrt{n_{obj2}}} \right) \quad (5.6)$$

formülleri ile hesaplanmaktadır. Bu eşitliklerde;

W_{smooth} ve W_{compt} : yumuşaklık ve bütünlük parametrelerinin ağırlık değerleri,

Δh_{smooth} ve Δh_{compt} : yumuşaklık ve bütünlük değerlerinin farkı,

l : nesnenin çevre uzunluğu,

b : bir nesneyi sınırlayan kutunun mümkün olan en kısa kenar uzunluğu olarak tanımlanır.

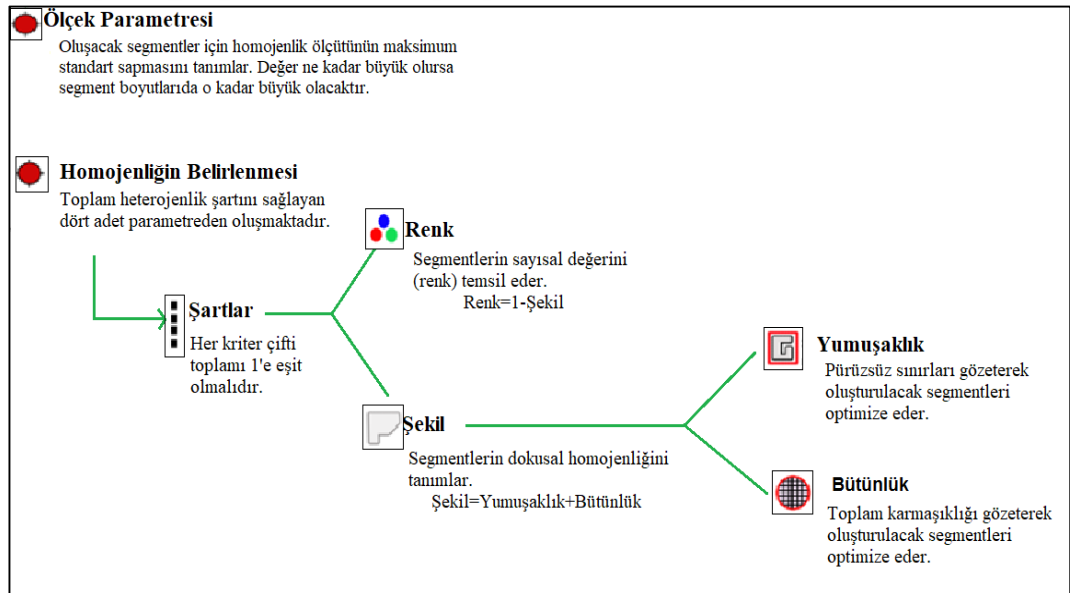
Görüntü segmentasyonun en uygun şekilde yapılabilmesi için formülleri verilen beş parametrenin (W_c , W_{color} , W_{shape} , W_{smooth} , W_{compt}) belirlenmesi gerekmektedir. Ölçek parametresi, segmentasyon işlemini durdurmak için gerekli olan parametredir. Heterojenlik kriteri (f), iki komşu nesne birleştirilmeden önce hesaplanır. Heterojenlik değişimi, ölçek parametresi tarafından belirlenen eşik değerini geçtiğinde segmentasyon işlemi biter.

Preseptte sonsuz ölçek parametresi vardır. Ancak hangi ölçek parametresinin sınıflandırma doğruluğunu artıracığını belirlemek zordur. En uygun ölçek parametresi için nicel bir ölçüt bulunmamaktadır. Ancak, görüntünün görsel yorumlanmasına bağlı olarak bir değerlendirme yapılabilir. Ayrıca sınıflandırmayı tüm olası parametre kombinasyonları ile değerlendirmek oldukça zaman alıcıdır. Bu

nedenle bu tez çalışmasında, amaçlanan doğrultuda uygun ölçek parametresini seçmek için eCognition Developer programının Cognition Network Language (CNL) ortamında Drăgut vd., (2014) tarafından oluşturulan ESP-2 yazılımı kullanılmıştır.

eCognition Developer yazılımında çok çözünürlüklü segmentasyon, ölçek, şekil, bütünlük parametreleri, bant ağırlıkları ve varsa tematik katmanlar kullanılarak yapılmaktadır. Burada;

- Ölçek parametresi, segmentler için verilen maksimum heterojenlik sınırını belirleyen bir eşik değeri olarak yorumlanabilir. Ölçek parametresi, spektral homojenliği düzenlerken, bütünlük parametresi ise, bütünlük ve yumuşaklık dengelemesini yaparak, objenin şeklini belirlemektedir.
- Renk ve şekil parametreleri ile renk ve şekil özelliklerinin segmentlerin oluşmasındaki etkisi (ağırlığı) belirlenmektedir. Şekil parametresine ağırlık verildiğinde, segmentasyon için şekil özelliklerine daha çok dikkat edilirken spektral homojenliğinin (renk) etkisi daha az olacaktır.
- Yumuşaklık ve bütünlük parametreleri ise, şekil kriterinin 0'dan büyük olduğu durumlarda yumuşaklık ve bütünlük ağırlıkları değiştirilerek segmentasyonda şekil parametresinin dikkate alacağı özellikler belirlenmelidir (Şekil 5.9).



Şekil 5.9: Homojenlik şartları (Definiens User Guide, 2014).

5.2.2.2 Çok eşikli segmentasyon

Çok eşikli segmentasyon algoritması, segmentasyon sonucu ortaya çıkan segmentleri piksel değeri olarak tanımlanan bir eşik değerini baz alarak sınıflandırır. Eşik değeri

tüm görüntü için veya oluşturulan her bir segment katmanı için ayrı ayrı belirlenebilir (Definiens User Guide, 2014).

5.2.2.3 Spektral fark segmentasyonu


Spektral fark segmentasyon algoritması, komşu segmentleri ortalama bant yoğunluk değerlerine göre birleştirir. Ortalama bant yoğunlukları arasındaki fark maksimum spektrum farkı tarafından verilen değerin altında olduğunda, komşu segmentler birleştirilir. Bu algoritma, önceden üretilmiş segmentleri bir araya getirerek mevcut segmentasyon sonuçlarını hassaslaştırmak üzere tasarlanmıştır. Piksel seviyesine dayalı segment düzeyleri oluşturmak için kullanılamaz (Definiens User Guide, 2014).

5.3 Nesne Bazında En Yakın Komşuluk Sınıflandırması

Nesne bazında en yakın komşuluk algoritması, belirli bir özellik alanındaki resim nesnelerini ve ilgilenilen sınıflar için belirlenen örnekleri kullanarak sınıflandırır. Üyelik işlevleri ile sınıflandırma, nesne özelliklerinin kullanıcı tanımlı işlevlerine dayanırken, en yakın komşu sınıflandırması, üyelik değerlerini atamak için farklı sınıf örnek setlerini kullanır.

Bunun için yazılım öncelikle, her sınıfı uygun biçimde temsil eden örneklere ihtiyaç duymaktadır. Örnek veri seti seçimi tamamlandıktan sonra algoritma, her segment için tanımlanmış özellik uzayında bulunan en yakın örnek nesneyi arar. Kullanıcı, özellik uzayı için dikkate alınması gereken özellikleri seçebilmektedir.

eCognition yazılımında tüm sınıf atamaları, 0 (atama yok) ile 1 (tam atama) aralığındaki atama değerleriyle belirlenir. Eğer bir segment, seçilmiş bir örneğe özdeş ise 1 üyelik değerini almaktadır. Özellik uzayındaki her noktanın etkin üyelik fonksiyonu, o sınıfın tüm örnekleri üzerinde bulanık fonksiyonun bir kombinasyonudur (Şekil 5.10).



Şekil 5.10: NN üyelik fonksiyonu (Definiens User Guide, 2014).

eCognition yazılımında mesafe;

$$= \sqrt{\sum_f \left(\frac{v_f(s) - v_f(o)}{\sigma_f} \right)^2} \quad (5.7)$$

formülü ile hesaplanmaktadır. Eşitlikte;

s : örnek nesne,

o : görüntü nesnenin f bandında ki değeri,

d : s ve o nesneleri arasındaki mesafe,

f : algoritmanın uygulanacağı özlellik /bant,

$V_f(s)$: f bandında bulunan örnek nesnenin değeri,

$V_f(o)$: f bandında bulunan görüntü nesnesinin değeri,

σ_f : f bandının standart sapmasını ifade etmektedir

5.4 Sınıflandırma Sonuçlarının Değerlendirilmesi

Görüntü sınıflandırma işleminin tamamlanması için doğruluk analizinin yapılması gerekmektedir. Doğruluk analizi, sınıflandırma sonucunda elde edilen verilerin referans verilerle karşılaştırılmasına dayanan bir yöntemidir. Doğruluk analizi için, sınıflandırılmış görüntü ve referans veri (yer gerçekleri) olmak üzere iki veri setine ihtiyaç duyulmaktadır. Doğruluk analizinde kullanılacak referans veri için genellikle

yersel ölçümlerle üretilen veriler, yüksek çözünürlüklü uydu görüntüleri, hava fotoğrafları ve mevcut haritalar kullanılmaktadır.

Hata matrisi, sınıflandırmanın doğruluk analizi için kullanılan en yaygın yöntemlerden biridir. Hata matrisi; referans veriden elde edilen gerçek arazi örtüsüne göre sınıflandırılan piksellerin sayısını satırlar ve sütunlar halinde düzenleyen karesel bir çizelgedir (Jensen, 2005).

Sınıflandırma sonucunda iki tür hata oluşmaktadır. Bunlar, piksellerin olması gerekenden farklı bir sınıfa atanması (error of comission) ve piksellerin uygun bir sınıfa atanamaması (error of omission) hatalarıdır (Mather, 2004).

Hata matrislerinden, çeşitli sınıflandırma doğrulukları hesaplanmaktadır. Bunlardan üretici doğruluğu (producer's accuracy), hata matrisinde köşegen elemanlarının bulundukları sütun toplamına oranı ile hesaplanırken, kullanıcı doğruluğu (user's accuracy), hata matrisinde köşegen elemanlarının, bulundukları satır toplamına oranı ile hesaplanmaktadır. Bu doğruluk değeri, herhangi bir sınıfa atanan bir pikselin bu sınıfı gerçekte temsil etme olasılığını gösterir. Sınıflandırmanın toplam doğruluğu (overall accuracy) ise, hata matrisinin tüm köşegen elemanları toplamının, matrisin tüm elemanlarının toplamına oranı ile hesaplanmaktadır (Mather, 2004).

Hata matrisi, 0 ile 1 arasında değişen kappa katsayısı ile istatistiksel olarak analiz edilir. k değeri kappa katsayısını göstermek üzere;

$$k = \frac{P_0 - P_h}{1 - P_h} \quad (5.8)$$

formülü ile hesaplanmaktadır.

P_0 değeri hata matrisinin köşegenlerindeki elemanların toplamının, her satır veya sütundaki elemanlarının toplamına oranlanması ile elde edilir.

$$P_h = \sum P_\alpha(i)P(i) \quad (5.9)$$

P_α değeri, ayrı ayrı her bir sütunun toplamının, tüm sütunların toplamına bölünmesi ile bulunmaktadır.

P değeri ise, ayrı ayrı her bir satırın toplamının, tüm satırların toplamına bölünmesi ile bulunmaktadır (Musaoğlu, 1999).

Kappa (κ) değeri, hata matrisinde doğru sınıflandırılan piksellerin rastgele uyuşum nedeniyle mi yoksa doğru uyuşum sonucu mu olduğunun bir göstergesidir ve 0 ile 1 arasında değerler almaktadır. Burada, 0.00 değeri, sınıflandırılmış ve referans verileri arasında uyuşumun olmadığını, 1.00 değeri tam uyuşum olduğunu göstermektedir (Çizelge 5.1).


Çizelge 5.1: Kappa katsayısı yorumlama (Landis ve Koch, 1977).

κ	Uyuşma yorumu
0.00	Uyuşma yok
0.00 - 0.20	Kötü uyuşma
0.21 - 0.40	Az uyuşma olması
0.41 - 0.60	Orta derecede uyuşma olması
0.61 - 0.80	İyi derecede uyuşma olması
0.81 - 0.99	Neredeyse tam uyuşma olması
1.00	Tam uyuşma

6. YÖNTEM

6.1 Çalışma Alanı

Çalışma alanı, Türkiye'nin Marmara bölgesinde bulunan Bursa ili, Karacabey ilçesinin güneybatısındadır. Yaklaşık $18 \text{ km} \times 13.5 \text{ km}$ büyüklüğünde bir alanı kapsamaktadır. Alan, $40^{\circ} 07' 44'' - 40^{\circ} 13' 43''$ Kuzey Enlemleri ile $28^{\circ} 10' 31'' - 28^{\circ} 20' 28''$ Doğu Boylamları arasında yer almaktadır (Şekil 6.1).




Şekil 6.1: Çalışma alanının konumu.

Çalışma alanının, Karacabey ilçesine göre konumu ve yerleşim merkezleri Google Earth görüntüsü üzerinde Şekil 6.2’de gösterilmiştir.



Şekil 6.2: Çalışma alanı sınırları ve yerleşim merkezleri.

Domates, mısır, biber, buğday, pirinç ve şeker pancarı bölgede yetiştirilen temel ürünler arasında yer almaktadır. Buğday haricinde diğer tüm bitkiler sulanır. Ürünlerin fenolojik özellikleri Şekil 6.3'te verilmiştir.



Şekil 6.3: Ürünlerin fenolojik özellikleri (Türker ve Özdarıcı, 2011).

Çalışma alanında 1988-1992 yılları arasında arazi toplulaştırma projesi yapıldığından dolayı çoğu parsel dikdörtgen şeklindedir. Fakat, arazi toplulaştırma uygulamasının üzerinden geçen süre içerisinde tarım parsellerinde parçalanma meydana gelmiştir. Bu nedenle çalışma alanının özellikle kuzeydoğu ve güneybatı bölgelerinde küçük alanlı tarım arazileri oluşmuştur. Çalışma alanında bulunan tarım parsellerinin alanları 0.0074 ila 48 ha arasında değişmektedir (Çizelge 6.1) (Türker ve Özdarıcı, 2011).

Çizelge 6.1: Parsellerin alanlarına göre dağılımı (Türker ve Özdarıcı, 2011).

Parsel Sayısı	Alan (ha)	Yüzde (%)
929	0.0074 – 0.49	22.47
1034	0.5 – 0.99	25.0
1850	1 – 4.99	44.85
216	5 – 9.99	5.28
99	10- 47.99	2.39

6.2 Kullanılan Veri ve Yazılımlar

Türker ve Özdarıcı (2011) tarafından yapılan çalışmada, gerekli görüntü ön işleme adımları uygulanarak elde edilen 15 Temmuz 2004 tarihli ve 1m konumsal çözünürlüklü keskinleştirilmiş (pan sharpened) IKONOS uydu görüntüsü ve 11-14 Temmuz 2004 tarihleri arasında sahadan toplanan 1230 parseli içeren yer gerçekleri verileri kullanılmıştır. Çalışma alanında çok sayıda çoklu ürün içeren tarım parselleri

mevcut olduğundan söz konusu parseller sayısallaştırılarak dinamik ürün sınırları (alt sınırlar) belirlenmiştir. Alt sınırların yer gerçeği verisine eklenmesiyle çalışma alanında bulunan parsel sayısı 4128'e yükselmiştir. Bu tez çalışması kapsamında, bahsedilen IKONOS uydu görüntüsü ve yer gerçeği verisi kullanılmıştır.

24 Eylül 1999 tarihinde Kaliforniya Vanderberg hava sahasından ABD tarafından uzaya gönderilen IKONOS uydusu Geoeeye tarafından çalıştırılan ilk ticari yüksek çözünürlüklü uydudur. Bir IKONOS görüntüsünün arazide kapladığı alan ortalama 11 km x 11 km olup, uydu dünya çevresinden bir kez geçişinde 10.000 km²' lik bir alanın görüntüsü alabilmektedir. IKONOS uydusunun iki temel ürünü yanında, pankromatik (1m) ve multispektral (4m) görüntüleri birleştirilerek, 1m çözünürlüğe sahip keskinleştirilmiş renkli görüntüler de elde edilebilmektedir. IKONOS uydu ve görüntü özellikleri Çizelge 6.2 ve 6.3'de verilmiştir (URL-5).

Çizelge 6.2: Ikonos uydu özellikleri (URL-5).

Yükseklik	681 km
Ağırlık	720 kg
Eğim Açısı	98.1°
Yörünge Hızı	7.5 km/saniye
Yersel Hız	6.8 km/saniye
Yörünge Periyodu	98 dakika
Aynı noktadan tekrar geçiş zamanı	40° enleminde yaklaşık 3 gün
Yörünge Tipi	Kutupsala yakın, Güneş uyumlu
Ekvator Geçiş Zamanı	≈ 10:30 (alçalma durumunda)

Çizelge 6.3: Ikonos görüntü özellikleri (URL-5).

	Bant Aralıkları (µm)	Geometrik Çözünürlük (m)	Dinamik Aralık (bit)
MS	0.445 - 0.516 (Mavi) 0.506 - 0.595 (Yeşil) 0.632 - 0.698 (Kırmızı) 0.757 - 0.853 (NIR)	4	11
PAN	0.45 - 0.90	1	

Kullanılan IKONOS uydu görüntüsü ve yer gerçeği verileri Şekil 6.4’de gösterilmektedir.



Şekil 6.4: IKONOS uydu görüntüsü ve yer gerçeği verileri.


Çalışma kapsamında, eğitim alanlarının belirlenmesi, segmentasyon ve nesne tabanlı sınıflandırma işlemleri Definiens eCognition 9.1 yazılımı ile gerçekleştirilmiştir. Trimble firmasına ait Definiens eCognition yazılımı, görüntü işleme alanında mevcut yazılımlar içerisinde en gelişmiş özelliklere sahip yazılımlardan birisi olarak bilinmektedir. Geleneksel görüntü sınıflandırma yöntemlerinin eksiklik ve kısıtlamalarını gidermek için geliştirilen eCognition yazılımı, görüntü nesnelerinin sınıflandırma işleminde önemli semantik bilgiler sağladığı varsayımına dayanır ve görüntü analiz işlemlerinde nesne tabanlı ve çok ölçekli bir yaklaşım sunmaktadır.

Nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon işleminde ölçek parametresini otomatik olarak belirlemek için eCognition Developer programının Cognition Network Language (CNL) ortamında Drăgut vd., (2014) tarafından geliştirilen, ESP-2 yazılımı kullanılmıştır. Ayrıca, NDVI ve doku özellikleri PCI Geomatica yazılımı kullanılarak elde edilmiştir. Diğer taraftan, sınıflandırma sonucunun genelleştirilmesi, hata matrislerinin oluşturulması ve doğruluk analizi işlemleri Esri firması tarafından geliştirilen ArcGIS yazılımı ile yapılmıştır.

6.3 Yöntem

Şekil 6.5’ de görülen yöntem akış diyagramında görüleceği üzere bu tez çalışmasında uygulanan yöntem on temel aşamadan oluşmaktadır. Bu aşamalar;

- 1- Yapılacak segmentasyon işlemi için uygun parametrelerin belirlenmesi,
- 2- Sınıfların belirlenmesi,
- 3- Yardımcı verilerin oluşturulması,
- 4- Çok çözünürlüklü segmentasyon işlemi,
- 5- Eğitim alanlarının seçilmesi,
- 6- Sınıflandırma işlemi,
- 7- Sınıflandırma sonrası işlemler,
- 8- Parsel sınırlarından referans parsellerin seçilmesi,
- 9- Referans parsellerin ağırlık merkezlerinin belirlenmesi,
- 10- Doğruluk analizidir.



Şekil 6.5: Yöntem akış diyagramı.

Nesne tabanlı sınıflandırma yaklaşımlarının önemli aşamalarından biri olan segmentasyon işlemi için ölçek, şekil ve bütünlük parametreleri ESP-2 ve Deneme-yanılma yöntemlerinin birlikte kullanılmasıyla belirlenmiştir. Bu parametrelerin en önemlisi olan ölçek parametresinin otomatik olarak belirlenmesi için ESP-2 yazılımı kullanılmış ve ESP-2 sonucunda elde edilen Lokal varyans-Değişim oranı grafiği yorumlanarak uygun ölçek parametresi belirlenmiştir. Belirlenen ölçek parametresine yakın dört adet ölçek parametresi ile farklı şekil ve bütünlük parametre değerleri denenerek çalışma alanı için en uygun segmentasyon parametreleri belirlenmiştir.

Mevcut olan yer gerçeği verisi kullanılarak çalışma alanında bulunan Mısır, Domates, Biber, Pirinç, Şeker Pancarı, Anız ve Mera olmak üzere yedi adet sınıf belirlenmiştir. Fakat aynı ürünün ekili olduğu tarım parsellerinde farklı yansıma özellikleri mevcut olduğundan, aynı ürünü temsil eden birkaç sınıf oluşturulmuş ve bu sınıflar sınıflandırma sonrasında birleştirilmiştir.

Segmentasyon ve sınıflandırma işlemlerinde kullanılmak üzere yardımcı veriler oluşturulmuştur. Bunun için öncelikle IKONOS uydu görüntüsünün tüm bantlarına 3x3 boyutunda GAUSS yumuşatma filtresi uygulanmıştır. Bitki örtüsü ile ilgili çalışmalarda sıklıkla kullanılan endekslerden biri olan NDVI oluşturulmuştur. Ayrıca, homojenlik, zıtlık, entropi, farklılık, ortalama ve varyans olmak üzere 6 adet GLCM doku ölçüm yöntemi belirlenmiş ve bu yöntemler IKONOS uydu görüntüsünün orijinal bantlarına uygulanarak 24 bantlık ek veri seti elde edilmiştir.

IKONOS uydu görüntüsünün tüm bantları ve NDVI kullanılarak görüntünün çok çözünürlüklü segmentasyonu yapılmıştır. Definiens eCognition yazılımında mevcut olan en yakın komşuluk sınıflandırıcısını uygulamak için, belirlenen alt sınıflarda dâhil olmak üzere toplam 15 sınıfa ait ilgili eğitim alanları belirlenmiştir. Seçilen eğitim alanları kullanılarak orijinal bantlar ve elde edilen 24 bantlık ek veri seti ile birlikte toplam 29 bant üzerinden sınıflandırma işlemi yapılmıştır.

Sınıflandırma işleminden sonra, elde edilen sınıflar için, genelleştirme ve yumuşatma işlemleri yapılarak sınıflandırılmış çıktının kalitesi arttırılmıştır.

Sınıflandırma doğruluğunu belirlemek için ise, ArcGIS yazılımında tarım parsellerinin ağırlık merkezleri belirlenerek sınıf etiketleri bulunan bir nokta katmanı oluşturulmuştur. Bu nokta katmanı, sınıf etiketleri bulunan sınıflandırma sonuçları ile ilişkilendirilerek sonuçlar değerlendirilmiştir.

6.4 Yardımcı Verilerin Oluşturulması

Gerçekleştirilen segmentasyon neticesinde elde edilen görüntü nesneleri için tanımlanan özellikler Çizelge 6.4’de gösterilmiştir. Tanımlanan bu özelliklerin seçiminde önceki çalışmalarda en sık kullanıldığı tespit edilenler tercih edilmiştir. Her bir görüntü nesnesi için belirlenen özelliklerin tanımlanmasıyla nesne tabanlı sınıflandırma işlemine esas olan ve 29 özelliği (bandı) içeren çok boyutlu bir veri seti oluşturulmuştur.

Çizelge 6.4: Görüntü nesneleri için tanımlanan özellikler.

Temel Spektral Bilgiler	Özellik	Açıklama
	NDVI GAUSS Filtresi (3x3)	IKONOS K ve YKÖ Bantları IKONOS Tüm Bantlar
Doku Özellikleri	Homojenlik Zıtlık Entropi Farklılık Ortalama Varyans	IKONOS Tüm Bantlar (Tüm yönlerde GLCM, 5x5)

Hem segmentasyon hem de sınıflandırma işlemlerinde kullanılmak üzere PCI Geomatica yazılımında NDVI oluşturulmuştur (Şekil 6.6). Kırmızı ve yakın kızılötesi bantlar kullanılarak hesaplanan NDVI, bitki örtüsü analizinde en sık kullanılan endekslerden biridir. Eşitlik 6.1’de gösterildiği gibi, yakın kızılötesi bant ile kırmızı bant değerlerinin farkının toplamına bölünmesiyle hesaplanan NDVI değerinin yüksek olması, ilgili bölgelerde sağlıklı bitki örtüsünün fazla olması şeklinde yorumlanırken, değerin düşük olduğu bölgelerde sağlıklı bitki örtüsünün az olduğu ya da olmadığı şeklinde yorumlanmaktadır.

$$NDVI = (YKÖ - KIRMIZI)/(YKÖ + KIRMIZI) \quad (6.1)$$



Şekil 6.6: NDVI görüntüsü.

Görüntüdeki gürültü, sınıflandırma işleminden önce bir yumuşatma filtresi uygulanarak belirli bir ölçüde azaltılabilir (Gonzalez ve Woods, 2007). Bu nedenle sınıflandırma öncesinde uydu görüntüsünün orijinal dört bandına eCognition Definiens Developer 9.1 yazılımı kullanılarak Eşitlik 6.2’de verilen Gauss filtresi uygulanmıştır. Çalışma alanındaki parsel boyutlarına dikkat edilerek filtre boyutu 3x3 olarak seçilmiştir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (6.2)$$

Tanımlanan nesne özelliklerinden bir diğeri ise, yine eCognition yazılımında bulunan parlaklık (Brightness) değeridir. Sınıflandırma işleminde parlaklık özelliği kullanılacak görüntü bantları kullanıcı tarafından seçilir ve yazılım Eşitlik 6.3’ü uygulayarak ilgili bantların parlaklık özelliklerini hesaplamaktadır.

$$\bar{c}(v) = \frac{1}{W^B} \sum_{k=1}^K W_k^b \bar{c}_k(V), \quad W^B = \sum_{k=1}^K W_k^b \quad (6.3)$$

Bu eşitlikte;

W_k^b : ilgili k bantının 0 ile 1 arasında değişen parlaklık değer ağırlığını,

K : hesaplamada kullanılacak bant sayısını,

W^B : hesaplamada kullanılacak olan bantların ağırlıklarının toplamını,

$\bar{c}_k(V)$: V görüntü nesnesinin ilgili bantlardaki yoğunluk (intensity) değerini ifade etmektedir.

Ayrıca sınıflandırma işleminde Bölüm 4.4’de ayrıntılı olarak açıklanan 6 adet doku ölçüm yöntemi (homojenlik, zıtlık, farklılık, ortalama, varyans ve entropi) görüntünün mavi, yeşil, kırmızı ve yakın kızıl ötesi bantlarına tüm yönlerde (yatay, dikey ve iki diagonal) ve 5x5 filtre boyutu kullanılarak uygulanmıştır. Şekil 6.7’de bazı bantlara doku özelliklerinin uygulanması ile elde edilen doku bantları görülmektedir.

6.5 Segmentasyon İşlemi

IKONOS uydu görüntüsü Mavi (M), Kırmızı (K), Yeşil (Y) ve YKÖ bantlarına NDVI bantının eklenmesiyle oluşan veri setinin segmentasyonu için eCognition yazılımının sunduğu çok çözünürlüklü segmentasyon yöntemi kullanılmıştır. Çok çözünürlüklü segmentasyon için Bölüm 5.2.2.1’de açıklanan üç adet parametre (ölçek, şekil, bütünlük) ve bu parametrelere ait değerlerin belirlenmesi gerekmektedir.

Bölge birleştirme yöntemine dayanan çok çözünürlüklü segmentasyon algoritmasında öncelikle her piksel, ayrı bir nesne olarak değerlendirilir ve birleştirme işlemi renk ve homojenlik ölçütlerinin ağırlıklarına göre devam eder ya da durdurulur. Heterojenlik artışları en küçük olan nesne çiftleri iteratif bir yöntemle birleştirilir. Bu işlem, en küçük artışın kullanıcının belirlediği eşik değerini geçene kadar devam eder. Bu eşik değeri ölçek parametresi ile belirlenmektedir.

Çalışmada, öncelikle ölçek parametresinin belirlenmesi amacıyla ESP-2 yazılımı kullanılmıştır. Buradan elde edilen ölçek değerine yaklaşık olan değerler olarak belirlenen 35, 40, 45 ve 50 ölçek değerleri için en uygun şekil ve bütünlük parametreleri değerleri deneme yanılma yöntemi ile belirlenmiştir.

M, K, Y, YKÖ ve NDVI bantlarının kullanıldığı segmentasyon işleminde, bitki örtüsü karakteristiklerini daha belirgin şekilde ifade eden ve literatürde sıklıkla kullanılan NDVI ve YKÖ bantları için ağırlık değerleri 3, ölçek parametresi değeri 40, homojenlik ölçütünün belirlenmesinde etkili olan şekil ve bütünlük parametrelerinin ağırlık değerleri sırasıyla 0.3 ve 0.5 alınarak çok çözünürlüklü segmentasyon işlemi gerçekleştirilmiştir.



Kırmızı_Entropi



Yeşil_Varyans




Kırmızı_Homojenlik



YKÖ_Farklılık



YKÖ_Ortamala



Kırmızı_Zıtlık

Şekil 6.7: Sınıflandırma işleminde kullanılan bazı doku bantları.

6.5.1 ESP yöntemi ile ölçek parametresinin belirlenmesi

Çok çözünürlüklü görüntü segmentasyonu, nesne tabanlı görüntü analizinin ilk ve en önemli aşamalarından biri olmasına rağmen, günümüzde segmentasyon için en uygun ölçeği kesin olarak belirleyebilen bir yazılım bulunmamaktadır. Fakat, son yıllarda ölçek parametresini otomatik olarak belirlenmesi için ölçek parametresi tahmin etme araçları geliştirilmeye başlanmıştır. Drăgut vd., (2010) tarafından, eCognition Developer programının Cognition Network Language ortamında geliştirilen ESP (Estimation of Scale Parameter) yazılımı bunlardan en çok tercih edilenidir (D'oleire-Oltmanns ve Tiede, 2014). ESP yazılımı iteratif bir yöntem ile birçok segment katmanı seviyesinde aşağıdan yukarıya (bottom-up) yaklaşımına göre görüntü nesnelerini üretir ve her ölçek için lokal varyans değerlerini hesaplar.

Drăgut vd., (2014) tarafından, lokal varyansın istatistiksel analizine dayalı ESP-2 yazılımı geliştirilmiştir. ESP-2 yazılımında, heterojenlik değişimi ölçek parametrelerine göre çizilen lokal varyans değişkeni ile yorumlanmaktadır. Lokal varyansın değişim oranlarındaki (rate of change) eşik değerleri farklı ölçek parametrelerinde anlamlı olabilecek nesnelerin yorumlanmasını sağlamaktadır.

ESP-2 yazılımı, eCognition yazılımına kural seti olarak yüklendikten sonra, ölçek parametresinin belirlenmesi için 12 adet parametrenin kullanıcı tarafından tanımlanması gerekmektedir (Şekil 6.8). Bu parametreler;

- Hiyerarşi kullanımı onayı (Use of Hierarchy),
- Hiyerarşi kullanım tipi (Hierarchy: TopDown=0 or BottomUp=1),
- Üç adet farklı ölçek parametresi başlangıcı (Starting scale_Level 1, 2, 3),
- Üç adet farklı ölçek parametresi artış miktarı (Step size_Level 1, 2, 3),
- Şekil ve bütünlük (Shape ve Compactness) parametrelerinin ağırlığı (0.1-0.9),
- Lokal varyans - değişim oranı grafiğinin üretilmesi onayı (Produce LV Graph),
- Döngü sayısı (Number of Loops)'dır.

İşlem sonucunda oluşan lokal varyans - değişim oranı grafiği yorumlanarak uygun ölçek parametreleri belirlenmektedir (Şekil 6.9). Ayrıca ESP-2 yazılımı, yukarıda belirtilen değerler kullanarak üç adet segmentasyon seviyesi oluşturmaktadır (Şekil 6.10).

Edit Process

Name: ☒ Automatic

ESP2 (Estimation of Scale Parameter 2)[1,1,20,2,20,3,20,4,]

Algorithm: ESP2 (Estimation of Scale Parameter 2)

Domain: execute

Parameter	Value
Threshold condition	---
Map	From Parent

Loops & Cycles

☒ Loop while something changes only

Number of cycles: 1


Algorithm Description

Algorithm parameters


Parameter	Value
Select map	main
Use of Hierarchy (0=no; 1=yes)	1
Hierarchy: TopDown=0 or Botto...	1
Starting scale_Level 1	20
Step size_Level 1	2
Starting scale_Level 2	20
Step size_Level 2	3
Starting scale_Level 3	20
Step size_Level 3	4
Shape (between 0.1 and 0.9)	0.5
Compactness (between 0.1 and...	0.5
Produce LV Graph (0=no; 1=yes)	1
Number of Loops	30

Execute Ok Cancel Help

Şekil 6.8: ESP-2 yazılımı parametre ayarlama görüntüsü.



Şekil 6.9: Lokal varyans ve değişim oranı grafiği.



Şekil 6.10: ESP-2 ile elde edilen segmentasyon seviyeleri.

Bu tez çalışmasında, kullanılan 1 m çözünürlüklü keskinleştirilmiş IKONOS uydu görüntüsü için, ESP-2 yazılımı ile 40 ölçek parametresi değerine ulaşılmıştır. Şekil ve bütünlük parametrelerinin de belirlenmesi için 40 değerine yakın olacak şekilde 35, 40, 45 ve 50 değerleri seçilmiştir. Bu değerler ile farklı şekil ve bütünlük değerleri deneme yanılma yaklaşımı ile değerlendirilerek kesin karar verilmiştir.

Ayrıca, işlem sonucunda sunulan üç farklı segmentasyon seviyesi yeterli görülmediğinden dolayı ESP-2 yazılımı ile elde edilen ölçek parametresine yakın değerler belirlenerek şekil ve bütünlük parametreleri deneme yanılma yaklaşımıyla belirlenmiştir.

6.5.2 Deneme yanılma yaklaşımı ile tüm segmentasyon parametrelerinin belirlenmesi

Yukarıda da bahsedildiği üzere, segmentasyon işleminde ölçek, şekil ve bütünlük parametreleri olmak üzere üç adet parametre esastır. Şekil parametresinin ağırlığı arttığında, farklı şekillere sahip alanlar kolayca ayırt edilebilir. Fakat benzer özellikler gösteren ürünlerin ekili olduğu ve aynı ekim dönemine ait komşu tarım parselleri, aralarından geçen bir yol olmasına rağmen algılanamayabilir. Çünkü algoritma, tarım parsellerini belirlemek için parsellerin şekil özelliklerinde yeterli bir fark arar. Ayrıca, parsel sınırlarının ve yol çizgisinin benzer spektral değerlere sahip olması durumunda iki komşu parsel tek bir segment ile temsil edilebilmektedir. Bu durumun tersine, renk parametresinin ağırlığının artması, alanlar arasındaki yolların etkili bir şekilde tanınmasına bağlı olarak, aynı veya benzer türde ürünlerin ekili olduğu tarım parsellerinin sahip olduğu küçük farklarla bile algoritma tarafındam ayırt edilebilmesinde önemli bir bir etkiye sahiptir (Zhao vd., 2012).


Bütünlük parametresi değerinin artması ise, keskin sınırların veya kentsel yapıların iyi bir şekilde ayrılmasını sağlamaktadır. Fakat, yansıma değeri göz ardı edildiği için birbirinden çok farklı özelliklere sahip bölgeleri birleştirebilir. Bütünlük parametresi, kompakt bölgeler araması nedeniyle, kapalı poligonlar oluşturma eğilimindedir. Bu nedenle, bütünlük parametresinin ağırlığı arttırıldığında, yol, demiryolu, nehir gibi yerlerde iyi sonuçlar alınamayabilir. Bazı durumlarda avantaj sağlamasına rağmen, ağırlığının mümkün olduğunca az belirlenmesi önerilmiştir. Bütünlük değerine gerekenden fazla ağırlık verilmesinin bir diğer dezavantajı, küçük varyasyonlarda dahi aynı alanlarda aşırı bölütlemeye neden olmasıdır (Zhao vd., 2012).

Bu bilgiler ışığında, ölçek parametresi için 35, 40, 45 ve 50 değerleri, şekil parametresi için 0.5, 0.6, 0.7 değerleri ve bütünlük parametresi için de 0.3, 0.4 ve 0.5 değerleri olmak üzere toplam 36 adet kombinasyon denenerek bu çalışma için en uygun parametre değerleri belirlenmiştir (Çizelge 6.5). Bu parametre değerleri kullanılarak gerçekleştirilen segmentasyon sonuçları Şekil 6.12, 6.13, 6.14 ve 6.15’de görülmektedir.


Çizelge 6.5: Segmentasyon işleminde kullanılan parametre kombinasyonları.

Segmentasyon Parametresi	Kombinasyonlar								
	A	B	C	D	E	F	G	H	I
Şekil	0.5	0.6	0.7	0.5	0.6	0.7	0.5	0.6	0.7
Bütünlük	0.3	0.3	0.3	0.4	0.4	0.4	0.5	0.5	0.5


Belirlenen ölçek, şekil ve bütünlük parametreleriyle gerçekleştirilen denemeler sonucunda elde edilen segment sayıları incelendiğinde, ölçek parametresinin oluşturulacak segment sayısı üzerinde ağırlıklı etkisi görülmektedir (Şekil 6.11).




Şekil 6.11: Farklı parametreler sonucunda elde edilen segment sayıları.




Şekil 6.12: Ölçek 35. A₃₅=Şekil 0.5, Bütünlük 0.3; B₃₅=Şekil 0.6, Bütünlük 0.3; C₃₅=Şekil 0.7, Bütünlük 0.3; D₃₅=Şekil 0.5, Bütünlük 0.4; E₃₅=Şekil 0.6, Bütünlük 0.4; F₃₅=Şekil 0.7, Bütünlük 0.4; G₃₅=Şekil 0.5, Bütünlük 0.5; H₃₅=Şekil 0.6, Bütünlük 0.5; I₃₅=Şekil 0.7, Bütünlük 0.5.



Şekil 6.13: Ölçek 40. A_{40} =Şekil 0.5, Bütünlük 0.3; B_{40} =Şekil 0.6, Bütünlük 0.3; C_{40} =Şekil 0.7, Bütünlük 0.3; D_{40} =Şekil 0.5, Bütünlük 0.4; E_{40} =Şekil 0.6, Bütünlük 0.4; F_{40} =Şekil 0.7, Bütünlük 0.4; G_{40} =Şekil 0.5, Bütünlük 0.5; H_{40} =Şekil 0.6, Bütünlük 0.5; I_{40} =Şekil 0.7, Bütünlük 0.5.




Şekil 6.14: Ölçek 45. A_{45} =Şekil 0.5, Bütünlük 0.3; B_{45} =Şekil 0.6, Bütünlük 0.3; C_{45} =Şekil 0.7, Bütünlük 0.3; D_{45} =Şekil 0.5, Bütünlük 0.4; E_{45} =Şekil 0.6, Bütünlük 0.4; F_{45} =Şekil 0.7, Bütünlük 0.4; G_{45} =Şekil 0.5, Bütünlük 0.5; H_{45} =Şekil 0.6, Bütünlük 0.5; I_{45} =Şekil 0.7, Bütünlük 0.5.



Şekil 6.15: Ölçek 50. A₅₀=Şekil 0.5, Bütünlük 0.3; B₅₀=Şekil 0.6, Bütünlük 0.3; C₅₀=Şekil 0.7, Bütünlük 0.3; D₅₀=Şekil 0.5, Bütünlük 0.4; E₅₀=Şekil 0.6, Bütünlük 0.4; F₅₀=Şekil 0.7, Bütünlük 0.4; G₅₀=Şekil 0.5, Bütünlük 0.5; H₅₀=Şekil 0.6, Bütünlük 0.5; I₅₀=Şekil 0.7, Bütünlük 0.5.


Yapılan denemeler sonucunda, ölçek parametresi için 40, şekil parametresi için 0.5 ve bütünlük parametresi için 0.3 değerleri kullanılarak gerçekleştirilen segmentasyon işlemi çalışma alanındaki arazi örtüsü sınırlarını en iyi belirleyen değerler kombinasyonu olduğu görülmüştür. Ayrıca, çok çözünürlüklü segmentasyon parametreleri girilirken YKÖ ve NDVI bantlarının ağırlıkları 3 alınmıştır. Bu değerler ile elde edilen 4917 adet segmet kullanılarak sınıflandırma işlemine devam edilmiştir (Şekil 6.16).



Şekil 6.16: Ölçek parametresi için 40, şekil parametresi için 0.5 ve bütünlük parametresi için 0.3 değerleri kullanılarak gerçekleştirilen segmentasyon sonucu.

Ekran üzerinde yapılan görsel incelemeler sonucunda, aynı tarım parseli içerisinde yapılan çoklu ekimlerin, parsellerin içerisinde bulunan çeşitli yapıların (taş öbekleri ve kuyu vb.) ve parsel içi spektral varyasyonların bir parselin birkaç segment ile temsil edilmesine neden olduğu görülmüştür (Şekil 6.17).


Bu gibi durumlar ve ölçek parametresinin küçük seçilmesi nedeniyle fazla sayıda segment oluşmuştur. Fakat söz konusu segmentler, sınıflandırma sürecinde ve sonrasında birleştirilebileceğinden dolayı ilgili nesne sınırlarını iyi bir şekilde temsil ettiği sürece, segmet sayısının fazla olmasının (over-segmented) sınıflandırma sonucuna olumsuz yönde etkisi bulunmamaktadır (Drăgut vd., 2014).



Şekil 6.17: a: İçinde çoklu ekim yapılmış parsel, b: İçinde kuyu bulunan parsel.


6.6 Sınıfların ve Eğitim Verilerinin Belirlenmesi

Gerçekleştirilecek nesne-tabanlı sınıflandırma için mısır, domates, biber, mera, pirinç, şeker pancarı ve anız olmak üzere 7 adet sınıf belirlenmiştir Aynı ürünün ekili olduğu bazı tarım parsellerinde ürünün olgunluk derecesine veya ekim zamanına bağlı olarak farklı nesne özellikleri göstermektedir. Bunun için aynı sınıfa ait olan bu parseller öncelikle birkaç sınıf halinde düzenlenmiş ve eğitim alanları bu sınıflar için ayrı ayrı toplanmıştır. Örneğin; pirinç sınıfı için iki farklı sınıf (Pirinç-1 ve Pirinç-2) oluşturularak eğitim alanları seçilmiştir (Şekil 6.18).




Şekil 6.18: Domates ve pirinç sınıflarının ekili olduğu parsellerden örnekler.

Böylece, 15 adet sınıf için eğitim alanları belirlenerek sınıflandırma işlemi yapıldıktan sonra aynı ürüne ait alt sınıflar birleştirilerek değerlendirilmiştir. Bu çalışmada kullanılan arazi örtüsü sınıfları (ürün türleri) ve bu sınıflara ait alt sınıflar Şekil 6.19’da gösterilmektedir.



Şekil 6.19: Çalışma alanında belirlenen sınıflar.


Sınıfların belirlenmesi işleminden sonra bu sınıflara ait eğitim verilerinin toplanması işlemine geçilmiştir. Eğitim alanları seçiminde, seçilecek ilgili görüntü segmentinin parseli iyi bir şekilde temsil etmesine ve seçilecek görüntü segmentlerinin homojen dağılımlı olmasına dikkat edilmiştir. Tüm sınıflar için eğitim alanları yer gerçekleri verileri doğrultusunda belirlenmiştir. Her sınıf için seçilen eğitim alanları Şekil 6.20’de gösterilmektedir.




Şekil 6.20: Seçilen eğitim alanları.

6.7 Segmentlerin Sınıflandırılması ve Sınıflandırma Sonrası İşlemler

Sınıflandırma işleminden önce eCognition yazılımının sağladığı *Sample Editör* penceresi kullanılarak her sınıf için her banttaki spektral yansıma değerleri ve eğitim alanı olarak seçilen segmentlerin sınıflandırmada kullanılacak bantlardaki histogramları incelenmiştir. İncelemeler sonucunda mısır, şeker pancarı, anız ve pirinç sınıflarına ait histogramlar incelendiğinde belirgin ayrımlar görülmüştür. Ancak, özellikle domates ve biber sınıflarının tanımlanan veri setinin hemen hemen tüm bantları üzerindeki dağılımının benzer aralıkta olduğu görülmüştür. Şekil 6.21 ve Şekil 6.22’de domates ve biber sınıflarının en çok örtüşme gösterdiği bantlardaki histogram değerleri verilmiştir. Histogramdaki örtüşme değerleri incelendiğinde, domates ve biber sınıflarının ayrımı oldukça zor olduğundan bu iki sınıf birleştirilerek değerlendirilmiştir.




Şekil 6.21: Biber_2 ve Domates_2 sınıflarına ait histogramlar.




Şekil 6.22: Biber_2 ve Domates_3 sınıflarına ait histogramlar.

Bu işlemlerden sonra sınıflandırma işlemine geçilmiştir. eCognition yazılımı temelde en yakın komşuluk ve bulanık üyelik (fuzzy membership) fonksiyonları olmak üzere iki sınıflandırıcı sağlamaktadır. Bu çalışmada en yakın komşuluk sınıflandırması kullanılmıştır. En yakın komşu sınıflandırıcı, kullanıcının her sınıf için karar vermesi gereken örnek nesneler yardımıyla sınıfları oluşturan bir yöntem olup Bölüm 4.4’de açıklanmıştır.

En yakın komşu sınıflandırması için öncelikle sınıflandırma işleminde kullanılacak özellikler (NDVI, texture bantları vb.) seçilerek özellik uzayı tanımlanmıştır (Şekil 6.23). Daha sonra, ilgili sınıflar seçilmiştir (Şekil 6.24). Böylelikle en yakın komşu sınıflandırması için gereken özellik uzayı tanımlanmış ve segmentasyon ile elde edilen görüntü segmentleri bu uzayda tanımlanan eğitim alanlarına göre sınıflandırılmıştır.



Şekil 6.23: Özellik uzayının tanımlanması.




Şekil 6.24: Sınıfların seçilmesi.

Nesne tabanlı sınıflandırma işleminde, sınıflara ait segment sayılarının fazla tutulmasından (over segmentation) dolayı, bazı parseller birden çok segment ile temsil edilmiştir. Dolayısıyla, her sınıf için ilgili segmentler eCognition yazılımında tanımlı birleştirme (region merge) işlemi ile tek bir sınıf altında toplanmıştır. Daha sonra, birleştirilen sınıflandırma sonuçları “.shp” formatında kaydedilmiştir. Sınıflandırma sonrası işlemler için, ArcGIS yazılımı Spatial Analyst modülünün sağladığı genelleme araçları kullanılarak genelleştirme ve yumuşatma işlemleri


Çoğunluk filtresi, hücreleri belirlenen komşuluk sınırları içinde değişimini sağlamaktadır. Bu değişim yapılmadan önce filtrenin çalışması için iki şartın sağlanmış olması gerekmektedir. Bunlardan birincisi, hücrelerin en az yarısının (belirtilen parametreye bağlı olarak) aynı değere sahip olması gerekliliği, ikincisi ise; hücrelerin belirtilen filtrenin merkezine bitişik olması gerekliliğidir. Hücrelerin mekânsal tutarlılığı ile ilgili olan ikinci ölçüt, mekânsal deformasyonu en aza indirir. Eğer bu ölçütler sağlanmazsa, değişim meydana gelmez ve hücre değeri korunur (Şekil 6.25).





Girdi Raster
 Çıktı Raster
Veri Yok

Gerçekleştirilen sınıflandırma sonrası işlemler neticesinde elde edilen sınıflandırılmış uydu görüntüsü Şekil 6.27’de gösterilmektedir.




Şekil 6.27: Nesne-tabanlı yöntemle sınıflandırılmış uydu görüntüsü.

6.8 Sınıflandırılmış Görüntünün Doğruluk Analizi

Sınıflandırılmış görüntünün doğruluk analizi için, öncelikle PCI Geomatica görüntü işleme yazılımı kullanılarak ilgili sınıflara ait parseller seçilmiştir (Şekil 6.28). Yapılan seçim sonucunda elde edilen referans parsel sayıları Çizelge 6.6’da gösterilmiştir.

Çizelge 6.6: Referans parsel sayıları.

Sınıflar	Referans Parsel Sayıları
Mısır	603
Domates-Biber	748
Mera	43
Pirinç	71
Şeker Pancarı	85
Anız	662
Toplam: 2212	




Şekil 6.28: Referans parsellerin seçilmesi işlemi.


ArcGIS yazılımı kullanılarak mevcut 2212 adet parselin her birinin içine bir tane olacak şekilde rastgele noktalar atılmıştır. Daha sonra, yer gerçeği verisinin sınıf etiketini (Landcover) taşıyan referans nokta katmanı, sınıflandırma sonucu üretilen ve sınıf etiketi (Class_name) olan raster veri ile ilişkilendirilerek, bu iki veri arasında karşılaştırma yapılmıştır.

Ancak, bu yolla yapılan sınıflandırma sonucu değerlendirmesi işleminde; referans noktaların rastgele belirlenmesinden dolayı bazı noktaların parsel sınır ve köşelerine çok yakın bir konumda olduğu görülmüştür. Bu durumun yanında, segmentasyon sonucunda oluşan segment sınırlarının düz olmaması nedeniyle söz konusu referans noktaların olması gerekenden farklı veya komşu parselin sınıf etiketini aldığı gözlemlenmiştir. Dolayısıyla, sınıflandırma sonucunu daha güvenilir bir şekilde değerlendirebilmek için referans noktaları mevcut parsellerin ağırlık merkezlerine ötelenmiştir (Şekil 6.29).

Böylece, doğruluk analizi işleminde kullanılmak üzere 2212 adet referans noktası parsellerin ağırlık merkezlerinde olacak şekilde elde edilmiştir. Şekil 6.30'de referans nokta katmanı ve ilişkilendirilen öznelilik tablosu görülmektedir.



Şekil 6.29: Referans noktalarının parsellerin ağırlık merkezine ötelenmesi.



Şekil 6.30: Referans verilerinin dağılımı.

Belirlenen referans noktaları ile yapılan doğruluk analizinde elde edilen sonuçlar bir hata matrisi üzerinde gösterilmiş ve genel doğruluk ile üretici ve kullanıcı doğrulukları hesaplanmıştır (Çizelge 6.7, Çizelge 6.8). Ayrıca, hata matrisini istatistiksel olarak analiz etmek için K (kappa katsayısı) değeri hesaplanmış ve referans veri ile sınıflandırma sonuçları arasında neredeyse tam uyumu temsil eden aralıkta (0.81-0.99) yer alan 0.83 değeri bulunmuştur.

Çizelge 6.7: Hata matrisi.

Sınıflandıma	Referans Veri						Satır Toplamı
	Mısır	Dom/Biber	Mera	Pirinç	Ş.Pancarı	Anız	
Mısır	509	56	5	7	0	26	603
Domates-Biber	60	629	18	0	5	36	748
Mera	0	2	41	0	0	0	43
Pirinç	1	1	0	68	1	0	71
Şeker Pancarı	5	7	0	0	73	0	85
Anız	11	19	12	5	0	615	662
Sütun Toplamı	586	714	76	80	79	677	2212

Çizelge 6.8: Üretici ve kullanıcı doğrulukları.

Sınıflar	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Mısır	86.86 (509/586)	84.41 (509/603)
Domates-Biber	88.10 (629/714)	84.09 (629/748)
Mera	53.95 (41/76)	95.35 (41/43)
Pirinç	85.00 (68/80)	95.77 (68/71)
Şeker Pancarı	92.41 (73/79)	85.88 (73/85)
Anız	90.84 (615/677)	92.90 (615/662)
Toplam Doğruluk: 87.48		

$$Kappa (\kappa) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (6.4)$$
$$= \frac{2212 * (1935) - 135167}{2212^2 - 135167} = 0.83 = 83\%$$

N = 2212 (toplam örnek sayısı)

$$\sum_{i=1}^r x_{ii} = 1935$$

$$\sum_{i=1}^r (x_{i+} * x_{+i}) = 1351267$$

r = 6 (sınıf sayısı)

7. SONUÇLAR VE ÖNERİLER

Son yıllarda uydu teknolojilerinde yaşanan gelişmeler, hem yeni nesil uydu görüntülerinin hem de yeni sınıflandırma yöntemlerinin geliştirilmesine yol açmıştır. Yeni nesil uydu görüntülerinin zengin içeriğinden en iyi şekilde yararlanmak için, daha gelişmiş sınıflandırma yöntemleri ile değerlendirilerek hızlı ve güvenilir sonuçlar üretilmesi ve üretilen bu verilerin büyük ölçekli uygulamalarda kullanılabilirliğinin incelenmesi ön plana çıkan başlıca araştırma konularındandır.

Bu tez çalışmasında, tarımsal alanlarda ürün deseni tespiti, son yıllarda etkin olarak kullanılan ve gün geçtikçe gelişmeye devam eden, nesne tabanlı sınıflandırma yöntemi ile yapılmıştır. Çalışma alanı olarak Bursa ili, Karacabey ilçesinin güneybatısında, yaklaşık 18 km × 13.5 km büyüklüğünde bir alan ve uydu görüntüsü olarak da 1m konumsal çözünürlüklü keskinleştirilmiş IKONOS uydu görüntüsü seçilmiştir. Nesne tabanlı sınıflandırma işlemi, günümüzde en yaygın kullanılan nesne tabanlı görüntü işleme yazılımlarından olan eCognition Developer yazılımı ile yapılmıştır. Sınıflandırmada, uydu görüntüsü orijinal bantlarına ek olarak NDVI bantı ile GLCM'den hesaplanan homojenlik, zıtlık, farklılık, entropi, ortalama ve varyans doku bantları da kullanılmıştır.

IKONOS uydu görüntüsü, mevcut yer gerçekleri verisinden de yararlanılarak, anız, domates/biber, mera, mısır, pirinç ve şeker pancarı olmak üzere 6 sınıfa ayrılmıştır. Sınıflandırma ve doğruluk analizi işlemleri de mevcut yer gerçekleri verisinden elde edilen eğitim ve test verileri kullanılarak yapılmıştır.

Nesne tabanlı sınıflandırma işleminde, öncelikle en önemli işlem adımlarından biri olan segmentasyon işlemi gerçekleştirilmiştir.

Bu tez çalışmasının amacı doğrultusunda seçilen tarımsal çalışma alanı ve kullanılan 1 m konumsal çözünürlüklü çok bantlı IKONOS uydu görüntüsünün nesne-tabanlı otomatik sınıflandırması için gerekli en uygun segmentasyon parametre değerleri belirlenmiştir.

Nesnelerin belirlenmesinde önemli etkiye sahip olan en uygun ölçek parametresinin belirlenmesinde, otomasyon sağlanması ve işlem süresini kısaltma açısından avantaj sağlayacağı düşünülen ESP-2 yazılımı, deneme yanılma yöntemi ile beraber kullanılmıştır. Bunun için, önce ESP-2 yazılımı kullanılarak elde edilen grafik üzerinden görüntüde belirli özellikleri ifade edebilecek ölçek parametreleri yorumlanmıştır. ESP-2 yazılımı kullanılarak elde edilen Lokal varyans-Değişim oranı grafiğinden en uygun ölçek parametresi için 40 değeri belirlenmiştir. Fakat, bu grafiği elde etmek için yazılım arayüzü üzerinden girilen şekil ve bütünlük parametrelerinin segmentasyon sonuçları üzerinde etkisi olacağından ESP-2 sonucuna bağlı olarak farklı segmentasyon parametreleri kullanılarak çeşitli kombinasyonlar denenmiştir.

ESP-2 yazılımından elde edilen grafik üzerinden yorumlanan ölçek parametresine yakın olacak şekilde belirlenen dört adet parametre değeri (35- 40- 45- 50) ile farklı şekil (0.5- 0.6- 0.7) ve bütünlük parametre değerleri (0.3- 0.4- 0.5) denenerek bu çalışma için en uygun segmentasyon parametre değerleri analiz edilmiştir. Gerçekleştirilen 36 adet kombinasyon sonuçlarının görsel olarak değerlendirilmesi ile çalışma alanında bulunan parsel sınırlarını en iyi tanımlayan ölçek, şekil ve bütünlük parametreleri sırasıyla 40, 0.5 ve 0.3 olarak belirlenmiştir.

IKONOS uydu görüntüsünün segmentasyonu işlemi, belirlenen segmentasyon parametreleri ile görüntünün orijinal bantlarına NDVI bantı da eklenerek, eCognition yazılımında çok çözünürlüklü segmentasyon yöntemi ile yapılmıştır. Görüntü segmentasyonu işleminde, bitki örtüsü karakteristiklerini belirlemede sıklıkla kullanılan YKÖ ve NDVI bantlarının segmentasyon sonucuna olan etkilerinin arttırılması amacıyla bu bantların ağırlıkları 3 olarak alınmıştır.

Nesne tabanlı sınıflandırma işleminin ikinci aşaması olan sınıflandırma işlemine geçilmeden önce, sınıflandırma doğruluğunu artırmak amacıyla tarımsal alanlarda literatürde de sıklıkla kullanılmış olan homojenlik, zıtlık, farklılık, ortalama, varyans ve entropi olmak üzere 6 adet GLCM doku ölçüm yöntemi belirlenmiş ve bu yöntemler IKONOS uydu görüntüsünün orijinal bantlarına PCI Geomatica yazılımı kullanılarak uygulanmış ve 24 bantlık ek veri seti elde edilmiştir.

Orijinal bantlar ve elde edilen 24 bantlık ek veri seti ile birlikte toplam 29 bant kullanılarak, görüntü sınıflandırması işlemi eCognition yazılımında nesne tabanlı en

yakın komşuluk sınıflandırması tekniği ile yapılmıştır. Elde edilen sınıflandırma çıktısı, çalışma alanına homojen bir şekilde dağılmış 2212 adet tarım parseli referans alınarak, ArcGIS yazılımında değerlendirilmiş ve doğruluk analizleri yapılmıştır.

Doğruluk analizleri sonucunda, toplam doğruluk %87.48 ve kappa ise ise %83.70 doğruluk değerleri elde edilmiştir. Hesaplanan sınıflara ait doğruluk değerleri incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- Özellikle Domates/Biber ve Anız sınıflarına ait görüntü segmentlerinin Mera olarak sınıflandırılması ve parsel içi varyasyonlarının fazla olmasından dolayı, en düşük üretici doğruluğu %53.95 ve kullanıcı doğruluğu %95.35 oranıyla mera sınıfı olduğu tespit edilmiştir.
- Üretici doğruluğu %86.86 ve kullanıcı doğruluğu %84.41 olarak belirlenen Mısır sınıfı ağırlıklı olarak Domates/Biber sınıfı ile karışmıştır. Bunun temel nedeni, çalışmada kullanılan IKONOS uydu görüntüsünün çekim tarihi olan Temmuz ayının ortalarında yeni olgunlaşan mısır bitkilerinin domates ve biber bitkileri ile benzer olan spektral özelliğe sahip olmasıdır.
- Domates/Biber sınıfının ise, özellikle Mısır ve Anız sınıfı ile karışması sonucunda üretici doğruluğu %88.10, kullanıcı doğruluğu %84.09 olarak belirlenmiştir. Ayrıca, Domates ve Biber sınıfları arasındaki yüksek oranda spektral örtüşmeden dolayı tanımlanan tüm bantlarda bu iki sınıfın birbiriyle karıştığı gözlemlenmiştir. Yukarıda da belirtildiği gibi bunun temel sebebi, her iki ürünün de yansıma karakteristiklerinin benzer olması ve görüntü çekim tarihinin ürünlerin aynı olan olgunluk dönemlerine denk gelmesidir. Bu spektral karışıklık doğruluk oranını önemli derecede azalttığı için söz konusu iki ürün sınıfı birleştirilerek değerlendirilmiştir.
- Çalışma alanında yer alan Anız parselleri, seyrek ve çoğunlukla ekili olmadığından diğer sınıflardan spektral olarak farklı ve parsel içi varyasyonları azdır. Bu nedenlerle Anız sınıfı, üretici doğruluğu %90.84 ve kullanıcı doğruluğu %92.90 oranıyla en iyi belirlenen sınıf olmuştur.
- Diğer sınıflarla spektral örtüşmenin düşük olmasına rağmen, az miktarda Mısır ve Anız sınıfına ait görüntü segmentlerinin Pirinç olarak sınıflandırılmasından dolayı Pirinç sınıfının üretici doğruluğu %85.00 oranında ve yaklaşık olarak tüm

Pirinç alanlarının belirlendiğini gösteren kullanıcı doğruluğu ise %97.55 oranında belirlenmiştir.

- Şeker Pancarı sınıfı, Mısır ve Domates/Biber sınıflarıyla az miktarda karıştığı için kullanıcı doğruluğu %85.88 ve üretici doğruluğu %92.41 oranıyla yüksek doğrulukla belirlenmiştir.

Bu tez çalışması neticesinde varılan diğer sonuçlar şu şekildedir:

- Tarımsal alanlarda, en azından bu tez çalışmasında kullanılan tarımsal çalışma alanı için, nesne tabanlı sınıflandırmanın başarısını etkileyen en önemli etkenlerden birisinin, sınıflandırma öncesinde gerçekleştirilen segmentasyonun başarısının olduğu tespit edilmiştir. Bilindiği üzere, segmentasyonun kalitesi, çalışmanın amacına uygun olarak seçilen en uygun segmentasyon parametre değerlerinin kullanılmasına dayanmaktadır. Bu çalışmada, en önemli segmentasyon parametresinin, nesnelerin heterojenlik ölçütü olarak bilinen ve nesne boyutu üzerinde doğrudan etkili olan ölçek parametresi olduğu görülmüştür. Dolayısıyla, nesne tabanlı sınıflandırma sonucunun yüksek doğrulukta elde edilebilmesi için, en uygun segmentasyon parametre değerlerinin belirlenmesi oldukça önem arz etmektedir.
- Segmentasyon parametrelerinin belirlenmesi için yapılan denemeler sonucunda, ölçek parametresinin artması ile segment sayısının azaldığı ve bu azalma sayısında seçilen şekil ve bütünlük parametrelerinin benzer etkiye sahip olduğu belirlenmiştir. Aynı şekil ve bütünlük parametreleri farklı ölçek parametreleri ile değerlendirildiğinde, özellikle ölçek parametresinin segment sayısı ve büyüklüğü üzerinde etkisinin büyük olduğu görülmüştür.
- Her ne kadar ESP-2 yazılımı ile en uygun ölçek parametresi değeri belirlenmiş olsa da farklı görüntüler ve farklı çalışma alanları için tüm segmentasyon parametrelerini tam otomatik olarak belirleyen ve tatmin edici sonuçlar veren bir parametre kestirim yöntemi/programı bulunmamaktadır.
- Bu çalışmada kullanılan IKONOS uydu görüntüsü nesne-tabanlı yöntemle sınıflandırılması ile yüksek oranda doğruluk elde edilmiş ve ülkemiz için oldukça önemli olan ürün deseni tespiti çalışmalarında kullanılabilir olduğu görülmüştür.

Yüksek çözünürlüklü uydu görüntülerinde artan heterojenlik, nesnelerin birbirinden ayırt edilmesinde sorunlara neden olmaktadır. Bu sorunların çözümü için uydu

görüntülerinin yardımcı veriler ile birlikte değerlendirilmesi genellikle tercih edilen bir yaklaşımdır. Özellikle, tarım alanlarında yapılan çalışmalarda bitkilerin ekim zamanı, şekli ve karakteristiğinden dolayı sahip olduğu doku özellikleri sıklıkla kullanılmaktadır.

Doku hesaplamaları karmaşık matematiksel işlemler içermektedir. Özellikle doku özelliği uygulanacak bant sayısının artması işlem süresini oldukça uzatmaktadır. Bu nedenle, kullanılacak doku özellikleri ve uygulanacak bantlar, çalışma amacı ve zaman açısından değerlendirilerek belirlenmelidir. Ayrıca, daha yüksek çözünürlüklü uydu görüntülerinin kullanılması, doku özelliklerinden daha iyi bir şekilde yararlanılabileceği için doğruluğu arttırılabileceği düşünülmektedir.

Çalışma alanında bulunan tarım ürünlerinin fenolojik ve karakteristik özelliklerinden dolayı meydana gelen spektral örtüşmeler kaçınılmazdır. Çalışmada, 29 adet banttan oluşan veri seti sınıflandırılarak, sınıflandırma sürecinde dahil edilecek yardımcı verilerin ve dolayısıyla bant sayısının artmasının sınıflandırma sonucuna olumlu yönde katkısı olduğu görülmüştür. Bu nedenle, çalışma amacına yönelik olacak şekilde bant sayısının arttırılması ve çok-zamanlı uydu görüntülerinin kullanılması ile bu durumun etkisi azaltılabilir.

Nesne tabanlı görüntü analizinde, farklı sınıflandırma algoritmalarının veya kural tabanlı sınıflandırma yaklaşımının kullanımı ile sınıflandırma sonuçların iyileştirilmesine katkıda bulunacağı düşünülmektedir.

Bu yöntemle elde edilen veriler ülkemiz için oldukça önemli olan birçok alanda kullanılabilmektedir. Bu alanların başında tarım ve pazarlama politikalarının belirlenmesi gelmektedir. Ayrıca, tarım ürünlerinin gelişimlerinin izlenmesi, çiftçiye yapılacak teşviklerin belirlenmesi ve bununla ilgili olarak Çiftçi Kayıt Sistemi'ne (ÇKS) kaynak sağlaması, gıda güvenliği ve rekolte tahmini gibi güvenilir veriler gerektiren çalışmalarda da kullanılması konusunda avantajlar sağlayabileceklerdir.

KAYNAKLAR

- Addink, E., Jong, S. ve Pebesma, E., 2007. The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery, *Photogrammetric Engineering and Remote Sensing*, 73, 8, 905-912.
- Algancı, U., Sertel, E., Özdoğan, M. ve Örmeci, C., 2013. Parcel-level identification of crop types using different classification algorithms and multi-resolution imagery in southeastern Turkey, *Photogrammetric Engineering and Remote Sensing*, 79,11, 1053-1065.
- Antunes, A., Lingnau, C. ve Centeno, J., 2003. Object oriented analysis and semantic network for high resolution image classification, *Anais XI SBSR, Belo Horizonte, Brezilya*, 273-279.
- Baatz, M. ve Schape, A., 2000. Multiresolution segmentation-an optimization approach for high quality multi-scale image, pp.12-23, in: Strobl, J., Blaschke, T., Griesebner, G. (Editör), *Angewandte Geographische Informations-Verarbeitung XII*, Wichmann Verlag, Karlsruhe, Almanya.
- Baatz, M., Hoffmann, C. ve Willhauck, G., 2008. Progressing From Object-Based To Object-Oriented Image Analysis, pp.29-42, in: Blaschke, T., Lang, S., Hay, G. (Editör), *Object-Based Image Analysis*, Springer, Berlin, Almanya.
- Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I. ve Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry and Remote Sensing*, 3, 4, 239-258
- Blaschke, T., 2010. Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 1, 2-16.
- Bock, M., Xofis, P., Mitchley, J., Rossner, G. ve Wissen, M. 2005. Object-oriented methods for habitat mapping at multiple scales– Case studies from Northern Germany and Wye Downs, UK. *Journal for Nature Conservation*,13,2, 75-89.
- Boyacı, D., 2012. Cbs-uzaktan algılama entegrasyonu ve örnek uygulama: uydu görüntülerinden detay ve otomatik öznitelik tespiti, *Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya*.
- Brodsky, L. ve Boravka, L., 2006. Object-oriented fuzzy analysis of remote sensing data for bare soil brightness mapping, *Soil & Water Resources*,1, 79-84.
- Campbell, J. ve Wynne, R., 1996. *Introduction to remote sensing*, Five Edition, New York, USA.
- Conrad, C., Fritsch, S., Zeidler, J., Rücker, G. ve Dech, S., 2010. Per-Field irrigated crop classification in arid central Asia, *Remote Sensing*, 2, 4, 1035-1056.

- Carleer, E. ve Wolff, E., 2006. Region-Based classification potential for land-cover classification with very high spatial resolution satellite data, Proceedings of 1st International Conference on Object-based Image Analysis, Salzburg Üniversitesi, Avusturya.
- Castillejo-Gonzalez, I., Lopez-Granados, F., Garcia-Ferrer, A., Peña-Barragán, J. ve Jurado-Expósito, M., 2009. Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using quickbird imagery, *Computers Electronics Agriculture*, 68, 2, 207-215.
- D'Oleire-Oltmanns, S. ve Tiede, D., 2014. Application of the Estimation of Scale Parameter-2 (ESP-2) tool for the identification of scale levels for distinct target objects, *South- Eastern European Journal of Earth Observation and Geomatics*, 3, 2, 597-584.
- Definiens Developer User Guide, 2014. Definiens eCognition developer 9.1 user guide.
- Drăgut, L., Tiede, D., Levick, S., 2010. ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data, *International Journal of Geographical Information Science*, 24, 859-871.
- Drăgut, L., Csillik, O., Eisank, C. ve Tiede, D., 2014. Automated parameterisation for multi-scale image segmentation on multiple layers, *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 119-127.
- Dymond, C. ve Johnson, E., 2002. Mapping vegetation spatial patterns from modeled water, temperature and solar radiation gradients, *ISPRS Journal of Photogrammetry and Remote Sensing*, 57, 2, 69-85.
- Förster, M., Kleinschmit, B. ve Walentowski., 2005. Comparison of three modelling approaches of potential natural habitats in Bavaria, *Waldökologie Online*, 2, 126-135.
- Gonzalez, R. ve Rafael, C., 2008. Digital image processing, Third Edition, Prentice Hall, New Jersey, USA.
- Goodin, D., Anibas, K. ve Bezymenniy, M., 2015. Mapping land cover and land use from objectbased, *International Journal of Remote Sensing*, 36, 18, 4702-4723.
- Griffith, J., 2006. Object-Oriented method to classify the land use and land cover in San Antonio using ecognition object-oriented image analysis, *Remote Sensing Image Process And Analysis*, 1-10.
- Haralick, R., Shanmugam, K. ve Dinstein, I., 1973. Textural features for image classification, *IEEE Transactions on Systems*, 3, 610-621.
- Jensen, J., 2005. Introductory digital image processing a remote sensing perspective, Prentice Hall, New Jersey, USA.
- Johnson, B., 2013. High-Resolution urban land-cover classification using a competitive multi-scale object-based approach, *Remote Sensing Letters*, 4, 2, 131-140.

- Karakış, S., 2005. Quickbird örneğinde yüksek çözünürlüklü uydu görüntüsü üzerinden kentsel ayrıntıların otomatik ve manuel çıkarımı üzerine bir uygulama, Yüksek Lisans Tezi, Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Zonguldak.
- Karakuş, P. ve Karabörk, H., 2016. ESP ile nesne tabanlı sınıflandırma kullanılarak arazi örtüsünün çıkarılması, 6.Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016).
- Kavzoğlu, T. ve İsmail, Ç., 2011. Uzaktan algılama teknolojileri ve uygulama alanları. Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Bölümü, 41400, Gebze, Kocaeli.
- Kim, M., Madden, M. ve Warner, T., 2008. Estimation of optimal image object size for the segmentation of forest stands with multispectral IKONOS imagery, pp.291-307, in: Blaschke, T., Lang, S., Hay, G. (Editör), Object-Based Image Analysis, Springer, Berlin, Almanya.
- Koutsias, N., Mallinis, G., Pleniou, M., Voukelatou, I., Paschali, T. ve Dimopoulos, P., 2011. Object-Based classification using a synergy of high spatial (IKONOS) and high spectral (ASTER) satellite data in a rural NATURA 2000 deltaic area, Proceedings of the 2nd International Conference on Space Technology, Atina, Yunanistan.
- Landis, J. ve Koch, G., 1977. The Measurement of Observer Agreement for Categorical Data, Biometrics, 33, 1, 159-174.
- Li, M., Ma, L., Blaschke, T., Cheng, L. ve Tiede, D., 2016. A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments, International Journal of Applied Earth Observation and Geoinformation, 49, 87-98.
- Lillesand, T., Kiefer, R. ve Chipman, J., 2007. Remote sensing and image interpretation, Sixth Edition, John Wiley Sons, New York, USA.
- Liu, J. ve Mason, P., 2009. Essential image processing and gis for remote sensing, John Wiley ve Sons, New York, USA.
- Löw, F., Michel, U., Dech, S. ve Conrad, C., 2013. Impact of feature selection on the accuracy and spatial uncertainty of perfield crop classification using support vector machines, ISPRS Journal of Photogrammetry and Remote Sensing, 85, 102-109.
- Lu, D., Hetrick, S. ve Moran, E., 2011. Impervious surface mapping with Quickbird imagery, International Journal of Remote Sensing, 39, 9, 2519-2533.
- Marangoz, A., 2009. Uydu görüntülerinden kentsel ayrıntıların nesne-tabanlı sınıflandırma yöntemiyle belirlenmesi ve CBS ortamında bütünleştirilmesi. Doktora tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Mather, P., 2004. Computer processing of remotely-sensed images: an introduction, Third Edition, John Wiley ve Sons.
- Mathieu, R., Aryal, J. ve Chong, A., 2007. Object-based classification of IKONOS imagery for mapping large-scale vegetation communities in urban areas, Sensors, 7, 11, 2860-2880.

- Mialhea, F., Gunnell, Y., Ignacio, J., Delbart, N., Oganian, J. ve Henry, S., 2015. Monitoring land-use change by combining participatory land-use maps with standard remote sensing techniques: showcase from a remote forest catchment on Mindanao, *International Journal of Applied Earth Observation and Geoinformation*, 36, 69-82.
- Musaoğlu, N., 1999. Elektro-Optik ve aktif mikrodalga algılayıcılarından elde edilen uydu verilerinden orman alanlarına ait meşcere tiplerinin ve yetişme ortamı birimlerinin belirlenme olanakları, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Myint, S., Gower, P., Brazel, A., Grossman-Clar, S. ve Weng, Q., 2011. Per-Pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery, *Remote Sensing of Environment*, 115, 1145-1161.
- O'Connell, J., Bradter, U. ve Benton, T., 2015. Wide-area mapping of small-scale features in agricultural landscapes, *ISPRS Journal of Photogrammetry and Remote Sensing*, 109, 165-177.
- Pena-Barragan, J., Ngugi, M., Plant, K. ve Six, J., 2011. Object-Based crop identification using multiple vegetation indices, Textural Features and Crop Phenology, *Remote Sensing of Environment*, 115, 1301-1306.
- Radoux, J. ve Defourny, P., 2008. Quality assessment of segmentation results devoted to object-based classification, *Department of Environmental Sciences and Land Use Planning*, 257-271.
- Robertson, L. ve King, D., 2011. Comparison of pixel and object based classification in land cover change mapping, *International Journal of Remote Sensing*, 32, 6, 1505-1529.
- Shackelford, A. ve Davis, C., 2003. A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas, *Ieee Transactions On Geoscience And Remote Sensing*, 41, 2354-2363.
- Shanahan, J., Schepers, J., Francis, D., Varvel, G., Wilhelm, W., Tringe, J. ve Major, D., 2011. Use of remote-sensing imagery to estimate corn grain yield, *Agronomy Journal*, 93, 3, 583-589.
- Singha, M., Wu, B. ve Zhang, M., 2016. An object-based paddy rice classification using multi-spectral data and crop phenology in Assam Northeast India. *Remote Sensing*, 8, 6, 479.
- Tso, B. ve Mather, P., 2009. Classification methods for remotely sensed data, Second Edition, CRC Press, Londra, İngiltere.
- Türker, M., 1999. Uzaktan algılama görüntülerinin sınıflandırılması işleminde yardımcı verilerin kullanılması teknikleri, *Harita Dergisi*, 122, 1 - 10.
- Türker, M. ve Özdarıcı, A., 2011. Field-Based crop classification using SPOT4, SPOT5, IKONOS And Quickbird Imagery for agricultural areas: a comparison study, *International Journal of Remote Sensing*, 32, 24, 9735-9768.
- Yomralıoğlu, T. ve Çölkesen, İ., 2014. Arazi örtüsü ve kullanımının haritalanmasında Worldview-2 uydu görüntüsü ve yardımcı verilerin kullanımı, *Harita Dergisi*, 152.

- Yu, Q., Gong, P., Clinton, N., Biging, G. ve Kelly, M., 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery, *Photogrammetric Engineering and Remote Sensing*, 72, 7, 799-811.
- Zhang, H., Li, Q., Liu, J., Du, X., Dong, T., McNairn, H. ve Shang, J., 2017. Object-based crop classification using multitemporal SPOT-5 imagery and textural features with a Random Forest classifier, *Geocarto International*, 1-19.
- Zhao, M., Li, F. ve Tang, G., 2012. Optimal scale selection for DEM based slope segmentation in the Loess Plateau, *International Journal of Geosciences*, 3, 37-43.
- Watmough, G., Palm, C. ve Sullivan, C., 2017. An operational framework for object-based land use classification of heterogeneous rural landscape, *International Journal of Applied Earth Observation and Geoinformation*, 54, 134-144.
- Xu, W., Wu, B., Huang, J., Zhang, Y. ve Tian, Y., 2004. A segmentation and classification approach of land cover mapping using QuickBird image, *Geoscience and Remote Sensing Symposium*, 7, 3368-3370.
- URL-1<<http://www.kozmikanafor.com/yildizlari-anlamak-2-tayf>>, alındığı tarih: 10.10.2017.
- URL-2< <http://www.nrcan.gc.ca/node/9291>>, alındığı tarih: 10.10.2017.
- URL-3 <<http://www.yildiz.edu.tr/~bayram/sgi/saygi.htm>>, alındığı tarih: 10.10.2017.
- URL-4<http://www.crisp.nus.sg/~research/tutorial/ppt_int.htm>, alındığı tarih: 10.10.2017.
- URL-5<http://www.nik.com.tr/content_sistem_uydu.asp?id=13>, alındığı tarih: 11.10.2017.
- URL-6<[http://pro.arcgis.com/en/pro-app/tool-reference/spatial-analyst/smoothing zone-edges-with-boundary-clean-and-majority-filter.htm](http://pro.arcgis.com/en/pro-app/tool-reference/spatial-analyst/smoothing_zone-edges-with-boundary-clean-and-majority-filter.htm)>, alındığı tarih: 25.11.2017.

ÖZGEÇMİŞ

Adı ve Soyadı : Beste TAVUS

Doğum Tarihi ve Yeri: 19.07.1992/ANKARA

E-posta adresi : bestetavus@gmail.com

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Aksaray Üniversitesi - Harita Mühendisliği (2010-2014).

Yüksek Lisans : Aksaray Üniversitesi – Fen Bilimleri Enstitüsü - Jeodezi ve Coğrafi Bilgi Sistemleri A.B.D. (2014-2017).

MESLEKİ DENEYİM VE ÖDÜLLERİ

Hacettepe Üniversitesi, Araştırma Görevlisi (2017-halen).