

**QUICKBIRD ÖRNEĞİNDE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜSÜ
ÜZERİNDEN KENTSEL AYRINTILARIN OTOMATİK VE MANUEL ÇIKARIMI
ÜZERİNE BİR UYGULAMA**

Serkan KARAKIŞ

**Zonguldak Karaelmas Üniversitesi
Fen Bilimleri Enstitüsü
Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalında
Yüksek Mühendislik Tezi
Olarak Hazırlanmıştır**

**ZONGULDAK
Temmuz 2005**

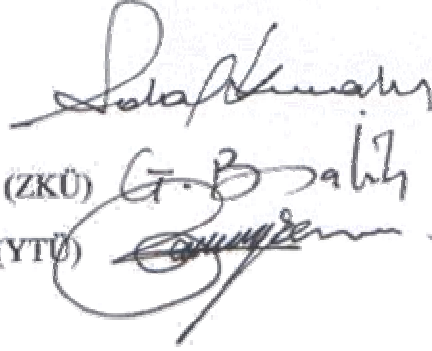
KABUL:

Serkan KARAKIŞ tarafından hazırlanan "QUICKBIRD ÖRNEĞİNDE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜSÜ ÜZERİNDEN KENTSEL AYRINTILARIN OTOMATİK VE MANUEL ÇIKARIMI ÜZERİNE BİR UYGULAMA" başlıklı bu çalışma jürimiz tarafından değerlendirilerek, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalında Yüksek Mühendislik Tezi olarak oybirliğiyle kabul edilmiştir.
01/07/2005

Başkan: Prof. Dr. Erdal KOÇAK (ZKÜ)

Üye : Doç. Dr. Gürcan BÜYÜKSALİH (ZKÜ)

Üye : Yrd. Doç. Dr. Bülent BAYRAM (YTÜ)



ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım 27/7/2005



Prof. Dr. İhsan TOROĞLU

Fen Bilimleri Enstitüsü Müdürü V.

ÖZET

Yüksek Mühendislik Tezi

QUICKBIRD ÖRNEĞİNDE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜSÜ ÜZERİNDEN KENTSEL AYRINTILARIN OTOMATİK VE MANUEL ÇIKARIMI ÜZERİNE BİR UYGULAMA

Serkan KARAKIŞ

Zonguldak Karaelmas Üniversitesi

Fen Bilimleri Enstitüsü

Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Erdal KOÇAK

Temmuz 2005, 84 sayfa

Bu tez, QuickBird Standart Orthoready görüntüsü üzerinden detay çıkarımı örneğiyle, kentsel ayrıntıların yüksek çözünürlüklü uydu görüntüleri üzerinden otomatik ve manuel çıkarımlarının analizini amaçlamaktadır.

Bu çalışmanın yürütülmesinde gerekli olan kuramsal bilgiler, Bölüm 2’de Geometrik Düzeltme ve Radyometrik Geliştirme, Bölüm 3’de Nesne Tabanlı Görüntü Analizi ve eCognition Yazılımı, Bölüm 4’te QuickBird Uydusu ve Ürünleri başlıkları altında verilmektedir.

Uygulama kapsamında QuickBird Standart Orthoready görüntüsünden detay çıkarımı için öncelikle görüntü geometrik olarak, SYM ve YKN noktaları yardımıyla düzeltilmiştir. Bunun için PCI Geomatica OrthoEngine V9.1.4 yazılımı altında Satellite Orbital Modelling algoritması kullanılmıştır. Görüntüden en iyi sonucu alabilmek için radyometrik

ÖZET (devam ediyor)

geliştirme yine PCI Geomatica yazılımı altında yer alan Pan-sharp modülüyle yapılmıştır. Detay çıkarımına hazır hale gelen görüntü üzerinden öncelikle vektörel bilgi CAD yazılımları yardımıyla ekran üzerinden sayısallaştırma tekniğiyle çıkarılmış ardından eCognition V4.0.6 yazılımı altında nesne tabanlı görüntü analizi tekniğiyle irdelenmiştir. Sonuç ürünlerin üst üste karşılaştırılması yapılmış ve analiz teknikleriyle birbirine olan üstünlükleri ve eksiklikleri ortaya konmaya çalışılmıştır.

Anahtar Sözcükler: QuickBird, Standart Orthoready görüntü ürünü, Pan-sharp, eCognition, Nesne Tabanlı Görüntü Analizi

Bilim Kodu: 616.02.04

ABSTRACT

M.Sc.Thesis

AUTOMATIC AND MANUAL EXTRACTION OF URBAN FEATURES FROM QUICKBIRD HIGH RESOLUTION SPACE IMAGERY

Serkan KARAKIŞ

**Zonguldak Karaelmas University
Graduate School of Natural and Applied Sciences
Department of Geodesy and Photogrammetry Engineering**

Thesis Advisor: Prof. Erdal KOÇAK

July 2005, 84 pages

The aim of this thesis is to analyse the automatic and manual extraction of urban features from high resolution QuickBird Standard Orthorectified image.

Theoretical background needed to apply this study is given in Chapter 2, Geometric Correction and Radiometric Improvement; Chapter 3, Object Oriented Image Analyse and eCognition Software; Chapter 4, QuickBird Satellite and Products.

The image has been geometrically corrected by using DEM and GCPs measured using GPS static surveying. PCI Geomatica OrthoEngine V9.1.4 software and its sub-module Satellite Orbital Modelling have been used to make this correction. To reach the best result, image has been radiometrically improved by using Pan-sharp module of the same software. After applying the above steps, the image has been ready for the feature extraction and first handled on a CAD software. The details are manually digitized and resulting vector layer has been compared to the object oriented image analysis on the

ABSTRACT (continued)

eCognition V4.0.6 software. The products of the two methods have been superimposed, and the advantages and disadvantages are discussed by some analysis techniques.

Keywords: QuickBird, Standart Orthoready Image, Pan-sharp, eCognition, Object-Oriented Image Analysis

Science Code: 616.02.04

TEŐEKKÜR

Bu alıőma konusunun seilmesinde; gerekli yazılım, donanım, veri ve belgenin saėlanmasında ve ayrıca engin bilgi birikiminden yararlanmamda gösterdiėi ilgiden dolayı deėerli danıőman hocam Prof.Dr. Erdal KOAK (ZKÜ) ve Do.Dr. Gürcan BÜYÜKSALİH'e (ZKÜ); her zaman engin bilgi ve deneyimleriyle bana yardımcı olan tüm ZKÜ Jeodezi ve Fotogrametri Mühendisliėi Bölümü öğretim elemanlarına teşekkürü bir bor bilirim.

alıőmalarım sırasında benden desteklerini esirgemeyen sevgili aileme őükranlarımı sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	viii
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ.....	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiv
BÖLÜM 1 GİRİŞ VE AMAÇ	1
BÖLÜM 2 GEOMETRİK DÜZELTME VE RADYOMETRİK GELİŞTİRME.....	5
2.2 UYDU GÖRÜNTÜLERİNİN GEOMETRİK DÜZELTİLMESİ.....	5
2.3 PARAMETRİK OLMAYAN MATEMATİKSEL MODELLER	6
2.3.1 Çeşitli Polinom Derecelerini Kullanan İki Boyutlu Yaklaşım	7
2.3.2 Yükseklik Değerini Kullanan Afin Dönüşüm	11
2.3.3 Direct Linear Transformation.....	12
2.3.4 Rational Functions Modeli	13
2.4 PARAMETRİK MATEMATİKSEL MODELLER.....	14
2.4.1 SOM	15
2.5 PAN-SHARP VE KULLANILAN ALGORİTMALAR.....	15
2.5.1 HIS Sharpening	18
2.5.2 PCA Sharpening	21
2.5.3 Gramm Schmidt Sharpening	22
2.5.4 Wavelet Sharpening.....	23
2.5.5 UNB Sharpening	24
BÖLÜM 3 NESNE TABANLI GÖRÜNTÜ ANALİZİ VE ECOGNITION YAZILIMI	25

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.1 NESNE TABANLI GÖRÜNTÜ ANALİZİ YAKLAŞIMI	25
3.2 GÖRÜNTÜ YORUMLAMADA TEMEL BİLEŞENLER.....	27
3.2.1 Görüntü İşlemede Yaklaşık Ölçek.....	27
3.2.2 Görüntü Semantikleri – Görüntü Nesneleri Arasındaki Karşılıklı İlişkiler.....	29
3.3 SEGMENTASYON	31
3.4 SINIFLANDIRMA - SINIFLANDIRICILAR VE METOTLAR.....	34
3.4.1 Bulanık Sınıflandırma Sistemleri	36
3.4.1.1 Bulanıklaştırma.....	37
3.4.1.2 Bulanıklık Kural Tablosu	38
3.4.1.3 Durulama	40
3.5 ECOGNITION ALTINDA NESNE TABANLI GÖRÜNTÜ ANALİZİ.....	40
3.5.1 Görüntü Nesnelерinin Çoklu Segmentasyonu	42
3.5.2 Segmentasyonun Uygulanması	45
3.5.2.1 Heterojenlik Kriterinin Belirlenmesi.....	46
3.5.3 Alt Nesnelерin Çizgi Analizi Amaçlı Segmentasyonu	49
3.5.4 Görüntü Nesnelерinin Hiyerarşik Ağ Yapısı	50
3.5.5 Ecognitionda Vektör Bilgisi	52
3.5.6 Ecognition Altında Bulanık Sınıflandırma	54
BÖLÜM 4 QUICKBIRD UYDUSU VE ÜRÜNLERİ	58
4.1 QUICKBIRD UYDUSU	58
4.2 QUICKBIRD ÜRÜNLERİ.....	59
4.2.1 Temel Görüntü Ürünü	59
4.2.2 Standart Görüntü Ürünü	61
4.2.3 Orto Görüntü Ürünü	63
BÖLÜM 5 UYGULAMA	65
5.1 GENEL.....	65
5.2 TEST ALANI.....	65
5.3 KULLANILAN VERİLER VE YAZILIMLAR.....	66

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
5.3.1 Uydu Görüntüsü	66
5.3.2 Yer Kontrol Noktaları.....	66
5.3.3 Kullanılan Yazılımlar	67
5.3 YAZILIM ORTAMINDA DEĞERLENDİRME.....	68
5.3.1 Geometrik Düzeltme.....	68
5.3.2 Radyometrik Geliştirme	72
BÖLÜM 6 SONUÇ VE ÖNERİLER.....	79
KAYNAKLAR.....	82
ÖZGEÇMİŞ.....	84

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
2.1 Polinom terimlerinin x (sol) ve y (sağ) eksenlerdeki etkisi.....	8
2.2 İki boyutlu afin dönüşümde koordinat eksenleri	9
2.3 Doğrusal dizi sensörlerin şekilsel yapısı.....	16
2.4 Odak düzleminde senörlerin algılama durumu ve yer yüzünden yansıma alım anı .	16
2.5 QuickBird uydusunun 4 bantta ayrı ayrı yapmış olduğu alım	17
2.6 Uydu hareketinden kaynaklanan bantlar arasındaki paralaks.....	18
2.7 HIS algoritmasıyla üretilmiş pan-sharp QuickBird görüntüsü	19
2.8 Yoğunluk bandıyla pankromatik bant arasındaki parlaklık farkı (A: Yoğunluk Bandı, B: Pankromatik Bant).....	19
2.9 Yoğunluk bandıyla birlikte görünür pankromatik bant (A: Yoğunluk Bandı, B: Görünür Pankromatik Bant)	20
2.10 Görünür pan iyileştirmesi uygulanmış HIS algoritması sonucu.....	20
2.11 PCA algoritmasıyla hazırlanmış pan-sharp görüntü	21
2.12 PCA ve UNB algoritmalarının karşılaştırılması (A: PCA algoritması sonucu, B: UNB algoritması sonucu)	22
2.13 Gramm Schmidt ve UNB algoritmalarının karşılaştırılması (A: GS algoritması sonucu, B: UNB algoritması sonucu)	23
2.14 Wavelet ve UNB algoritmalarının karşılaştırılması (A: Wavelet algoritması sonucu, B: UNB algoritması sonucu)	23
3.1 Üyelik fonksiyonlarına örnek	37
3.2 Birbiri içine giren fonksiyonlarla bulanıklığın sağlanması.....	38
3.3 Özelliğin her bir sınıfa karşılık vermesi ancak bir sınıfa baskın çıkması.....	39
3.4 Birbirine yakın değerler nedeniyle sınıf tayininin yapılamaması.....	40
3.5 Heterojen nesnelere örnek çatılar ve yeşil alan	43
3.6 Düşük heterojenlik sonucu geometrik anlamda bozuk şekillerin oluşması.....	46
3.7 Optimize edilmiş heterojenlikle daha düzgün şekilli yapıların oluşması	47
3.8 Alt segmentlere ayrılmış nesne örneği.....	50
3.9 Hiyerarşik ağ yapısı	50
3.10 eCognition altında poligonların oluşturulması	53
3.11 Douglas Peucker algoritmasının poligonlara uygulanması	53

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
3.12 eCognition altında kullanılan fonksiyon çeşitleri	55
5.1 Zonguldak Test Alanı	65
5.2 Test Alanı üzerinde yer kontrol noktalarının dağılımı.....	67
5.3 PCI Geomatica OrthoEngine V 9.1.4 yazılımı altında proje tanımlanması.....	69
5.4 PCI Geomatica OrthoEngine V 9.1.4 yazılımı altında görüntünün okutulması	69
5.5 Yer Kontrol Noktası Toplama Arayüzü ile noktaların girilmesi	70
5.6 Girilen YKN' bağlı olarak elde edilen doğruluk değeri	70
5.7 Yazılım altında orto görüntünün üretim anı	71
5.8 Orto için kullanılan 1927 yılına ait SYM	71
5.9 Yazılım altında pan-sharp algoritmasının çalıştırılması	72
5.10 Çalışmaya esas olan uygulama bölgesi.....	73
5.11 Görüntü üzerinden elle sayısallaştırılmış detaylar	74
5.12 eCognition altında projenin tanımlanması ve görüntünün açılması	74
5.13 Aynı parametrelerle oluşturulmuş vektörlü ve vektörsüz segmentasyon (A=Vektör Yapılı, B=Vektör yapısız)	75
5.14 Sınıf atamaları için kullanılan özellikler ve bunlara ait fonksiyonlar (A=Üçüncü banda ait yansıma değerlerini kullanan dikdörtgensel fonksiyon, B=Dikdörtgensel şekil uyuşumunu kullanan dikdörtgensel fonksiyon).....	76
5.15 Nesne-tabanlı sınıflandırma sonucu.....	77
5.16 Nesne-tabanlı sınıflandırma sonucu ile vektör haritanın çakıştırılmış hali (Sarı çizgiler vektör haritada bulunan binaları,mavi çizgiler de yolları ifade etmektedir)77	
5.17 Elle vektörleştirme ve nesne-tabanlı yaklaşım sonucunun üst üste gösterimi.....	78

ÇİZELGELER DİZİNİ

<u>No</u>		<u>Sayfa</u>
4.1	QuickBird Uydusu Teknik Özellikleri	58
4.2	QuickBird Uydusu Görüntüleri	59
5.1	QuickBird Standart OrthoReady görüntüsü teknik özellikleri	66
5.2	Uygulamada kullanılan segmentasyon parametreleri.....	75

SİMGELER VE KISALTMALAR DİZİNİ

A	:	Düzeltilme denklemlerinin katsayılar matrisi
b	:	Nesnenin sınırlandırılmış uzunluğu
dx	:	Dengeleme bilinmeyenleri vektörü
f	:	Birleştirme değeri
F	:	İşlev
h	:	Heterojenlik
l	:	Nesnenin fiili uzunluğu
\underline{L}	:	Ölçülen görüntü koordinatları vektörü
\overline{L}	:	Dengeli görüntü koordinatları vektörü
m_0	:	Birim ağırlıklı ölçünün soncul karesel ortalama hatası
m_x, m_y	:	x ve y görüntü koordinatlarına ait soncul karesel ortalama hatalar
n	:	Toplam YKN sayısı
n_s	:	Nesneyi oluşturan piksel sayısı
N	:	Polinomun derecesi
u	:	Matematiksel modelin bilinmeyen sayısı
\underline{v}	:	Düzeltilmeler vektörü
w	:	Kullanıcı tanımlı ağırlık
x, y	:	YKN'nın görüntü koordinatı
X, Y, Z	:	YKN'nın yer koordinatı
σ	:	Spektral değerlerin ağırlıklı standart sapması

KISALTMALAR:

ATRC	:	Affine Terrain Relief Corrected
CBS	:	Coğrafi Bilgi Sistemi
CCD	:	Charge-Couple Device
CCRS	:	Canada Center for Remote Sensing

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

DLT	:	Direct Linear Transformation
GPS	:	Global Positioning System
ISPRS	:	International Society for Photogrammetry and Remote Sensing
Pan	:	Pankromatik
RFM	:	Rational Function Model
SDLT	:	Self-Calibrating Direct Linear Transformation
SOM	:	Satellite Orbital Modeling
SYM	:	Sayısal Yükseklik Modeli
UTM	:	Universal Transvers Mercator
WGS	:	World Geodetic System
YKN	:	Yer Kontrol Noktası
ZKÜ	:	Zonguldak Karaelmas Üniversitesi

BÖLÜM 1

GİRİŞ VE AMAÇ

Günümüzde bilgiye ulaşmak ve doğru bilgi edinmek büyük önem taşımaktadır. Yapılacak bir uygulama veya yapılmış bir uygulamayı revize etmek söz konusu olduğunda, gerekli olan bilgiyi edinmek uygulamanın ekonomik ömrünü zorlamamalıdır. Bu açıdan uygulamaya geçmek için gerekli olan bilgi biran önce edinilmeli ve doğruluğu açısından da uygulamanın kötü bir biçimde sonuçlanmasına yol açmamalıdır. Bu, tüm bilim dallarında olduğu gibi haritacılık dalında da böyledir.

Tüm bu gereksinimlere bağlı olarak uzaktan algılama teknolojilerinin kullanımı kaçınılmazdır. Harita yapımı, analiz, risk yönetimi ve bunun gibi sayılabilecek daha birçok konuda uygulama altlığını oluşturan uydu görüntüleri, kullanıcılara teknik olarak farklı özelliklerde sunulmaktadır. Günümüzde zengin bilgi içeriği düşünüldüğünde yüksek çözünürlüklü uydu görüntüleri, uygulamanın içindeki kullanıcıları bu pazara çekmektedir.

Yüksek çözünürlüklü uydu görüntüleri yukarıda da belirtildiği gibi, zengin bilgi içeriğine sahiptirler ve bu yüzden tercih edilirler. Ancak tabii ki uygulamanın maliyeti söz konusu olduğunda bu görüntülerin ekonomik olup olmayacağı yapılacak işe bağlı olarak önceden belirlenmelidir. Bunun dışında bu görüntülerin kullanıma hazır hale getirilmesi ve uygulama aşamasında görüntü içerisinden bilgi çıkarılması için gerekli olacak yazılım ve donanım ihtiyaçları da göz önünde bulundurulmalıdır. En basit anlamda, uygulanacak metod bile bu aşamada söz sahibi olacaktır. Örneğin bu görüntülerdeki detayları ekran üzerinden elle çizmek veya bazı algoritmalar kullanarak otomatik veya yarı otomatik çıkarmak bile yazılım ve bu yazılımlar arasında teknik ve mali farklar oluşturacaktır.

Maliyetin dışında teknik olarak düşünüldüğünde, günümüzde uydu görüntülerinden detay çıkartma konusunda değişik yöntemler mevcuttur. Bu bağlamda en eski yöntem vektörel çizim tekniğidir. Bu yöntemle görüntü ekran üzerinde ele alınarak detayların sınırlarından vektör çizimler geçirilir ve bu vektörler anlamlı katmanlarda gösterilerek sonuç ürüne

ulaşılır. Ancak her bir detayın vektörel çizgilerle ifade edilmesi göz önüne alındığında ,bu oldukça uzun bir işlemdir. Tüm bunların yanında uydu görüntülerinin analizi için değişik sınıflandırma teknikleri kullanılmaktadır. Sınıflandırma teknikleri ele alınırken, kullanılan algoritmalarındaki işlem birimi önem kazanmaktadır. Görüntü sınıflandırmada, günümüze kadar piksel tabanlı yaklaşımlar söz sahibi olmuştur. Bu yaklaşımlarda görüntü içerisindeki tekil pikseller, renk değerlerine ve birbirleriyle olan komşuluk ilişkilerine göre ele alınmaktadır.

Günümüz görüntü işleme ve dolayısıyla uzaktan algılama teknolojilerinde, piksel tabanlı yaklaşımların yanında nesne tabanlı yaklaşımlar da kullanılmaya başlanmıştır. Yüksek çözünürlüklü görüntülerden elde edilen zengin bilgi içeriği, piksel tabanlı yaklaşımlarda tam olarak yansıtılamamaktadır. QuickBird uydu görüntüleri, piksel tabanlı yaklaşımlarda tutarsız sınıflandırma sonuçları vermekte ve araştırılan nesnenin çıkarımında beklentileri karşılayamamaktadır. Bahsedilen klasik metotların yapısından dolayı, bu durum, yeni ve nesne tabanlı görüntü analizi yapabilen yazılımların kullanımını gerektirir. Bu tür yazılımlarda kullanılan algoritmalar, sınıflandırmaların düzenlenmesi konusunda segmentleri daha uygun hale getirmek için, spektral bilginin yanında yapısal veya dokusal ek bilgilerle daha uygun çözümler sunar.

Piksel tabanlı yaklaşımların aksine, nesne-tabanlı yaklaşım, yapıyı, dokuları ve spektral bilgileri birlikte dikkate alır. Bu yaklaşımda sınıflandırma aşaması, komşu piksellerin gruplandırılmasının, sınıflandırmanın sonraki basamağında ele alınabilir anlamlı bölgelere dönüştürülmesi ile başlar. Bu tür segmentasyon ve topoloji oluşumu, çözünürlüğe ve çıkarılması düşünülen nesnelerin ölçeğine göre ayarlanmalıdır. Bu metotla, sadece tekil pikseller sınıflandırılmakla kalmaz, ayrıca bir önceki segmentasyon basamağı sırasında homojen görüntü nesnelere de ortaya çıkar. Bu segmentasyon değişik çözünürlüklerde yapılabilirken, nesne kategorilerinin katmanlarını ayırt etmeye de izin verir.

Yukarıda bahsedilen yeni yaklaşımlar yardımıyla günümüz şartlarında neler yapılabileceği doğrultusunda ele alınan bu tezin amacı aşağıda açıklanmaktadır.

Çalışmanın amacı düşünüldüğünde, günümüz teknolojilerinde uydu görüntüleri harita yapımı, analiz, risk yönetimi ve daha birçok konuda uygulama altlıklarını oluşturmaktadır. Kullanılan görüntünün özellikleri yapılan çalışmanın içeriğini doğrudan etkilemektedir.

Günümüzde büyük ölçekli haritaların yapımı bile uydu görüntüleriyle yapılabilir hale gelmiş bulunmaktadır. Örneğin, mevcut QuickBird uydusu verileriyle yaklaşık 5000 ile 10000 ölçekleri arasında haritalar üretilebilmektedir. Burada asıl önemli olan çözünürlükle harita ölçeğini ilişkilendirmek değil, o ölçekte elde edilmesi gereken bilgi içeriğinin kullanılan görüntüden çıkarılıp çıkarılamayacağıdır. Bahsedilen ölçek değerleri de bu noktada bilgi içeriğini karşılama anlamında kullanılmıştır (Karakış et al., 2005).

Ticari bir uydu olan QuickBird uydusundan elde edilen veriler çok değişik amaçlar için çok değişik yapılarda kullanıcılara sunulmaktadır. Günümüzde kullanılan tekniklerle bu veriler geometrik ve radyometrik olarak en iyi hale getirilmekte ve hemen hemen altlık gerektiren her türlü uygulamaya temel oluşturabilmektedir.

Ele alınan bu çalışmada, QuickBird uydusuna ait kullanılabilir verilerin yapısı ve hangi amaçlar için kullanılabilirliği araştırılmıştır. Ayrıca mevcut QuickBird Standart Ortho Ready (Standart Orto Hazır) test verisinin geometrik ve radyometrik istekleri karşılayıp karşılamayacağı, büyük ölçekli bir harita uygulamasıymış gibi ele alınarak da çözümlenmeye çalışılmıştır.

Yapılan çalışmanın başlıca amacı bu tip bir görüntüden hangi detayların ne ölçüde derlenebileceği, bu amaçla uygulanması gereken işlem adımlarının neler olduğu ve farklı tekniklerle yapılabilecek çıkarımların birbirine göre ve mevcut eldeki bilgilere göre ne kadar başarılı veya başarısız olduğunu incelemektir. Bu güdümlerle ele alınan bilgiye uygulanması gereken öncelikle geometrik işlemler tasarlanmış ve uygulanmış, ardından istenilen içeriğin tam çıkarılması için görüntüde yapılabilecek radyometrik geliştirmeler incelenmeye çalışılmıştır.

İzlenen yöntem açısından bakıldığında, yukarıda amacı açıklanan çalışmada, QuickBird Standart Orto Hazır görüntü seti kullanılmıştır. Bu veri sistematik yapıdaki geometrik hatalardan arındırılmıştır ve bir referans düzleme projekte edilmiştir. Kullanılan bu görüntü seti iki parçadan oluşmaktadır. İlk kısım pankromatik bant olup 60 cm yer örnekleme aralığına sahiptir. İkinci kısım çok bantlı görüntüdür, mavi, yeşil, kırmızı ve yakın kızılötesi bantlar içerilmektedir ve yer örnekleme aralıkları 2.4m'dir. Bu verilerin geometrik değerlendirilmesi sırasında GPS (Global Positioning System) gözlemleriyle konumlandırılan 33 nokta kullanılmıştır. Bu noktalar PCI Geomatica OrthoEngine V 9.1.4

yazılımında kullanılan ve CCRS (Canada Center for Remote Sensing)'den Dr. Thierry TOUTIN tarafından geliştirilmiş olan SOM (Satellite Orbital Modelling) yaklaşımında YKN (Yer Kontrol Noktası) olarak kullanılmıştır.

Ayrıca yüksek çözünürlükte çalışmanın sağlayacağı avantaj dolayısıyla, renkli görüntüden alınabilecek bilgi içeriğinin, pankromatiğe olan üstünlüğüne bağlı olarak bir görüntü birleştirme tekniği olan pan-sharp algoritması kullanılmıştır. Bu şekilde ele alınan görüntü verisi yüksek çözünürlüklü pankromatik ve daha düşük çözünürlüklü çok bantlı görüntülerin birleştirilmesiyle yüksek çözünürlüklü renkli görüntüye dönüştürülmektedir. Yine PCI Geomatica yazılımı altında bulunan pan-sharp algoritması, UNB (University of New Brunswick)'den Dr.Yun Zhang tarafından geliştirilmiş ve lisanslandırılmıştır. QuickBird firması tarafından da geçerli pan-sharp algoritması olan UNB algoritması diğer pan-sharp algoritmalarına olan üstünlüğü nedeniyle çoğu kullanıcı ve ticari yazılım firması tarafından kabul görmektedir.

Daha sonraki aşama ise görüntüden ne tür verilerin ne kadar çıkarılabildiği ve farklı yöntemlerin birbirine ve mevcut verilere olan üstünlüğünün araştırılmasıdır. Bu amaçla eski bilinen ekran üzerinden sayısallaştırma tekniği ve nesne tabanlı yaklaşımla çalışan eCognition yazılımının sonuçları irdelenmiştir. Ayrıca iki çıkarımın mevcut halihazır haritalarla uyuşup uyuşmadığı bu tezin sonuç analiz aşamasında ele alınmaktadır.

BÖLÜM 2

GEOMETRİK DÜZELTME VE RADYOMETRİK GELİŞTİRME

2.1 GENEL

Uzaktan algılama görüntüleri yapılarında sistematik ve sistematik olmayan hatalar barındırırlar. Bu nedenle uygulamada kullanılabilmeleri için bir takım düzeltmelere tabi tutulmaları gerekir. Görüntüden konumsal olarak yararlanma söz konusu olduğunda, görüntü orto ürüne veya sayısallaştırma sonucunda görüntüden elde edilecek vektör bilgiye dönüştürülebilir ve bu şekilde bir çok çalışmaya altlık oluşturabilir. Bunun için görüntüler uygulamaya geçmeden önce geometrik ve radyometrik olarak işlenmelidirler. Bu şekilde değişik zamanlarda ve değişik uydulardan elde edilen görüntülerin herhangi bir uygulamaya uyumu sağlanmış olur. Ayrıca günümüz yüksek çözünürlüklü uydu görüntülerinde kullanılması kaçınılmaz hale gelen pan-sharp tekniği ile yüksek çözünürlüklü pankromatik görüntü ve daha düşük çözünürlüklü renkli görüntü birleştirilerek yüksek çözünürlüklü renkli görüntü elde edilmektedir. Bu şekilde renk dokusuyla yüksek çözünürlüğün birleşiminden çok daha fazla ayrıntı görüntü üzerinden tanınıp, çıkarılabilmektedir.

Bu bölüm kapsamında, geometrik düzeltme amaçlı kullanılan matematiksel modeller üzerinde durulacak, ayrıca pan-sharp tekniği hakkında bilgi verilecektir.

2.2 UYDU GÖRÜNTÜLERİNİN GEOMETRİK DÜZELTİLMESİ

Ham uzaktan algılama görüntülerindeki geometrik hatalar, sistematik ve düzensiz hatalar olmak üzere iki farklı yapıya sahiptirler. Sistematik hatalar, bazı kalibrasyon ve yörünge bilgileri ile düzeltilebilirler ve çoğu zaman görüntüler, pazarlamacı firma tarafından sistematik hatalarından arındırılmış olarak satılırlar. Rastlantısal karakterli hatalar ise YKN ve SYM verilerinin kullanılması ile giderilebilirler. Rastlantısal hataların giderilmesinde pek çok matematiksel yöntem mevcuttur. Bu yaklaşımlar iki veya üç boyutlu olabilirler.

Parametrik veya parametrik olmayan modeller olarak iki farklı yapıda incelenebilen yaklaşımlar, algılayıcı sistemin görüntüleme geometrisinin dikkate alınıp alınmamasına göre isimlendirilmektedirler (Topan, 2004). Görüntüleme geometrisinin dikkate alınmadığı, parametrik olmayan modellerin geometrik düzeltmedeki özellikleri aşağıda sıralanmıştır.

- a. İki boyutlu parametrik olmayan modellerde yatay konum bilgisi kullanılmakta, bu yüzden yükseklikten kaynaklanan hatalar giderilememektedir.
- b. İki boyutlu bu modellerde, YKN'nın konum doğruluğu ve görüntüdeki dağılımı önem taşımaktadır. Bu tip yöntemde, YKN'nın yoğun olduğu bölgelerde yeterli sonuç alınabilirken, nokta yoğunluğunun dışında sonuçlar kötüleşmektedir.
- c. Üç boyutlu parametrik olmayan modellerde, yatay konum bilgisinin yanında yükseklik bilgisi de kullanılmaktadır. Bu şekilde YKN'nın konumundaki yükseklikten kaynaklanan hata da giderilmeye çalışılır. Fakat yatay ve düşey konum arasında fiziksel bir ilişki olmadığından bu üç konum değeri sadece model bilinmeyenlerini çözmek için kullanılır.
- d. YKN'sının konum doğruluğu ve dağılımı iki boyutlu parametrik olmayan modelde olduğu gibi üç boyutlu parametrik olmayan modelde de önem taşımaktadır.

Parametrik modeller, parametrik olmayan modellerden farklı olarak sistemin görüntüleme geometrisini dikkate alan daha üstün modellerdir. Bu modeller, YKN'nın konum doğruluğuna bağlı iken, dağılımına bağlı değildirler ve parametrik olmayan modellerden daha az sayıda YKN'na ihtiyaç duyulur (Toutin, 2003).

Parametrik ve parametrik olmayan modellere ilişkin genel bilgiler aşağıda başlıklar halinde verilmektedir.

2.3 PARAMETRİK OLMAYAN MATEMATİKSEL MODELLER

Uzaktan algılama görüntülerinin geometrik düzeltilmesinde kullanılan parametrik olmayan modeller için görüntü koordinat sisteminde koordinatları ölçülen ve yer koordinat

sisteminde koordinatları bilinen YKN verilerine gereksinim duyulmaktadır. YKN verileri aracılığıyla görüntü koordinat sistemi (x, y) ile yer koordinat sistemi (X, Y, Z) arasında matematiksel bir ilişki kurulabilir. Bu ilişki genel bir gösterimle, üç boyutlu uzayda:

$$\begin{aligned} x_i &= F_1(X_i, Y_i, Z_i) \\ y_i &= F_2(X_i, Y_i, Z_i) \end{aligned} \quad (2.1 \text{ a,b})$$

veya iki boyutlu uzayda,

$$\begin{aligned} x_i &= F_1(X_i, Y_i) \\ y_i &= F_2(X_i, Y_i) \end{aligned} \quad (2.2 \text{ a,b})$$

şeklinde ifade edilir ($i = 1(1)n$ n : Toplam YKN sayısı).

Bu bölümde üzerinde durulacak olan iki ve üç boyutlu parametrik olmayan matematiksel modeller, görüntü alım geometrisini dikkate almadan geometrik düzeltme işlemi yapmakta ve bu nedenle genel bir yaklaşımı ifade etmektedirler (Topan, 2004).

2.3.1 Çeşitli Polinom Derecelerini Kullanan İki Boyutlu Yaklaşım

Daha önce de söz edildiği gibi, görüntü ve yer koordinatları arasında kurulan matematiksel ilişki iki veya üç boyutlu uzayda kurulabilir. Çeşitli polinom derecelerinin kullanıldığı iki boyutlu yaklaşımda, isminden de anlaşılacağı üzere, matematiksel ilişki, iki boyutlu uzayda kurulmaktadır. Burada, modelin katsayıları belirlenmekte ve yer koordinatları hatasız kabul edilerek, görüntü üzerinde ölçülen herhangi bir noktanın görüntü koordinatına getirilecek düzeltme miktarı ve yer koordinat sistemindeki karşılığı bulunmaktadır.

Polinomal yaklaşımda, görüntü koordinatları ile YKN koordinatları arasındaki ilişki:

$$\begin{aligned} x_i &= \sum_{j=0}^N \sum_{k=0}^{N-j} a_{jk} X_i^j Y_i^k \\ y_i &= \sum_{j=0}^N \sum_{k=0}^{N-j} b_{jk} X_i^j Y_i^k \end{aligned} \quad (2.3 \text{ a,b})$$


şeklindedir. Burada;

N : Polinomun derecesi, $j= 1, 2, \dots, N, k= 1, 2, \dots, N-j, i = 1(1)2n$ şeklindedir.

Bu eşitlikte N dönüşümün amacına göre değişmektedir. Polinomal yaklaşımın genel kullanım şekli aşağıdaki gibidir:

$$\begin{aligned}
 x_i &= a_{00} && \text{(Sabit bir terim)} \\
 &+ a_{10}X_i + a_{01}Y_i && \text{(Doğrusal (1°) terimler)} \\
 &+ a_{11}X_iY_i + a_{20}X_i^2 + a_{02}Y_i^2 && \text{(Kuatratik (2°) terimler)} \\
 &+ a_{21}X_i^2Y_i + a_{12}X_iY_i^2 + a_{30}X_i^3 + a_{03}Y_i^3 && \text{(Kübik (3°) terimler)} \\
 &+ a_{31}X_i^3Y_i + a_{13}X_iY_i^3 + a_{40}X_i^4 + a_{04}Y_i^4 + a_{22}X_i^2Y_i^2 && \text{(Kuartik (4°) terimler)} \\
 &+ a_{32}X_i^3Y_i^2 + a_{23}X_i^2Y_i^3 + a_{50}X_i^5 + a_{05}Y_i^5 + a_{41}X_i^4Y_i + a_{14}X_iY_i^4 && \text{(Kuintik (5°) terimler)} \\
 &+ \dots && \\
 y_i &= b_{00} && \\
 &+ b_{10}X_i + b_{01}Y_i && \\
 &+ b_{11}X_iY_i + b_{20}X_i^2 + b_{02}Y_i^2 && \\
 &+ b_{21}X_i^2Y_i + b_{12}X_iY_i^2 + b_{30}X_i^3 + b_{03}Y_i^3 && \\
 &+ b_{31}X_i^3Y_i + b_{13}X_iY_i^3 + b_{40}X_i^4 + b_{04}Y_i^4 + b_{22}X_i^2Y_i^2 && \\
 &+ b_{32}X_i^3Y_i^2 + b_{23}X_i^2Y_i^3 + b_{50}X_i^5 + b_{05}Y_i^5 + b_{41}X_i^4Y_i + b_{14}X_iY_i^4 && \text{(3.4 a,b)} \\
 &+ \dots &&
 \end{aligned}$$


Yukarıdaki terimlerin her iki eksendeki etkisi Şekil 2.1’de görülebilir (Zoej, 1997).



Şekil 2.1 Polinom terimlerinin x (sol) ve y (sağ) eksenlerdeki etkisi.

Bu yöntem, YKN'lerin konum doğruluğuna oldukça bağlıdır ve katsayılar bu konum doğruluğuna bağlı olarak hesaplanırlar. Bu yöntem, YKN koordinatlarının yüksek doğrulukla seçilmesi durumunda kullanışlı olabilmektedir.

Yukarıda genel yapısı ile verilen polinomal dönüşümün en yaygın kullanım şekli ve birinci dereeden polinom eşitliği afin dönüşümü vermektedir (2.5 a,b). Dönüşümde koordinat eksenlerinin durumu Şekil 2.2'de gösterilmektedir.



Şekil 2.2 İki boyutlu afin dönüşümde koordinat eksenleri.

$$\begin{aligned} x_i &= a_{00} + a_{10}X_i + a_{01}Y_i \\ y_i &= b_{00} + b_{10}X_i + b_{01}Y_i \end{aligned} \quad (2.5 \text{ a,b})$$

(2.5 a,b) eşitlikleri, matris gösterimi ile yazılırsa,

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} 1 & 0 & X_i & Y_i & 0 & 0 \\ 0 & 1 & 0 & 0 & X_i & Y_i \end{bmatrix} \begin{bmatrix} a_{00} \\ b_{00} \\ a_{10} \\ a_{01} \\ b_{10} \\ b_{01} \end{bmatrix} \quad (2.6)$$

$$\bar{\underline{L}} = \underline{L} + \underline{v} = \underline{A}dx \quad (2.7)$$

bağıntısı yazılabilir. Bağınıtıda geçen terimlerin açıklamaları aşağıdaki gibidir:

\bar{L} : Dengeli görüntü koordinatları vektörü,
 L : Ölçülen görüntü koordinatları vektörü,
 A : Düzeltme denklemlerinin katsayılar matrisi,
 dx : Dengeleme bilinmeyenleri vektörü,
 v : Düzeltmeler vektörüdür.

dx bilinmeyenler vektörü ve v düzeltmeler vektörünün çözümü aşağıdaki gibidir:

$$dx = (A^T A)^{-1} A^T L \quad (2.8)$$

$$v = A dx - L \quad (2.9)$$

Birim ağırlıklı ölçünün karesel ortalama hatası (m_0),

$$m_0 = \pm \sqrt{\frac{\sum_{i=1}^{2n} v_i^2}{2n - u}} \quad (2.10)$$

x ve y görüntü koordinatına ait soncul karesel ortalama hatalar ise,

$$m_x = \pm \sqrt{\frac{\sum_{i=1}^n v_x^2}{n - \frac{u}{2}}} \quad (2.11)$$

$$m_y = \pm \sqrt{\frac{\sum_{i=1}^n v_y^2}{n - \frac{u}{2}}} \quad (2.12)$$

şeklinde hesaplanabilir.

Burada,

$v_{x,y}$: x ve y yönündeki görüntü koordinatlarına getirilecek düzeltmeler,
 u : Matematiksel modelin bilinmeyen sayısıdır.

Polinomal dönüşümde, görüntü ve yer koordinatları arasında kurulan matematiksel ilişkilerde, YKN'larına ait yükseklik değeri dikkate alınmadığı için YKN'nın yüksekliğinden dolayı oluşan konum hatasını gidermek mümkün olmamaktadır. Üç boyutlu matematiksel modelde, yükseklik (Z) değeri de hesaplamalarda dikkate alınmaktadır.

Burada üç boyutlu matematiksel modelden üçü üzerinde durulacaktır. Bunlardan ilki, afin dönüşümün değiştirilmiş bir hali olan ATRC (Yükseklik Değerini Kullanan Afin Dönüşüm), DLT ikincisi (Direct Linear Transformation) ve sonuncusu ise RFM (Rational Functions Modeli)'dir (Topan, 2004).

2.3.2 Yükseklik Değerini Kullanan Afin Dönüşüm

ATRC, afin dönüşüm gibi doğrusal bir yapıya sahiptir ve sekiz parametrelidir (Büyüksalih et.al., 2003). Bu yöntem, üç boyutlu afin dönüşüm olarak da adlandırılmaktadır. Ancak burada bu adlandırma yerine “yükseklik değerini kullanan” afin dönüşüm ifadesi kullanılmaktadır. Bunun nedeni, üç boyutlu afin dönüşümün üç boyutlu iki koordinat sistemi arasında kullanılmasıdır. Oysa burada kullanılan koordinat sistemlerinden görüntü koordinat sistemi iki boyutludur ve dolayısıyla afin dönüşüm, YKN'lere ait yükseklik değerini kullanarak üç boyutlu yer ve iki boyutlu görüntü koordinat sistemi arasında dönüşüm yapmaktadır. ATRC'ye ait bağıntı aşağıdaki gibidir:

$$\begin{aligned}x_i &= a_1 + a_2 X_i + a_3 Y_i + a_4 Z_i \\y_i &= b_1 + b_2 X_i + b_3 Y_i + b_4 Z_i\end{aligned}\tag{2.13 a,b}$$

Bu dönüşüm modelinin EKK Dengelemesiyle çözülebilmesi için, uygun dağılıma sahip en az beş YKN noktasının görüntü ve yer koordinatlarına gereksinim duyulmaktadır. (2.13 a,b) eşitlikleri, matris gösterimi ile yazılırsa,

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} 1 & 0 & X_i & Y_i & Z_i & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & X_i & Y_i & Z_i \end{bmatrix} \begin{bmatrix} a_1 \\ b_1 \\ a_2 \\ a_3 \\ a_4 \\ b_2 \\ b_3 \\ b_4 \end{bmatrix} \quad (2.14)$$

şeklinde olacaktır. dx bilinmeyenler vektörü ve y düzeltmeler vektörünün çözümü (2.8) ve (2.9) bağıntılarında olduğu gibidir. Soncul karesel ortalama hatalar da (2.10), (2.11) ve (2.12) bağıntılarında olduğu gibi hesaplanabilir (Topan, 2004).

2.3.3 Direct Linear Transformation

Bu yöntem, fotogramride sıkça kullanılan kolinearite bağıntılarının metrik olmayan fotogrametrik çalışmalar için geliştirilmiş halidir. Metrik olmayan sistemlerle yapılan fotogrametri uygulamalarında, kameranın iç ve dış dönüklük elemanları bilinmemektedir ve bu nedenle DLT yöntemi, bu ve benzeri çalışmalar için kullanılabilir. Benzer olarak bu yöntem, uzaktan algılamada da bu amaçla kullanılabilir. Metrik uygulamalarda da kullanılabilen bu yöntem, bilgisayar programcılığı açısından kolaylıkla uygulanabilmektedir (Abdel-Aziz and Karara, 1971).

DLT yönteminin on bir parametrelili genel eşitliği,

$$x_i = \frac{L_1 X_i + L_2 Y_i + L_3 Z_i + L_4}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1} \quad (2.15 \text{ a,b})$$

$$y_i = \frac{L_5 X_i + L_6 Y_i + L_7 Z_i + L_8}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1}$$

şeklinde dir. (2.15 a,b) eşitlikleri matris gösterimiyle,

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} X_i & Y_i & Z_i & 1 & 0 & 0 & 0 & 0 & x_i X_i & x_i Y_i & x_i Z_i \\ 0 & 0 & 0 & 0 & X_i & Y_i & Z_i & 1 & y_i X_i & y_i Y_i & y_i Z_i \end{bmatrix} \begin{bmatrix} L_1 \\ L_2 \\ L_3 \\ L_4 \\ L_5 \\ L_6 \\ L_7 \\ L_8 \\ L_9 \\ L_{10} \\ L_{11} \end{bmatrix} \quad (2.16)$$

şeklinde olacaktır.

Wang (1999)'da DLT yöntemini yüksek çözebilirlikli uydu görüntüleri (Ikonos, QuickBird vd.) için yeniden organize edilmiş bir fazla parametre taşıyan SDLT (Self-Calibrating DLT) yöntemini geliştirmiştir. SDLT'ye ait bağıntılar aşağıda verilmektedir:

$$x_i = \frac{L_1 X_i + L_2 Y_i + L_3 Z_i + L_4}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1} \quad (2.17)$$

$$y_i - L_{12} x_i y_i = \frac{L_5 X_i + L_6 Y_i + L_7 Z_i + L_8}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1}$$

DLT ve SDLT için \underline{dx} bilinmeyenler vektörü ve \underline{v} düzeltmeler vektörünün çözümü (2.8) ve (2.9) bağıntılarında olduğu gibidir. Soncul karesel ortalama hatalar da (2.10), (2.11) ve (2.12) bağıntılarında olduğu gibi hesaplanabilir (Topan, 2004).

2.3.4 Rational Functions Modeli

RFM, günümüzde Ikonos ve QuickBird görüntüleri için kullanılmakta ve uydu yörünge bilgileri yerine RFM'lere ait katsayılar, görüntüyü sağlayan şirketlerce kullanıcıya verilmektedir. (2.18 a,b) bağıntılarıyla gösterilen RFM yaklaşımı, YKN'lere ait Z değerini de kullanmaktadır:

$$x_{ij} = \frac{P_{i1}(X, Y, Z)_j}{P_{i2}(X, Y, Z)_j} \quad (2.18 \text{ a,b})$$

$$x_{ij} = \frac{P_{i3}(X, Y, Z)_j}{P_{i4}(X, Y, Z)_j}$$

Burada;

$$P_{i1}(X, Y, Z)_j = a_1 + a_2 Y_j + a_3 X_j + a_4 Z_j + \dots + a_{20} Z_j^3$$

$$P_{i2}(X, Y, Z)_j = b_1 + b_2 Y_j + b_3 X_j + b_4 Z_j + \dots + b_{20} Z_j^3$$

$$P_{i3}(X, Y, Z)_j = c_1 + c_2 Y_j + c_3 X_j + c_4 Z_j + \dots + c_{20} Z_j^3$$

$$P_{i4}(X, Y, Z)_j = d_1 + d_2 Y_j + d_3 X_j + d_4 Z_j + \dots + d_{20} Z_j^3$$
(2.19 a,b,c,d)

şeklindedir.

Parametrik matematiksel modeller, fotogrametrinin perspektif geometrisinin modellenmesi olan temel kolinearite eşitliğinin genişletilmiş yani değiştirilmiş şeklidir. Bu eşitliklerde sensör iç ve dış yöneltme parametrelerine ek olarak yörünge bilgileri içerilmekte ve sensörün her bir doğrusal dizini için ayrı bir eşitlik yazılmaktadır. Halbuki RFM yaklaşımında kullanıcıya sensör iç ve dış yöneltme bilgileri verilmemekte; sadece bu parametrelerden üretilmiş olan 80 adet katsayı verilmektedir. Kullanıcı böylece karmaşık matematik eşitliklerle çalışmaya ihtiyaç duymamaktadır. Space Imaging şirketinden alınan son bilgiye göre Ikonos-2 uydu görüntülerinden hiçbir YKN kullanılmadan, verilen katsayılarla herhangi bir nesne, 3-4 m doğrulukla konumlandırılabilir (Büyüksalih, 2004). Bu RFM'nin sağladığı yüksek duyarlılığı göstermektedir. Bu çalışmada bu yöntem denenmiş fakat geometrik açıdan SOM algoritmasının daha iyi sonuç vermesinden dolayı uygulama aşamasında gösterilmemiştir.

2.4 PARAMETRİK MATEMATİKSEL MODELLER

Parametrik matematiksel modeller, daha önce de değinildiği gibi, görüntü alım geometrisini dikkate alan modellerdir. Bu çalışmada kullanılan PCI Geomatica OrthoEngine V 9.1.4'de işletilen SOM algoritmasının yapısı hakkında aşağıdaki alt bölümde bilgi verilmektedir.

2.4.1 SOM

SOM, CCRS'den Dr. Toutin tarafından, doğrusal dizi sistemler için geliştirilmiştir. Bu yöntemde;


- a. Görüntüleme sistemini taşıyan uydunun konum, hız ve dönüklük değişimleri,
- b. Görüntüleme süresindeki değişimler, bakış açısı ve IFOV'dan kaynaklı etkiler,
- c. Yerin küreselliği,
- d. Harita projeksiyonundan kaynaklanan etkiler yörünge parametreleriyle birlikte dikkate alınmaktadır.

SOM yazılımı özel bir yazılım olup bu tez kapsamında ancak yürütümü yapılabilmektedir. Bu yazılımın arkasındaki matematiksel modelleme genel hatlarıyla bilinmekte olup, detaylı kapsam programların yazarlarında saklıdır (Topan, 2004).

2.5 PAN-SHARP VE KULLANILAN ALGORİTMALAR

2.1 alt bölümünde değinildiği gibi pan-sharp yapma bir çeşit görüntü birleştirmedir. Yüksek çözünürlüklü pankromatik görüntü, ondan daha düşük çözünürlüklü renkli görüntüyle birleştirilir. Sonuç ürün, yüksek çözünürlüklü renkli görüntüdür.

Öncelikli Ikonos, Quickbird ve ADS-40(hava) gibi sensörler pushbroom sensörlerdir. Detektör dizileri her bir spektral bant için ayrı doğrusal diziden oluşur. Doğrusal CCD dizi görüntüyü oluşturmak için yer boyunca tarama yapar (Padwick,2005). Şekil 2.3'de doğrusal dizi sensör gösterilmektedir.




Şekil 2.3 Doğrusal dizi sensörlerin şekilsel yapısı


QuickBird uydusu 16.5km'ye 16.5km'lik bir alanı yaklaşık olarak 4 saniyede toplar. QuickBird sensörleri aşağıda gösterilen bantlarda alım yaparlar;

- a. Pankromatik(Siyah-Beyaz)
- b. Çok Bantlı
 - Mavi
 - Yeşil
 - Kırmızı
 - Yakın kızılötesi

Şekil 2.4'de odak düzleminde sensörlerin oluşturduğu yapı, Şekil 2.5'de ise her bantta yapılmış bir alımın ayrı ayrı gösterimi yer almaktadır.



Şekil 2.4 Odak düzleminde sensörlerin algılama durumu ve yer yüzünden yansıma alım anı



Şekil 2.5 QuickBird uydusunun 4 bantta ayrı ayrı yapmış olduğu alım

QuickBird ve Ikonos uyduları için pankromatik ve çok bantlı alımların yapılması hemen hemen eş zamanlıdır. Kullanılan ekipmanların tarama yöntemine bağlı olarak alımlar arasında yaklaşık 0.2 saniyelik bir zaman gecikmesi vardır. Bu gecikme;


$$0.2 \times 7.5\text{km/sn}=1.5\text{km}$$

büyükliğündeki uzaklığa karşılık gelir. Diğer bir ifadeyle uydu alımlar arasında yörüngesinde 1.5km hareket eder.

Alımlar arasında uydunun belirsiz hareketleri pan ve ms bantların örtüşmemesine neden olur ve örtüşme sonucunda da bulanık bir pan-sharp görüntü oluşur. Ek olarak bantlar arasındaki paralaks da özellikle yükseklik modelinde hatalar olduğu zaman örtüşmemeye neden olabilir. Şekil 2.6'da oluşan paralaks durumu gösterilmektedir (Padwick, 2005).

$$p = hae \frac{d}{f} \times \frac{1}{\cos \theta}$$

p -> paralaks
 hae -> elipsoidal yükseklik
 d -> odak düzlemi uzaklığı
 f -> odak uzaklığı
 γ -> nadirden sapma açısı



Şekil 2.6 Uydu hareketinden kaynaklanan bantlar arasındaki paralaks

Günümüzde birçok yazılımla birlikte aşağıda belirtilen çeşitli pan-sharp algoritmaları mevcuttur. Bu algoritmaların kısa açıklamaları ilgili alt bölümlerde verilmektedir.

HIS Sharpening

PCA Sharpening

Gram Schmidt Sharpening

Wavelet Sharpening

UNB Sharpening (DigitalGlobe firması tarafından da kullanılan algoritma)

2.5.1 HIS Sharpening

HIS algoritması renk-yoğunluk-doygunluk (Hue Intensity Saturation) üzerine kuruludur. Düşük çözünürlüklü RGB görüntü yüksek çözünürlüğe örneklenir ve HIS görüntüye çevrilir. Daha sonra yoğunluk bandı yerine pankromatik görüntü yerleştirilir ve HIS görüntü yeniden RGB'ye çevrilir. Şekil 2.7'de HIS algoritmasıyla yapılmış bir pan-sharp görüntü verilmiştir. Şekilden de görüldüğü gibi yeşil alanlar yansıtılmamaktadır. Yeşil alanlara görünen ışıkta(RGB) bakıldığında koyudur (düşük yansıma). Eğer yakın kızılötesinde bakılırsa çok parlaktır (yüksek yansıma). Bu görüntüde kullanılan QuickBird ele alındığında, QuickBird pankromatik bantta yakın kızıl ötesini içerdiği sürece yeşil alan

pikselleri çok parlak olur ve küçük renk gürültü değerleri yükselir. Şekil 2.8’den de görüleceği gibi, yoğunluk bandı pankromatik bantla değiştirildiği zaman, yeşil alan pikselleri çok parlaktır ve sonuç olarak az bir renk değeri geri dönüştürülür.



Şekil 2.7 HIS algoritmasıyla üretilmiş pan-sharp QuickBird görüntüsü



A

B

Şekil 2.8 Yoğunluk bandıyla pankromatik bant arasındaki parlaklık farkı (A: Yoğunluk Bandı, B: Pankromatik Bant)

Pankromatik bantla ms bantlar arasındaki spektral örtüşme bilindiği sürece, yakın kızılötesinin etkisi pan banttan çıkartılabilir. Bu şekilde yapılan uygulamaya “görünür pan” adı verilirken, bu tarzda bir yaklaşımla görünür yoğunluğa uyum sağlanarak HIS algoritması iyileştirilmiş olur.

$$Görünenpan(piksel)=pan(piksel)-0.240*nir(piksel) \quad (2.20)$$


Şekil 2.9’da yoğunluk bandı ve görünür pan bandı birlikte görülmektedir. Şekil 2.10’dan da anlaşılacağı gibi iyileştirme biraz daha iyi sonuç alınmasını sağlamıştır.



A

B

Şekil 2.9 Yoğunluk bandıyla birlikte görünür pankromatik bant (A: Yoğunluk Bandı, B: Görünür Pankromatik Bant)

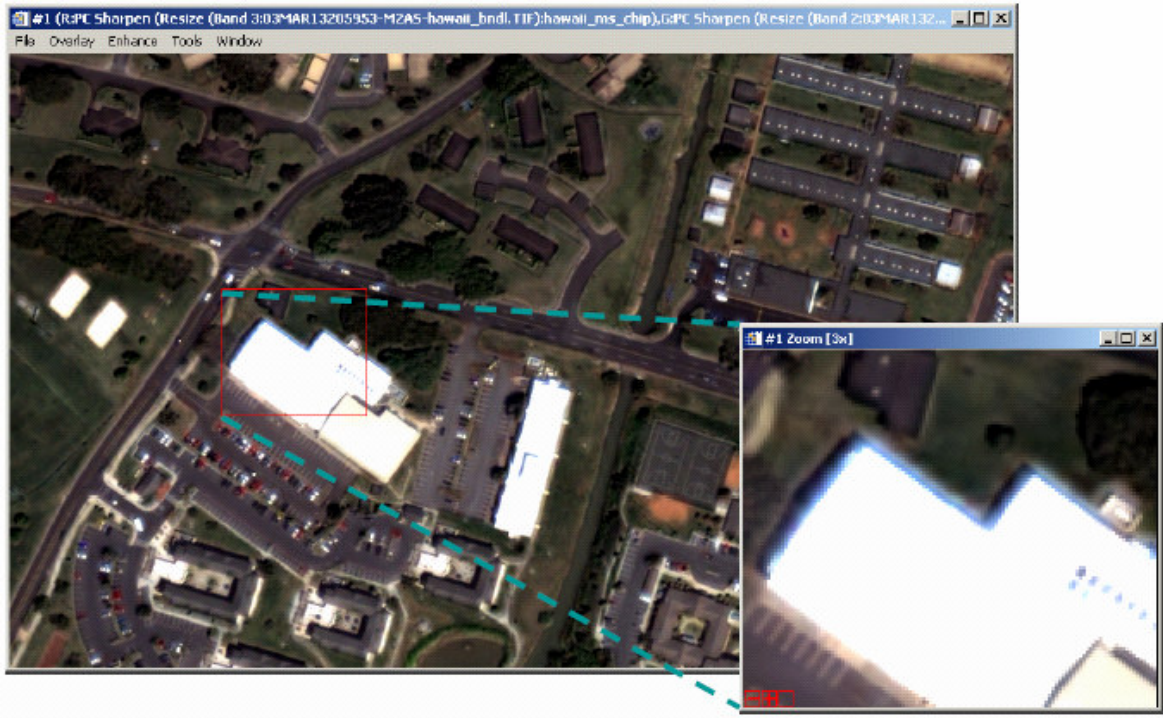


Şekil 2.10 Görünür pan iyileştirmesi uygulanmış HIS algoritması sonucu

HIS algoritması oldukça keskin bir görüntü sağlamaktadır, ancak çoğu kullanıcı için özellikle yeşil alanların dönüşümü doygunluk sağlayamamaktadır. Bahsedildiği gibi görünür pan yaklaşımıyla iyileştirilmeye gidilmektedir, ancak yine de sonuçlar yeterli düzeyde değildir.

2.5.2 PCA Sharpening

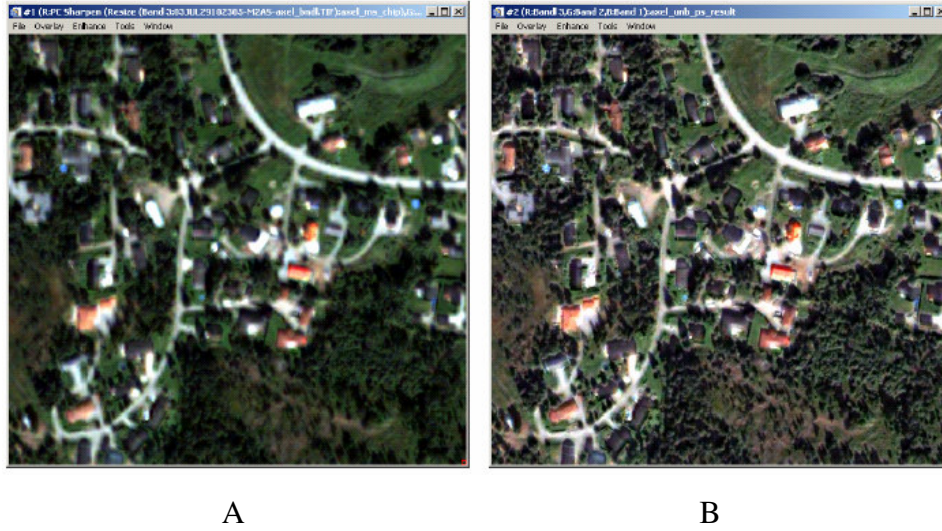
PCA algoritması (Principal Components Analysis - Temel Bileşenler Analizi) kovaryans matrisinin diagonal matrise (Tüm diyagonal elemanları 0) dönüşmesi üzerine kuruludur. İlk temel bileşen (PC) bilginin çoğunu içerir. Pankromatik bant ilk temel bileşen yerine koyulur ve görüntü eski haline döndürülür. Şekil 2.11’de bu algoritmaya bir örnek gösterilmektedir.



Şekil 2.11 PCA algoritmasıyla hazırlanmış pan-sharp görüntü

PCA sonuçları HIS sonuçlarına göre çok daha iyidir. Anlam ifade edebilecek uyşumsuzluklar parlak nesnelerin çevresinde görünür. Renk tonlaması açısından görüntü kabul edilebilecek niteliktedir. Ancak PCA algoritması çalışma alanının içeriğine doğrudan bağlıdır. Fazla yeşil alan içeriği, düşük performansa sebep olur. Yüksek yakın kızılötesi

katkısı, PCA dönüşümünün bozulmasına neden olur ve bulanıklaşma oluşur. Şekil 2.12’de aynı yerin PCA ve UNB algoritmalarıyla pan-sharp yapılmış hali verilmektedir.

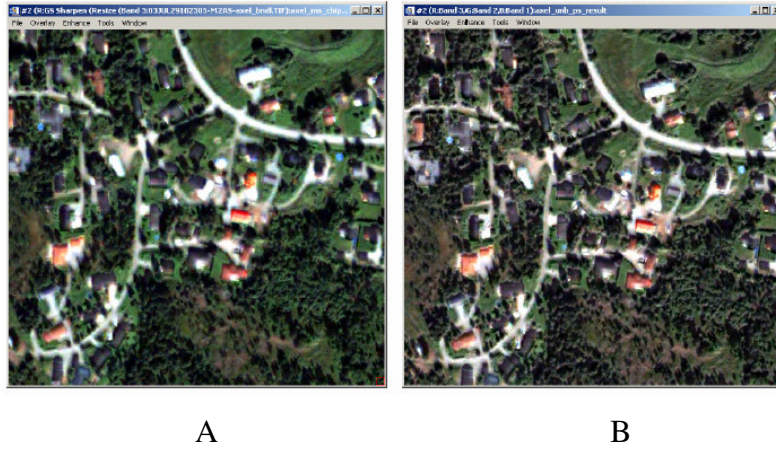


Şekil 2.12 PCA ve UNB algoritmalarının karşılaştırılması (A: PCA algoritması sonucu, B: UNB algoritması sonucu)

Renk dönüşümü tam olarak orijinal ms görüntüyü karşılamasa da genellikle kabul edilir sınırlar içinde bulunmaktadır. Keskinlik özellikle yeşil alanların fazla olduğu çalışmalarda sorun yaratabilmektedir. PCA algoritması çeşitli çalışma alanı içeriklerine kabiliyeti yok gibi görünmekle birlikte en iyi sonucu yerleşim alanlarında vermektedir.

2.5.3 Gramm Schmidt Sharpening

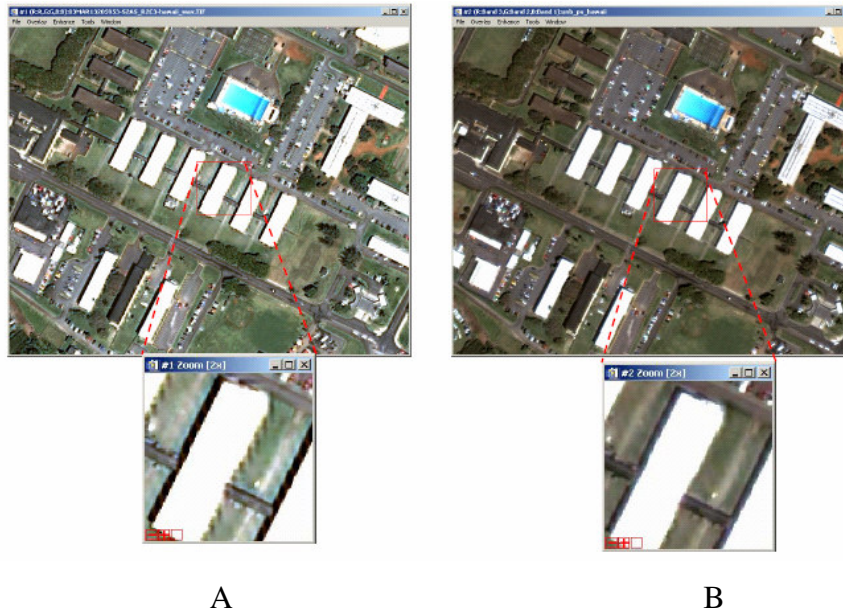
Bu algoritma Kodak/RSI firmasına ait bir algoritmadır. Algoritma doğasında PCA’ya benzer bir dönüşüm üzerine kuruludur. Sonuçlar da yine PCA’ya oldukça yakındır. Bu algortmada da özellikle çalışma alanında yeşil alanın fazlalığı sağlam sonuçlar almada problem yaratmaktadır. Şekil 2.13’de Gram Schmidt ve UNB algoritmalarıyla üretilen sonuçlar gösterilmektedir.



Şekil 2.13 Gramm Schmidt ve UNB algoritmalarının karşılaştırılması (A: GS algoritması sonucu, B: UNB algoritması sonucu)

2.5.4 Wavelet Sharpening

Diğerlerine göre daha yeni olan Wavelet algoritmasında dalgaların kullanımı söz konusudur. Bu algortmada düşük çözünürlüklü renkli görüntü, pankromatik görüntünün çözünürlüğüne yeniden örneklenir ve HIS görüntüye çevrilir. Pankromatik görüntü içerisinde yüksek frekans bilgisi çıkarılarak yoğunluk bandına eklenir. Sonuç görüntü tekrar RGB'ye dönüştürülerek pan-sharp yapılmış olur. Şekil 2.14'de Wavelet ve UNB algoritmalarının aynı alan için verdiği sonuçlar görülmektedir.



Şekil 2.14 Wavelet ve UNB algoritmalarının karşılaştırılması (A: Wavelet algoritması sonucu, B: UNB algoritması sonucu)

Wavelet algoritması sesin fiziksel temelleri üzerine kuruludur. Pankromatikten aldığı yüksek frekansı, rengi değiştirmeden çoklu bandın düşük frekansına ekler. Burada renk dönüşümü iyidir. Pankromatik ve ms bantlar arasındaki çözünürlük farkı (4X) uzaysal hatalara (gölgelenme, bulanıklık, basamaklanma) neden olur. Eğer çözünürlük yaklaşık 2 kat olsaydı sonuçlar çok daha iyi olurdu. Robust sonuçlar her zamanki gibi önemli bir konudur. Ancak sonuçlar her zamanki gibi çalışma alanının içeriğine bağlıdır.

2.5.5 UNB Sharpening

Algoritma UNB'den Dr.Yun Zhang tarafından geliştirilmiştir. Bu algoritma hem DigitalGlobe firması hem de bu uygulamada kullanılan PCI yazılımında lisanslı olarak kabul edilmiştir. DijitalGlobe firmasının normal şartlarda kullandığı algoritmadır.

Bu algoritmada renk dönüşümü mükemmeldir. Renkler orijinal çoklu banttakine çok yakın sonuçlar vermektedir.. Keskinlik kabul edilebilir sınırlarda olup diğer tekniklere göre (örneğin PCA, HIS) oldukça üstündür. Algoritma çok robust ve çeşitli çalışma alanı içeriklerini oldukça iyi ele alabilecek şekildedir (Padwick, 2005).

UNB algoritması istatistik tabanlı çalışan bir algoritmadır. Birleştirilen görüntü bantlarının gri değerleri arasındaki en iyi uyuşmayı bulmak ve renk distorsiyonunu azaltmak için her bir ayrı bandın sonuç ürüne ne kadar katkıda bulunacağını hesaplamak için en küçük kareler yöntemini kullanır. Veri seti bağımlılığı problemini ortadan kaldırmak ve birleştirme işlemi sürecini otomatikleştirmek için tüm işleme alınan bantlar arasındaki gri değeri ilişkilerini hesaplayan bir takım istatistik yaklaşım barındırır.

ulaşmak imkansızdır. Bundan başka, alt nesnelerin yapısına bağlı olarak, üst nesnelerin şekilleri değiştirilebilir.

Tekil pikseller veya tek pikselden oluşan nesnelerin, görüntü nesnelerinin özel bir durumu olduğu göz önüne alınmalıdır. Bu, en küçük işlem ölçeğini ifade eder.

Nesne tabanlı görüntü analizinin şaşırtıcı özelliklerinden biri, çok sayıda ek bilginin görüntü nesnelerinden çıkartılabilmesidir. Bunun arkasında yatan, şekil, doku, komşuluk ve diğer obje tabakalarından gelen bilgilerdir. Bu bilgiler kullanılarak, sınıflandırma, daha iyi semantik ayırım ve daha doğru sınıflandırma sonuçlarına ulaşabilir. Kavramsal bakış açısıyla, mümkün olan özellikler şu şekilde gruplara ayrılabilir:

Temel Özellikler: Objelerin fiziksel özellikleri, ki gerçek dünyanın resmedilmesiyle ve görüntüleme durumuyla belirlenir(basit olarak sensör ve aydınlatma). Bu özellikler rengi, dokuyu ve nesnelerin yapısını ifade eder.

Topolojik Özellikler: Nesnelere veya bütün çerçevenin geometrik komşuluğunu ifade eden özelliklerdir. Örneğin solda, sağda olma veya belirli bir nesneye belirli bir mesafede olma veya görüntü içindeki belirli bir alanda olma.

Çevresel Özellikler: Nesnelerin semantik komşuluk ilişkilerini tanımlayan özelliklerdir. Örneğin bir park %100 şehir alanıyla çevrili olmalıdır.

Sınıflandırmanın temelinde, görüntü nesnelerinin işlenmesi özel yollardan yapılabilir. Bir nesne orman olarak sınıflandırıldığı andan itibaren, örneğin lokal olarak yapay zeka uygulanabilir ve prensipte o andan itibaren bu nesneyle veya ilişkili çevresiyle yapılan her şey orman mantığı kullanılarak sürdürülür. Bir görüntünün tüm alanlarını aynı algoritmayla işlemek yerine, değiştirilmiş bir işlem uygulamak çok daha uygun olacaktır. Bu nesne tabanlı görüntü analizinin öne çıkan özelliklerinden biridir.

Nesne tabanlı yaklaşımın karakteristiği, görüntü nesnelerinin işlenmesi ve sınıflandırılması arasındaki döngüsel, karşılıklı etkileşimdir. Segmentasyona, ölçeğe ve görüntü nesnelerinin şekillerine bağlı olarak, sınıflandırma için özel bilgiler mevcuttur. Tam tersine, sınıflandırmaya bağlı olarak, özel algoritma işlemleri aktif hale getirilebilir. Çoğu

uygulamada istenilen coğrafi bilgi (geoinformasyon) ve ilgilenilen nesnelere, sınıflandırma ve işlemlerin iteratif döngüsüyle adım adım çıkarılabilir. Böylece, işlem birimi olan görüntü nesnelere, şekilleri, sınıf atamaları ve karşılıklı ilişkileri sürekli olarak değişmiş olur.

İnsanların görüntü anlama işlemine benzer olarak, bu çeşit döngüsel bir işlem, sınıflandırmada bir öncekinden daha farklı sonuçlar doğurur ve orijinal görüntü bilgisinin en doğru biçimde çıkarımını sağlar. Ayrıca her adımda üretilen bu farklı yeni bilgi ve malumatlar analizin diğer adımlarında yararlı bir şekilde kullanılabilir. Böylece çıkarım, sadece görüntü nesnelere, şekil ve boyutlarıyla ilgilenmekle kalmaz, onların semantik bilgilerini de işlem içerisine katar. Bu şekildeki döngüsel bir işlemle, görüntü alanındaki piksellerin sadece uzaysal kümeleşmesi gerçekleştirilmez, aynı zamanda görüntünün bilgi içeriğinin uzaysal ve semantik yapısına yaklaşılr ki bu noktada asıl önemli olan da gerçek dünya nesnelere yaklaşılmaktır. İlk adımlarda çıkarılan veri çok fazla fakat anlam ifade etmezken, gerçek anlamda bilgi ve semantik farklılıklar uygulamanın ileriki adımlarında oluşmaya başlar. Sonuç olarak sınıflandırılmış görüntü nesnelere, ilişkilendirilmesi, uzaysal veya semantik ağ olarak görülebilir. Bu noktadaki en önemli husus, bu şekilde bir ağ yapısının kurulmasıyla birlikte, ek bilgilerin bu ağ üzerinden çıkarımının, düzgün yapıdaki analizler yardımıyla oldukça basit bir şekilde yapılabilmesidir.

Nesne tabanlı yaklaşım, sonuçları birbirlerini etkilese de, pratikte birbirinden bağımsız olarak uygulanan, özel segmentasyon ve sınıflandırma teknikleridir. Örneğin, sınıflandırmaya esas olan yapı, segmentasyon sonucunda oluşan nesnelere, ancak iki aşama kesinlikle yapılırken birbirlerine bağılı değildir. Bununla beraber, bu iki ayrık uygulama içinde kullanılacak işlem metotlarının doğru seçimi, uygulamaya güç katabilir ve doğru bir segmentasyon ve sınıflandırma yöntemi, kullanıcıya yaklaşımın muhtemel tüm avantajlarını sağlar (eCognition, 2005).

3.2 GÖRÜNTÜ YORUMLAMADA TEMEL BİLEŞENLER

3.2.1 Görüntü İşlemede Yaklaşık Ölçek

Ölçek, görüntüyü anlamının önemli adımlarından biridir. Uzaktan algılama ve CBS için, günümüzde çok fazla kaynak bulunmaktadır. Her ne kadar uzaktan algılama alanında,

ölçek piksel çözünürlüğü olarak kabul edilse de, ilgi konusu istenilen nesnelere çoğu zaman kendi yapılarından gelen ölçeğe sahiptirler. Ölçek belirli bir obje sınıfının oluşmasını veya oluşmamasını belirler. Buna karşın sınıflandırma işi ve her bir nesne, direkt olarak ilgilenilen objenin ölçeğini belirler.

Ölçek ve çözünürlük arasındaki farklar: Çözünürlük genellikle bir pikselin yerde kapladığı alanı ifade ederken; ölçek, belirli bir olgunun tanımlanabildiği çıkarım büyüklüğünü veya seviyesini tanımlar. Bu nedenle bir görüntüyle farklı çözünürlükler yerine farklı ölçeklerde çalışmak analizi kolaylaştırır. Konu ile ilgili uzaktan algılama örnekleri, kentsel alanlar ve ekosistemlerdir. Bir şehrin yüksek çözünürlüklü görüntüsüne bakıldığını varsayalım. Çok yakından bakıldığında tekil evler, binalar, yollar ve diğer kentsel nesnelere ayrıntılı biçimde görülecektir. Eğer bakış mesafesi büyütülürse, bu kez tekil binalar görülmez, fakat oldukça farklı konut bölgeleri veya mahalleler ayırt edilebilir. Farklı dokular, farklı boyut ve şekilleriyle de seçilebilirler. Mahalle dokusu daha büyük bir ölçekte onun alt nesne ve yapılarını içerir (örn. Evler, yollar, bahçeler) ve bunlar özellikle renk tonu, şekil ve ayrıca topolojik ilişkileriyle tanımlanır.

Bir görüntüyü duvara yerleştirdiğimizde birkaç adımlık mesafeden, gözlemlerle şehrin kendisini ve belki onu çevreleyen tarım alanlarını ve ormanı fark edebilirsiniz. Çevreleyen tarımsal alanlar ve ormanların şehirle kıyaslanabilir büyüklükte olduğunu görebilirsiniz. Şehirlerin, ormanların ve tarım arazilerinin benzer ölçekte olduğunu kabul etmeliyiz. Farklı büyüklük ele alınırsa, aynı şey evler ve ağaçlar için de geçerlidir. Özet bir kabulle, eş zamanlı olarak yapıların farklı ölçeklerde olması, doğadaki ve ayrıca görüntüdeki fraktal geometrinin ve topolojinin bir sonucudur.

Ortaya çıkartılan farklı olgularda ve gerçek dünya nesnelere yapılarında bir çeşit hiyerarşi vardır. Bu hiyerarşi açıkça ölçekle belirlenir. Örneğin evleri, binaları, yolları çıkartırsak bunların birleştirilmesiyle yerleşim alanlarını, mahalleleri çıkartmış oluruz. Bunun gibi birçok yerleşim bölgesinin birleşimiyle kasaba veya şehir yapısına ulaşırız. Ekosistemler buna benzer örnekler gösterirler: Birkaç ağacın birleşimi bir grup ağaç oluşturur ve daha çok ağacı birleştirmek ya da birçok grubu birleştirmek bir ormanı oluşturur.

Ormanlar ve kasabalar benzer çıkarım düzeyi gösterirler. Her ikisi de kıyaslanabilir ölçektir ve her ikisi de yüksek semantik çıkarımdadır. Etkilenen nesne sınıfları arasındaki hiyerarşik ölçek ilişkileri açıktır: Örneğin mahalleler şehirlerin alt yapılarıdır ve evler de mahallelerin alt yapılarıdır. Bu hiyerarşik ölçek ilişkileri, gerçek dünya yapılarının gözlemlerinde ve tanımlanmalarında üstü kapalı olarak kendiliğinden verilir. Yine de bunun tersine, özellikle bu örneklerin açık bir şekilde sunumu, otomatikleştirilmiş görüntü yorumlama tekniklerine değerli katkılar sağlayabilir. Basitçe, evlerin kentsel alanlardaki sınıflandırma olasılığı, ormanda olmaları durumuna göre çok daha yüksektir. Bu nedenle bir görüntüyü başarılı bir şekilde analiz etmek için onun bilgi içeriğini birkaç farklı ölçekte eş zamanlı sunmak ve sonuç ürünler arasındaki farklı ölçek ilişkilerini ortaya çıkartmak gerekir (eCognition, 2005).

Bu bağ ve ilişkilerin, sadece görüntünün çözünürlüğünü değiştirerek analiz edilemeyeceğini gösterir. Bu husus birçok faydalı bilginin kaybolmasına da neden olabilir.

3.2.2 Görüntü Semantikleri – Görüntü Nesneleri Arasındaki Karşılıklı İlişkiler

Görüntüyü anlamadaki en önemli durumlardan biri, kontekst hakkındaki bilgidir. İki tür kontekstsel bilgi vardır: Görüntünün durumunu (basit olarak zaman, sensör ve konum bilgileri) tanımlayan global kontekst ve görüntü bölgelerinin karşılıklı ilişkilerini veya karşılıklı anlamlarını tanımlayan lokal kontekst. Kontekst bilgiyi işlemek her zaman bilinçli veya bilinçli olmadan insan algısında mevcuttur ve onun büyük kabiliyetine katkıda bulunur. Anlamlı kontekst bilgisi almak için, doğru ölçekteki görüntü alanları ilişkilendirilmelidir. Bu ölçek sınıflandırma işlemi ile görüntü verisinin çözünürlüğünün entegrasyonu ile kararlaştırılır.

Örnek olarak, çok yüksek çözünürlüklü bir görüntüde parkları ayırt etmek için sınıflandırma işlemi hayal edelim. Bir park her zaman geniş ve birbirini takip eden yeşil alanlardan oluşur. Bu farklı ölçek, parkı bahçeden ayırır. Ek olarak, parklar da örneğin parkların kentsel alanda yerleşmesiyle çayırlardan ayrılır. Tekil komşu evler parkları tanımlamak için yeterli bir şart değildir. Yine de, tekil binalara komşuluğu bahçeleri, çayırdan ayırmak için uygun bir ölçüttür. Bu basit örnek zaten ne kadar çok, birbiriyle ilişkili olan yapıların ölçeklerine bağlı kontekst bilginin mevcut olduğunu gösterir. Bu şaşırtıcı gerçek, anlamlı kontekst ilişkilerinin piksel tabanlı yaklaşımları kullanarak

tanımlamanın ne kadar zor veya hatta imkansız olduğunu açıklar. Sadece uygun ölçekteki görüntü nesnelere bağlı görüntü bilgisini sunmak, görüntü semantiğinin ele alınmasını sağlar. Ek olarak, görüntü nesnelere uzaysal kontekstinden haberdar olmalarını sağlamak için, onları ilişkilendirmek gerekir. Bu nedenle bir topolojik ağ yaratılır. Aynı konumdaki, farklı ölçekteki görüntü nesnelere bağlandığı zaman, bu ağ hiyerarşik olur. Böylece her nesne onun komşusunu, alt ve üst nesnelere bilir. Bu ayrıca hiyerarşik ölçek ilişkilerinin tanımına izin verir. Sınıflandırmayla ve sınıflarla nesnelere arasındaki karşılıklı bağlar ile böyle bir ağ uzaysal semantik ağ olarak görülebilir. Şu bir gerçektir ki; her zaman görüntü semantikleriyle uğraşmak anlamına gelen görüntü anlama, özellikle uzaktan algılama alanında dijital görüntü işleme kapasitesiyle yeterince örtüşmemektedir.

Uzaktan algılama bilgilerini çıkarmadaki şüphe ve çeşitli belirsizlikler, uzaktan algılama verisinden çıkarılacak bilgiyi etkiler. Her şeyin başında, aynı algılayıcıdan gelse bile, çerçeveden çerçeveye değişen, veri kazanım işlemlerini, veri işlemeyi ve veri üretimini etkileyen birçok faktör vardır. En basitinden, dünya gözlem verilerinin doğasından gelen problem, yer örtüsünün mevsime, günün zamanına, ışık durumuna ve hava durumuna göre farklı görünebilmesidir. Ayrıca, aynı çeşit nesnelere, sensöre ve çözünürlüğe bağlı olarak çok farklı görünebilirler.

Özellikler ve arazi örtüsü veya arazi kullanımı arasındaki ilişki genellikle sadece kaba bir şekilde modellenir ve belirsizlik, arazi örtü ve kullanım kavramının içinde bile doğal olarak içerilir. Sensör ölçümleri (görüntü pikselleri için ana kaynak) cihazların hassas kalibrasyonundan sonra bile sınırlı radyometrik çözünürlüğe sahiptir. Uzaktan algılamada geometrik çözünürlük (herhangi bir görüntü edinme işleminde) aynı şekilde sınırlıdır. Bu etki bir çözünürlük hücresi kadar sınıf karışmasına yol açar. Şöyle ki; bir çözünürlük hücresi su-kara geçişini kaplıyorsa, ilgili piksel kıyı bölgesini bir miktar suyla ve bir miktar yer örtüsüyle gösterir.

Görüntü üretim işlemi sensör ölçümlerini görüntü verisine çevirir. Ek olarak bu veri, arşivleme ve veri transferi gereksinimlerini azaltmak için sıkıştırılmalıdır. Çoğu durumda, bu veri işleme adımları, sonuç görüntü ürününde ek belirsizliklere yol açan, kusur ve tutarsızlıklara sebep olur.

Genellikle arazi örtüsü ve kullanımı için sadece belirsiz fikirler mevcuttur. Yoğun ve seyrek yerleşmiş alanlar arasında veya az çok bitki örtüsüyle kaplı alanlar arasında tam bir sınır yoktur. Her ne zaman sınırlar sayısal terimlerle tanımlanırlarsa, gerçek dünyaya yaklaşım genellikle tatmin edici olmaz. Bu nedenle, sınıflandırma boyunca ve sınıflandırmanın performansının belirlenmesinde sorunlar ortaya çıkar.

Uzaktan algılama veri tabanlarından geri alınan bilgi, büyük ölçüde belirsiz bilgiye dayanır. Özellikle önemli kontekst bilgisi tipik olarak sadece belirsiz dil kuralları terimlerinde ifade edilir. Örneğin, eğer ağaçlar “neredeyse tam olarak” yerleşim alanlarıyla çevriliyse park sınıfına dahil edilirler.

Bundan başka, çoğu durumlarda özel bir sınıflandırma işi için beklenen bilgi, o görüntü verisinde hiç içerilmeyebilir ya da yeterli olmayacak düzeydedir. Bu uzaysal veya radyometrik çözünürlükten, sinyal gürültü oranının çok düşük olmasından veya basit olarak, ilgili yerin farklı bilgileri için, sensörün farklı sinyalleri iletmemesinden kaynaklanabilir.

Eğer bu belirsizlikler, bilgi çıkarımında dikkate alınmazsa, sınıflandırma robust ve daha sonra kullanılabilir olmaz. Geçişli sınıflayıcılar olarak adlandırılan birkaç yaklaşım mevcuttur. Bunlar, sözü edilen bu belirsizlikleri dikkate alır (eCognition, 2005).

3.3 SEGMENTASYON

Segmentasyon görüntünün birbirinden farklı alt bölümlere ayrılmasıdır. Görüntü segmentasyon işlemleri, yıllar boyunca görüntü analizi alanında ana araştırma odağı olmuş ve çözüm için farklı yaklaşımlar izlenmiştir. Bunlardan yalnızca birkaçı, operasyonel ayarlar altında, robust, uygulanabilir ve nitelik bakımından ikna edici sonuçlar vermiştir ki bir görüntünün istenilen sayıda alanlara segmentasyonunun astronomik rakamlardaki muhtemel sonuçları olması zor bir problemdir. Çok sayıdaki serbestlik derecesi, verilen gereklilikleri karşılayabilecek bir veya birkaç serbestlik derecesine indirilmelidir. Ayrıca başka bir zorluk da, çoğu durumda ilgilenilen alanların heterojen olmasıdır. Heterojenlik durumunda belirsizlikler ortaya çıkar ve gerekli olan, anlaşılması gereken bilgi direkt olarak çıkarılamaz. Bu şekilde problemlerle baş edebilecek, kalite ve performansı

ilgilendiren gereklilikleri (veri setinin boyutu ve işletim süresi) ve yeniden üretilebilirliği aynı anda yerine getirebilecek çok az bir yaklaşım mevcuttur.

Görüntü segmentasyonunda arzu edilen, çoğu durumda belirli bir görev için bir görüntüde ilgilenilen, istenilen nesnelere otomatik olarak çıkarılabilmesinin mümkün olmasıdır. Bunun yanında, bu beklenti, çoğu durumda bu sonuca başarılı bir şekilde ulaşmak için ele alınması gereken çok sayıda semantiği yok sayar ya da problemlerin veya görüntü verisinin sadece indirgenmiş bir türüne uygulanabilen çok özelleştirilmiş algoritmaların geliştirilmesine yol açar.

Tabii ki görüntü nesnesi üretimi için burada özetlenemeyecek birçok çeşitli metod vardır ve her birinin kendisine özgü avantaj ve dezavantajları mevcuttur; kimisi yarı otomatikken kimisi tam otomatiktir. Genel bir bakışla, görüntü anlamadaki son araştırmalara göre, segmentasyon metodları iki ana gruba ayrılır; bilgi çıkarım metodları (yukarıdan-aşağıya) ve buna karşılık veri çıkarım metodları (aşağıdan-yukarıya). Yukarıdan-aşağıya yaklaşımında, kullanıcı zaten görüntüden ne çıkarmak istediğini bilir, fakat çıkarımı nasıl yapacağını bilmez. İstenilen nesne modeli formülize edilerek, sistem onları çıkarmak için en iyi görüntü işleme metodunu bulmaya çalışır. Formülize edilmiş nesne modeli, nesnelere anlamlarını üstü kapalı olarak verir. Aşağıdan-yukarıya yaklaşımında, segmentler bir dizi istatistik metod ve parametreyle tüm görüntüyü işlemeye bağlı olarak üretilir. Aslında, aşağıdan-yukarıya yöntemi bir çeşit veri çıkarımı veya sıkıştırma olarak görülebilir. Ama, gruplama metodlarındaki gibi, başlangıçta üretilen görüntü segmentleri hiçbir anlam ifade etmezler. Daha iyi bir tarifile görüntü nesne primitifleri olarak isimlendirilirler. Üretilen görüntü nesnelere ne çeşit gerçek dünya nesnelere ifade edeceğini belirlemek kullanıcıya bağlıdır. İki yaklaşım arasındaki temel fark; yukarıdan-aşağıya metodları genellikle lokal sonuçlar verir, çünkü hemen model tanımlamasını karşılayan pikselleri işaretler, oysa aşağıdan-yukarıya metodları bütün görüntünün segmentasyonunu gerçekleştirir. Pikselleri, belirli homojenlik ve heterojenlik kriterini karşılayan uzaysal gruplara birleştirirler.

Görüntü nesne primitiflerini temel işlem birimi olarak alan bir nesne tabanlı görüntü analizi yaklaşımında, bir görüntünün tamamının segmentlere ayrılması gerekir. Bu şekildeki genel bir bakışla en genel aşağıdan-yukarıya yaklaşımları düzenlenebilir.

Bazı basit yaklaşımlara örnek olarak, tüm sınır değer kullanan genel yaklaşımlar verilebilir. Spektral özellik uzayı alt bölümlere ayrılır ve aynı alt bölümlerin pikselleri, görüntü verisi içinde lokal olarak bitişik olduğunda birleştirilir. Bu metot bağıl olarak sınırlı kalitede sonuçlara yol açar. Segmentasyon taşması veya eksik kalması (örneğin, çok küçük bölümlere ayırmak veya birbirine ait olmayan alanları birleştirmek) anlamlı sınır değerlerinin iyi kontrol edilmediği durumlarda kolayca meydana gelir. Lokal kontrastlar göz önüne alınmaz ve uygun bir biçimde gösterilmezlerse sonuç alanlar geniş ölçüde boyut olarak farklı olurlar. Alan genişletme algoritmaları pikselleri sınırlı sayıda tekil kaynak noktasından başlayarak birleştirir. Bu algoritmalar temelde verilen kaynak noktalarına bağlıdır ve sıkça bir bölgenin genişlemesi için algoritma içinde kullanılan ölçütlerin tam kontrol altında tutulamamasından dolayı problem çıkarırlar.

Sık sık kullanılan eylemsel uygulamalar, farklı çeşitlerdeki doku segmentasyon algoritmalarıdır. İki aşamalı tasarıdan oluşurlar.

1. Model aşamasında karakteristik özellikler görüntü dokusu içerisinden ve sınırlar ise uzaysal frekanstan çıkarılır. Bunlar MRF modelleri, birlikte meydana gelme matrisleri dalga katsayıları, dalga paketleri ve fraktal gösterimlerdir.

2. Optimizasyon aşamasında özellikler uygun kalite ölçütüne kadar azaltılarak homojen segmentler halinde sınıflandırılırlar. Buna çoğu sıklıkta, birkaç çeşit gruplama kıymet fonksiyonlarıyla ulaşılır (Hoffmann et al., 1998).

Doku segmentasyonu her ne kadar çoğaltılmaya öncülük etse de çoğu zaman sadece sınırlı sayıdaki görüntü verisi, doku tipi ve problem çeşidine uygulanabilir. Dokunun çoğunlukla fark edilebilmesi için çok düzenli olması gerekir. Her seçilen ölçekte sonuçlara ulaşılamaz.

Segmentasyon aşaması için genel alternatifler bilgi-tabanlı yaklaşımlardır. Çalışma sahasından veya diğer kaynaklardan türetilen bilgileri segmentasyon işleminin içine katmaya çalışırlar. Bu yaklaşımlar çoğunlukla bir global özellik uzayında, gruplama üzerine, piksel tabanlı sınıflandırma yürütürler. Segmentler sınıflandırmadan sonra örtülü olarak üretilirler. Bu işlem basit olarak aynı sınıfa dahil olan tüm komşu pikseller birleştirilerek yapılır. Böyle olunca, bu yaklaşımda aynı sınıfta, ilgilenilen farklı birim veya

nesneleri ayırmak mümkün olmaz. Daha ötesi, sınıflandırmanın işletilmesinde kullanılan bilgi, spektral ve filtrelemeyle türetilmiş bilgiyle sınırlı kalır.

Daha güncel bir uygulama, su sınırı segmentasyonudur. İsmi, alanları su toplama havzalarına ayıran algoritmalarda izlenen yoldan alır. Tipik olarak yöntem, öncelikle orijinal veriyi eğim görüntüsüne çevirir. Sonuçta çıkan gri tonlamalı görüntü topoğrafik bir yüzey gibi kabul edilebilir. Eğer bu yüzey minimum değerlerinden itibaren kabartılır ve farklı kaynaklardan gelen su çizgilerinin birleşmesi engellenirse, görüntü su toplama havzaları ve su toplama çizgileri olmak üzere iki farklı bölüme ayrılmış olur. Su toplama havzaları teorik olarak bu görüntünün homojen gri düzeyi alanlarına uymalıdır. Bu metod, aslında dışbükey ve bağıl olarak yumuşatılmış nesneleri, hatta hafifçe dokunan nesneleri bağıl olarak homojen görüntü verisi içinde ayırmak için çalışır. Yöntem çalıştığı zaman rahat, hızlı ve güçlüdür. Bununla beraber, uzaktan algılama verisi için, ki belirli bir gürültü içerir ve her zaman kuvvetli kontrast sağlamaz, bu metod istenilen sonuçlara ulaşmayabilir (eCognition, 2005).

3.4 SINIFLANDIRMA - SINIFLANDIRICILAR VE METOTLAR

Genellikle sınıflandırma, belirli bir sayıdaki nesneyi, sınıf tanımlamalarına göre belirli bir sınıfa dahil etmek anlamına gelir. O sebeple, bir sınıf tanımlaması, istenilen sınıfın sahip olduğu tipik özelliklerin ve durumların tanımlamasıdır. Ardından nesnelere bu özellikleri veya durumları karşılayıp, karşılamadıklarına göre sınıfa dahil edilirler. Veri tabanı dilindeki terimiyle, özellik uzayı, nesnelere ve sınıflar arasında çoktan-teke ilişki kurmaya olanak sağlayan bağımsız bölgelere ayrılır. Sonuç olarak her nesne bir kesin sınıfa dahildir veya hiçbir sınıfa dahil değildir. Klasik sınıflandırıcılar uzaktan algılamada (örneğin maksimum benzerlik, minimum mesafe veya paralelyüz) bu suretle nesnelere 1 veya 0 olarak üyeliği atarlar. Bahsedilen bir nesne, ya bir sınıfa dahildir veya değildir. Bu tip sınıflandırıcılar, nesneleri, ikili yaklaşımla sınıfa atadığının kabulünden beri geçişsiz sınıflandırıcılar olarak adlandırılırlar. Bunun tersine, geçişli sınıflandırıcılar (temel olarak bulanık sistemler ve/veya Bayes sınıflandırıcıları) bir nesnenin, bir sınıfa üyeliğini tarif etmek için bir üyelik derecesi veya olasılık kullanırlar. Üyelik değeri genellikle 1.0 ve 0.0 arasında yer alır. 1.0 bir sınıfa tam üyelik/olasılık ifade eder (tamamen dahil olmak) ve 0.0 tam anlamıyla üye olmamayı/olasılık olmamasını ifade eder. Bu suretle üyelik/olasılık derecesi, nesnelere sınıf tanımlama özelliklerini/durumlarını, tam anlamıyla ne kadar

karşılıklarına bağlıdır. Geçişli metodun asıl avantajı, sınıf tanımlamalarındaki belirsizliklerin ifade edilmesidir. Aynı zamanda, her bir nesnenin birden fazla sınıfa üyeliğinin tanımlanmasını veya diğer sınıflara ait olma olasılıklarını farklı düzeylerdeki üyelik veya olasılık şartıyla mümkün kılar. Görüntü anlamaya bağlı olarak, bu geçişli sınıflandırma sonuçları dünya hakkındaki belirsiz insan bilgisini ifade etmekte daha başarılıdır. Bu da insan diline, düşüncesine ve aklına daha yakın sınıflandırma sonuçları vermesini sağlar. Başka bir deyişle, geçişli sınıflandırıcılar, geçişsiz sınıflandırıcılara karşı daha gerçekçi sonuçlar verir. Fakat çoğu uygulama, ihtiyaç duyduğu arazi kullanımının ve örtüsünün geçişli sınıflandırma sonuçlarını kullanamaz. Bu yüzden geçişli sınıflandırma sonuçları geçişsizleştirilmelidir, ancak bu sınıflandırma doğruluğunu ve hassasiyetini kötü yönde etkileyebilir.

Dikkate alınan sınıflandırma metotları temel olarak kontrollü ve kontrolsüz olarak ayrılabilir. Kontrollü metotta, istenilen sınıfların nasıl olacağı kullanıcıya sorulurken, kontrolsüz yöntem hemen hemen kullanıcıdan bağımsızdır. Benzer özellik gösteren nesnelere türlerine göre gruplara ayıran istatistiksel gruplama metotları olarak görülebilir. Kontrolsüz yöntem hemen hemen otomatik çalışırken, kontrollü yöntem kullanıcı tarafından düzenlenmelidir (genellikle ya örnekler seçerek ya da sınıf özelliklerini tanımlayarak). Bu yüzden, sınıf tanımlama bilgisi mümkün olduğu kadar hassas, temsil edici ve tam olmalıdır, ki birçok durumda bu imkansızdır. Bundan dolayı, bir sınıfın tanımlanması genellikle sadece istenilen sınıf özelliklerinin bir tahmini olabilir. Özellikleri tahmin etmek aynı zamanda sınıf tanımlamaları hakkında az çok bilinen bir belirsizliği kabullenmek veya özelliklerin ölçülmüş değerleri hakkındaki bilinen bir belirsizlik anlamına gelir. Bu belirsizlikleri formülize edebilmek ancak geçişli sınıflandırıcılar kullanarak olur.

Kontrolsüz ve kontrollü sınıflandırma metotları karşılaştırıldığında her birinin avantajları ve dezavantajları görülecektir. Kontrolsüz yöntemler, kontrollü yöntemlere göre fark edilebilir derecede hızlıdır, ama sınıflandırma algoritmalarının özel bir dalı oldukları sürece, sonuçların kullanıcılar tarafından yorumlanması gerekir (Bazı durumlarda bu zor olabilir ve sınıflandırmanın sayısız kez tekrarlanmasına yol açabilir). Kontrolsüz sınıflandırmanın diğer bir avantajı nesnelere istatistiklerini tamamen ve sistematik olarak analiz edebilme kabiliyetidir. Böylece, kontrolsüz bir sınıflandırmanın sonuçları, algılanabilecek sınıflar hakkında kullanışlı bilgiler verebilir. Ancak genelde belirsizlikleri

formülize etmek, sınıflara ve onların özelliklerine bağlı olarak değil, sadece sınıflandırma parametrelerine bağlı olarak mümkün olabilir. Tersine, kontrollü sınıflandırma metotları, kullanıcının, sınıf özelliklerini açık bir şekilde veya sınıfı temsil eden örnekleri seçerek tanımlamasını gerektiren çok daha yoğun çalışmalardan oluşabilir. Avantajları, ilk olarak genellikle yüksek kalitede olması ve sınıfların önceliklerinin sayılması ve isimlendirilmesi, ikinci olarak da, sınıf bağımlı belirsizliklerin açıkça formülize edilmesidir. Bazı sınıflandıramama durumlarında, özellikle ikinci avantaj, bunun sebeplerini araştırmayı kolaylaştırır. Ama sınıf tanımlamalarının kendileri de insan muhakemesinin bir sonucu olduğu sürece anlama açısından ve buna bağlı olarak araştırılması bakımından kolaydır (eCognition, 2005).

3.4.1 Bulanık Sınıflandırma Sistemleri

En güçlü geçişli sınıflandırıcılar, bulanık sistem üzerine kurulu olan sınıflandırıcılardır. Bulanık mantık, belirsiz ifadeleri ölçülendirmek için matematiksel bir yaklaşımdır. Temel düşünce, iki kati mantıksal ifade olan “evet” ve “hayır” durumlarını, devam eden $[0...1]$ aralığıyla değiştirmektir. Burada 0 “kesinlikle hayır” ve 1 “kesinlikle evet” anlamına gelir. 0 ve 1 arasındaki her değer, “evet” ve “hayır” ın daha az veya çok belirgin durumunu ifade eder. Böylece, bulanık mantık insan düşüncesinin yerini alabilir ve hesapta yer alabilir. Bulanık sınıflandırma sistemleri, uzaktan algılama bilgilerinin çıkarılmasındaki çoğu belirsizliği dikkate almaya iyi uyan bir yapıdadır. Parametre ve model belirsizlikleri, üyelik fonksiyonlarıyla tanımlanan bulanık ayarlamalarla dikkate alınır. İkili “doğru” veya “yanlış” yerine çoklu değerlendirmeli bulanık mantık, “doğru” ve “yanlış” arasındaki geçişlere izin verir. Ek olarak, “ve” ile “veya” mantık uygulamalarının da az veya çok geçişli ifadeleri bu şekilde kullanılabilir.

Bulanık sınıflandırma sistemlerinin çıkış ürünü, her bir nesne için, her arazi örtüsü veya arazi kullanımına ait sınıf üyelik derecelerinin belirtildiği bulanık sınıflandırmadır. Bu yaklaşım detaylı performans analizini ve her bir nesne için sınıf karışımı mantığını mümkün kılar. Bu geçişli sınıflandırmanın başta gelen avantajlarından biridir. En büyük üyelik derecesi, kati (boolean, ikilik) sistemlere bir arayüz oluşturmak için sonuç sınıflandırmayı belirler. Bulanık sistemler üç adımdan meydana gelirler. Bunlar; bulanıklaştırma, bulanıklık kural tablosu ve durulamadır.


3.4.1.1 Bulanıklaştırma

Bulanıklaştırma ikilik sistemden bulanık sisteme geçişi tanımlar. Her özellik değeri için 0 ve 1 arasında bir üyelik derecesi belirler. Üyelik değeri üyelik fonksiyonu diye isimlendirilen bir fonksiyon tarafından tanımlanır. Fonksiyonun şekline bağlı olarak, “evet” ve “hayır” arasındaki geçiş keskin (dikdörtgensel bir fonksiyon için) veya bulanık olabilir. Şekil 3.1’ de örnek bir fonksiyon grafik olarak gösterilmiştir.

0’ dan yüksek üyelik değerleri üreten özellik değerleri dizisi, bulanık dizi olarak adlandırılır. Genelde, üyelik fonksiyonunu genişletmek, alttaki kavramın belirsizliğine yol açar. Üyelik değerlerini küçülterek, daha çok belirsizlik dizide işlenebilir.


Bulanık bir sistemde farklı özelliklerin birleştirilmesi her zaman özelliklerin bulanıklaştırılmasından sonra yapılır. Bu yüzden, bulanık kombinasyonlar için tam giriş değerleri, ikilik özelliklerin dinamiğinden bağımsız olarak, 0 ve 1 aralığındadır. Bu çok boyutlu özellik uzayında değişik dinamiklerle ve değişik tipteki özelliklerle çalışmayı kolaylaştırır. Örneğin farklı sensörlerden geri emilim, coğrafi bilgi, doku bilgisi ve hiyerarşik ilişkiler vb.

Başarılı bir sınıflandırma için önceden üyelik fonksiyonlarının seçimi çok önemlidir. Bu, uzman bilgisinin sisteme girişine izin verir. Daha iyisi, gerçek sistem hakkındaki bilgi, üyelik fonksiyonları tarafından modellenerek daha iyi sınıflandırma sonuçlarına ulaşılır.



Şekil 3.1 Üyelik fonksiyonlarına örnek

Bir bulanıklık setinden daha fazlasını tanımlamak mümkündür, örneğin bir nesne özelliği için düşük, orta ve yüksek bulanıklık eşitlikleri tanımlamak gibi. Daha çok üyelik kesişiminde, bulanıklık eşitliğinden daha çok nesne elde edilecek ve sonuç sınıflandırmayı daha belirsiz hale getirecektir. Şekil 3.2 x özelliği için düşük, orta, yüksek olarak tanımlanmış üç bulanık eşitliği göstermektedir. Bu eşitlikler üst üste bindirilen üçgen üyelik fonksiyonlarıyla belirlenmişlerdir. Özellik değeri $x=70$ olan bir görüntü nesnesi için düşük sınıfına üyeliği 0.4, orta sınıfına üyeliği 0.2 ve yüksek sınıfına üyeliği 0.0' dır. Eğer özellik değeri $x=200$ olursa, sınıflara üyeliği sırasıyla 0.0, 0.0, 0.8 olur.



Şekil 3.2 Birbiri içine giren fonksiyonlarla bulanıklığın sağlanması

3.4.1.2 Bulanıklık Kural Tablosu

Bulanıklık kural tablosu, farklı bulanıklık setlerini birleştiren bulanıklık kurallarının kombinasyonundan oluşur. En basit bulanıklık kuralı, tek bir bulanıklık setine dayalı olmalıdır. Bulanıklık kuralları, “eğer-sonra” kurallarıdır. Eğer bir durum yerine gelirse, bir işlem yapılır. Şekil 3.2’ ye göre, şu kural tanımlanabilir: “eğer” x özelliği düşükse, “sonra” görüntü nesnesi arazi örtüsü W’ ye dahil edilmelidir. Bulanıklık deyimiyle şöyle yazılabilir: eğer x özelliği *düşük* bulanık setin bir üyesiye, sonrasında görüntü nesnesi, arazi örtüsü W’ nin bir üyesidir. Şekil 3.2’ deki tanımlamaya göre, özellik değeri $x=70$ olma durumunda, arazi örtüsü W’ ye üyelik 0.4 olur, $x=200$ olma durumunda, arazi örtüsü W’ ye üyelik 0 olur.

Gelişmiş bulanıklık kuralları oluşturmak için, bulanıklık setleri birleştirilebilir. Bir işleç birleştirilmiş bulanıklık setlerinden türetilmiş bir bulanıklık değeri sağlayabilir. Yani bu değer işlece bağlı olarak da türetilir. Temel işleçler “ve” ve “veya” dır. “ve” bütün setlerin tanımladığı dönüş değerinin, en küçük değer olması anlamına gelir, “veya” ise bütün ayarlamaların tanımladığı dönüş değerinin en büyük olması anlamına gelir. Sonuçlar

çok açık ve kural tanımlaması içindeki ardışık mantık kombinasyonlarının birbirinden bağımsız olduğunu garanti edici niteliktedir (A “ve” B, B “ve” A ile aynı sonucu verir). Ek olarak genel mantığı takip edecek bir yapı (örneğin A “veya” (B “ve” C), (A “veya” B) “ve” (A “veya” C) ye eşittir) kolayca oluşturulabilir.


Bir bulanık kural tablosu, düşünülen çıkış sınıflarının her biri için farklı dönüş değerlerinden ibaret olan bir bulanık sınıflandırma sağlar (Şekil 3.3). Bu değerler sınıf üyeliğinin derecesini gösterir.



Şekil 3.3 Özelliğin her bir sınıfa karşılık vermesi ancak bir sınıfa baskın çıkması

Olasılığa dayalı sınıflandırma, bir sınıfa ait olma olasılığını verirken, bulanık sınıflandırma bir nesnenin bir sınıfa ait olma ihtimalini verir. Olasılık belirli bir nesnenin bilgisini verirken, bir ihtimal istatistiklere bağlıdır ve birçok nesnenin bilgisini verir. Tüm muhtemel olayların ihtimali bir çatı altında toplansa da, bu olasılıklar için maalesef böyle değildir (Benz et al., 2003).

En olası sınıf için dönüş değerlerinin yükselmesi, üyelik için daha gerçekçidir. Yukarıda verilen örnekte, suya üyelik $\mu_{su}(\text{nesne})=0.8$ oldukça yüksektir ve çoğu uygulamada bu nesne bu yüzden su sınıfına dahil edilecektir. Bir nesnenin bir sınıfa dahil edilmesi için gereken en küçük üyelik değeri tanımlanabilir. Ayrıca, en yüksek ve ondan sonraki üyelik değeri de uygulamayı daha açık ve stabil kılar. Sınıflandırma stabilitesi ve güvenilirliği eCognition altında hesaplanıp gösterilebilir. Şekil 3.4 de ise sınıflandırmada sorun yaşanabilecek değerlere iki örnek verilmektedir. İlkinde yüksek değerler vardır ancak üç değer de birbirine çok yakın veya eşittir ki böyle bir durumda hangi sınıfa atama yapılacağı kestirilemez. Aynı şekilde ikinci şekilde de değerlerin oldukça küçük olma durumu vardır. Bu durumda da yine sınıf tayini yapılamaz.



Şekil 3.4 Birbirine yakın değerler nedeniyle sınıf tayininin yapılamaması

Bulanık sınıflandırmayla, sınıf karışımının, sınıf performansına, sınıflandırma güvenilirliğine ve stabilitesine ulaşmak mümkündür. Çünkü bulanık sınıflandırma, geçişli sınıflandırma yapan güçlü bir yaklaşımdır. Bulanık sınıflandırmanın sonuçları, çoklu veri kaynaklarıyla, güncel ve gelecekteki uzaktan algılama sistemlerinde bilgi entegrasyonu için önemli bir giriş sağlayacaktır. Her bir sensör için sınıf atamalarının güvenilirliği, en muhtemel ve en olası sınıf atamasını bulmak için kullanılabilir, farklı sensör verilerine bağlı tutarsız sınıf atamaları olmasına rağmen, bir çözüm almak mümkündür. Örneğin, eğer yoğun sis varsa optik sensörler, radar sensörlerinden daha az güvenilir olarak dikkate alınırlar.

3.4.1.3 Durulama

Sonuçları, standart arazi örtüsü haritaları ve arazi kullanım uygulamaları gibi işlemek için, bulanık sonuçlar ikilik sonuçlara geri dönüştürülmelidir, ki bu bir nesnenin, bir sınıfa üye olup olmaması anlamına gelir. Sınıflandırma adımında, genellikle en yüksek üyelik dereceli sınıf seçilir. Bu tip çıkış ürünlerinde, bulanık sınıflandırmanın zengin sonuçları kaybolur.

Durulama, bulanıklaştırma işleminin tersidir. Bu ikilik sınıflandırmayı verir. Eğer bir sınıfa üyelik derecesi belirli bir değer altındaysa, en düşük güvenilirliği sağlamak için, sınıflandırılmamış ifadesi atanır.

3.5 ECOGNITION ALTINDA NESNE TABANLI GÖRÜNTÜ ANALİZİ

eCognition sonuç olarak görüntü bilgisinin nesne tabanlı işlenmesi üzerine kuruludur. Bununla birlikte, segmentasyon ve sınıflandırma için yaklaşımı destekleyici, olanaklarını arttırıcı ve işlem optimizasyonunu sağlayan özgün yöntemler seçilmiştir. Farklı yöntemler

veri giriş çıkışı, vektörleştirme, çalışma, bilgi arayüzleri, doğruluk analizi ve istatistiğiyle bütünü tamamlar.

İlk segmentasyon, uygulamanın en önemli adımını oluşturmaktadır. İlk segmentasyon için orijinal görüntü bilgisinin, istenilen herhangi bir çözünürlükte ve ileriki sınıflandırma işlemlerine uyacak nesne blokları şeklinde çıkarılması gerekir. eCognition bu tip özellikleri karşılayamayan ve nitelik bakımından iyi segmentlerin oluşturulabilmesi için gerekli olan görüntü nesne primitifleri gibi yaklaşımları tam olarak desteklemeyen tüm bilinen segmentasyon yöntemlerini dışarıda bırakmıştır. Bu yüzden eCognition altında Definiens Imaging tarafından geliştirilen çoklu segmentasyon adı verilen bir segmentasyon yöntemi kullanılmaktadır.

İstenilen ölçekte, görüntü nesne primitiflerini üretme olasılığına bağlı olarak, eCognition birden fazla nesne düzeyi üretmeye ve bu düzeylerin hiyerarşik bir yapıda ilişkilendirilmesine izin verir. Görüntü nesnelерinin bu hiyerarşik yapısı içine entegre edilmiş olarak, her nesne onun bitişik nesnesini, alt ve üst nesnelерini tanır. Nesneleri düzeyde ilişkilendirerek, ölçüğe ve gelişmiş doku özelliklerine ulaşmak mümkündür. Nesne hiyerarşisi, farklı ölçeklerde, eş zamanlı görüntü bilgisi sunmaya izin verir.

Yazılım altında özel vektörleştirme algoritmaları uygulanabilir ve görüntü nesnelерine vektör bilgisi eklenebilir. Böyle yaparak, eCognition altındaki görüntü nesneleri eş zamanlı raster ve vektör sunumu haline gelir. Poligonlar, şekil özelliklerini hesaplamak için dış hat gösteriminde veya sonuçların vektör formatta dışarı verilmesinde kullanılabilir.

Bütün sınıflandırma süreci, bulanık mantık üzerine kuruludur. Bulanık mantık, karışık kural setlerine rağmen sezgisel ve şeffaf düzenlemeye ve işlemeye izin verir. Sınıflandırma bilgi tabanının iskeleti sınıf hiyerarşisidir, ki bu sınıflandırma planındaki tüm sınıfları içerir.

Her sınıf, bulanık kurallarla tanımlanabilir. Bu tek boyutlu fonksiyonlar üzerine veya çok boyutlu özellik uzayında bile çalışabilen, bir en yakın komşuluk sınıflandırıcısı üzerine de kurulu olabilir. İkisi de kontrollü sınıflandırma metotlarıdır. İlki doğrudan düzenlenebilir ve görüntü içeriği hakkındaki bilgileri formülize etmesine olanak tanır; ikincisi, istenilen sınıf özelliklerine belirlemek için uygun örneklerin seçimine ihtiyaç duyar. Örnekler

manuel olarak seçilebilir (tıklayarak) veya çalışılan alanların maskeleyişine göre seçilebilir. Farklı sınıflandırıcılar, bulanık mantık kullanılarak bir sınıf tanımlaması altında birleştirilebilir. Bu örneğin “ve” ve “veya” gibi işleçlerle sağlanır. Sınıflandırma sonuçları, semantik kontekst kullanarak farklılaştırılabilir ve geliştirilebilir. Örneğin nesnelere fiziksel ve topolojik özelliklerine göre sınıflandırıldıkları gibi, sınıflandırma semantik özellikler kullanılarak hatalarından arındırılabilir (çoğunlukla komşuluk ilişkilerini tanımlayarak veya alt nesnelere bir araya getirilmesiyle yapılır).

Sınıf hiyerarşisi, sınıfların semantik gruplamasını destekler. Bu farklı özelliklerdeki sınıfların, semantik anlamca üst bir genel sınıfa atanmasında kullanılabilir. Bu bağlamda, üst sınıf, kendi açık sınıf tanımlamalarına ihtiyaç duymaz. *Kentsel yeşil alan* ve *kentsel geçirimsiz*, örneğin *kentsel* sınıfı altında gruplandırılabilir. Bu durumun kendine özgü bir avantajı, üst sınıfla olan kontekst ilişkileri tarif etmektedir: *kentsel* sınıfı içinde olmak hem *kentsel geçirimsiz* hem de *kentsel yeşil* gösterir.

Ek olarak, sınıf hiyerarşisi, kalıtsal olarak sınıf tanımlamalarının, alt sınıflara geçmesini sağlar. Örneğin yeşil alan gibi bir sınıf, sınıf tanımlamalarını, kentsel yeşil veya kırsal yeşil gibi alt sınıflara kalıtsal olarak geçirerek değiştirilebilir. Bu bilgi tabanının şeklini oluşturur yani, bir sınıfın tanımlamasının detay seviyesi arttıkça, hiyerarşi kolları derinleşir.

Bu imkanlarla, sınıf hiyerarşisi şaşırtıcı semantik zenginlikte, iyi kurulmuş bir bilgi tabanının, etkin bir şekilde oluşturulmasını sağlar. Bulanık mantıkla birlikte bu nesne tabanlı görüntü analizi yaklaşımına çok fazla güç katar. Burada dikkat edilmesi gereken en önemli husus; sınıf hiyerarşisinin farklı bir şey olduğu ve görüntü nesnesi hiyerarşisinden bağımsızlığıdır.

Sonunda, nesnelere şekilleri, sınıflandırmayla ve bilgi tabanlı segmentasyonla geliştirilebilir. Genellikle bu yeni özellikli ve semantik ilişkili, sırasıyla, yeni üretilen özelliklerine göre sınıflandırılan yeni nesnelere yol açar (eCognition, 2005).

3.5.1 Görüntü Nesnelere Çoklu Segmentasyonu

Segmentasyon kendisi bir amaç değildir. Görüntü analizinin amacı, arazi örtüsü / arazi kullanım sınıflandırması veya ilgilenilen nesnelere çıkarımı olabilir. Bununla beraber,

İlgilenilen nesnelere, Şekil 3.5'deki çatılar gibi çoğu durumda oldukça fazla heterojen olabilirler. Genel homojenlik kriterine bağlı olarak yürütülen bir segmentasyon işlemi, çoğu durumda ilgilenilen sonuç alanları veya nesnelere direkt olarak çıkaramayacaktır. eCognition'da nesne tabanlı görüntü yaklaşımı için, bir görüntü segmentasyon işleminden çıkan nesnelere, bu yüzden görüntü nesne primitiflerinden daha iyi olacak şekilde tasarlanır, ki segmentler, ileri sınıflandırma ve diğer segmentasyon işlemleri için bilgi taşıyıcılar ve bina blokları gibi hizmet ederler. Bu düşünceyle, en iyi segmentasyon sonucu, ileri işlemler için optimum bilgi sağlayandır.



Şekil 3.5 Heterojen nesnelere örnek çatılar ve yeşil alan

İleri işlemlere optimum bilgi sağlamak amacıyla çoklu segmentasyon üretilmiştir. Çok geniş ölçüde, bilgiden bağımsız, istenilen ölçekte, homojen görüntü nesne primitiflerinin, özellikle lokal kontrastları göz önünde tutarak çıkarımına izin verir, çok geniş aralıktaki veri tiplerine uygulanabilir. İstenilen sayıdaki kanal üzerinde eş zamanlı çalışabilir ve özellikle dokusal veya düşük kontrastlı, örneğin radar veya VHR görüntüleri gibi verilere uyumludur.

Nesne tabanlı görüntü analizinde, optimum ham materyale ulaşmak için, aşağıda belirtilen sebepler, çoklu segmentasyonun eCognition için geliştirilmesinin ilk zamanlarında tanımlanmıştır:

- a. Bir segmentasyon aşaması, görüntü alanlarının optimum ayrımı ve sunumu için yüksek homojenlikte segmentler üretmelidir.

- b. Her görüntü analizi problemi, spesifik bir veriye bağlı, belirli bir uzaysal ölçekteki verilerle uğraşırken, görüntü nesnelерinin ortalama boyutları, ilgilenilen ölçęęe uygun olmalıdır.
- c. Görüntü nesnelерinin özellikleri (gri değeri, doku, yapı, ve bitişik alanlarla olan ilişkileri) az çok ölçek bağımlıdır. Ancak benzer ölçeklerdeki yapılar karşılaştırılabilir kalitededir ve karşılaştırılabilir özelliklere sahiptirler. Bu sebepten sonuç görüntü nesneleri az veya çok aynı değerde olmalıdırlar.
- d. Segmentasyon aşaması evrensel olmalı ve çok sayıda farklı görüntü ve probleme uygulanabilmelidir.
- e. Segmentasyon sonuçları çoğaltılabilmelidir.
- f. Yer gözlemleri, sıkça geniş veri grupları üretir. Bu yüzden segmentasyon işlemi olabildiğince hızlı olmalıdır.

Segmentasyon tekniklerinin değerlendirilmesi için güçlü ve tecrübeli bir kaynak, insan gözüdür. Segmentasyon işlemlerinin, görüntü analizinin otomatikleştirilmesine uygulanmasıyla, segmentasyon görsel sayısallaştırmanın yerini alır. Hiçbir segmentasyon sonucu (nicel olarak çok iyi hesaplanırsa bile) insan gözünü yeterince memnun etmediği sürece tam olarak anlamlı değildir. İstikrarlı lokal kontrastın ele alınması bu hedef için ön koşuldur. Örneğin görüntü bölgelerinin segmentasyonunun az çok benzer boyutlarda olması gerekir. Sonuç olarak, minimum sınır yumuşatmasıyla görüntü nesnelерinin üretilmesi için, spektral homojenliğin, karışık, dokulaşmış veri içindeki zorluğu açıkça ortadadır.

Bütün bunlara rağmen, ilk bakışta görünen, gerçekte aynı bölge için segmentasyondan beklenen sonuç, aynı faaliyet alanındaki farklı alt parçalarda görünse bile yeniden üretilebilirliktir. En genel segmentasyon işlemlerinin bu noktada zorlukları vardır. Optimizasyon ve bölümlenme global özellik uzayında yapılır. Bununla beraber global özellik uzayı, çalışılan alanın kısmi alt parçalarına bağlıdır. Farklı alt bölümlerin parçası olan görüntü kısımları, bu tip işlemlerin mantığından dolayı, farklı segmentlere ayrılırlar. Bu her zaman her bir alt parçanın kendine özgü özellik uzayına bağlıdır.

Kesin ölçüm ve segmentasyon sonuçlarının karşılaştırılabilirliği, bir segmentasyon tekniğinin değerlendirilmesi için ön koşuldur. Görüntü nesnelere ve görüntü nesnelere ortalamaya boyutları için, heterojenliğin tanımında verilen, olası kriterler:

- a. Görüntü nesnelere ortalamaya heterojenliği minimum olmalıdır.
- b. Görüntü nesnelere ağırlıklı ortalamaya heterojenliği minimum olmalıdır.

Çoklu segmentasyonun geliştirilmesi için, öncelik ikinci kriter verilmelidir. Bu kriter anlamı değiştirilmeden şu şekilde formüle edilebilir;

- a. Piksellerin ortalamaya heterojenliği minimum olmalıdır, hangi görüntü nesnesine aitse, onun heterojenliği her piksele atanır.

İkinci formül, bir görüntünün her parçasının, segmentasyon sonuçlarının heterojenliğinin değerlendirilmesine eşit katkıda bulunması gerektiğini vurgular.

Bu kavramsallaştırmada bir segmentasyon aşamasının sonucu, görüntü nesne primitiflerinin, verilen bir problemle ilgili olarak, gerçek dünyanın görüntü nesnelere ilk yaklaşım gibi ele alınmasını sağlar. Bununla birlikte bu yaklaşım, çok sayıda probleme uygulanabilen ve değişik tiplerdeki dokulu görüntü verisi üzerinde bile çalışabilen yüksek kaliteli evrensel bir çözüm olmalıdır.

3.5.2 Segmentasyonun Uygulanması

Çoklu segmentasyon aşağıdan-yukarıya, bir piksellik nesnelere başlayan, alan birleştirme tekniğidir. Çok sayıda alt adımda, küçük görüntü nesnelere, büyük olanlara birleştirilir. Bu çift mantıklı gruplandırma ile altta yatan optimizasyon işlemi, sonuç görüntü nesnelere ağırlıklı heterojenliği nh' ı minimuma indirir. Burada n segmentin boyutu ve h heterojenliğin kendine özgü tanımıdır. Her adımda, bitişik görüntü nesne çifti, tanımlanmış heterojenliğin en küçük artışına göre birleştirilir. En küçük büyüme değeri, ölçek parametresine göre belirlenen sınırı aşarsa, işlem durur. Böyle yaparak, çoklu segmentasyon, lokal optimizasyon adımı olur.


Küçük boyutlardaki bitişik görüntü nesnelere ve böylece karşılaştırılabilir kaliteye ulaşmak için, işlem, her adımda ve aynı zamanda sonuçta, bir çalışma alanındaki segmentlerin düzgün ve eş zamanlı büyümesini simule eder. Böylece işlem bir pikseli nesneyle görüntünün herhangi bir yerinden başlar. İkilik sayaç üzerine kurulu ardışık bir yaklaşım, ele alınan nesnelerin, düzgün uzaysal dağılımlarını garanti eder. Bununla birlikte, belirli sebeplerden dolayı, böyle bir ardışıklık tahmini, işlem geçmişine dayalı unsurlar içerir.

3.5.2.1 Heterojenlik Kriterinin Belirlenmesi

eCognitionda spektral veya renk heterojenliğinin tanımlanması için, her tabakanın ağırlığı w_c ile her tabakadaki spektral değerlerin ağırlıklı standart sapmasının çarpımının toplamı kullanılır;

$$h = \sum_c w_c \sigma_c \quad (3.1)$$

Birçok durumda, spektral heterojenliğin özel olarak minimize edilmesi, dallanmış segmentlere veya fraktal şekilli sınır çizgilerine sahip görüntü nesnelere yol açar (Şekil 3.6). Bu etki radar verisi gibi çok dokulu verilerde oldukça güçlüdür. Bu sebepten, çoğu durumda spektral heterojenlik kriterini, uzaysal heterojenlik kriteriyle karıştırmak, düzgün veya yumuşak bir şekilden sapmayı azaltmak için kullanışlıdır.



Şekil 3.6 Düşük heterojenlik sonucu geometrik anlamda bozuk şekillerin oluşması

Bütün bir şekilden sapma olarak heterojenlik, fiili uzunluk l' nin, bu nesneyi şekillendiren piksel sayısının kareköküne oranıyla tanımlanır.

$$h = \frac{l}{\sqrt{n_s}} \quad (3.2)$$

Şekil heterojenliğini tanımlamak için daha ileri bir imkan, fiili sınır uzunluğu l' nin, muhtemel en kısa (raster görüntüye paralel, görüntü nesnesini sınırlandıran kutuyla belirlenen) sınır uzunluğu b ye oranıdır.

$$h = \frac{l}{b} \quad (3.3)$$

Bu heterojenlik tanımının uygulanması, sonuç görüntü nesnelerinin şekillerinin yumuşaklığını optimize eder. Şekil 3.7 bu iki şekil kriterinin spektral kriterle karıştırılmasıyla elde edilen segmentasyon sonucunu göstermektedir. Görüntü nesnelere daha bütün bir yapıdadır ve çok daha yumuşak kenarlara sahiptir. Her ne kadar renkle ilgili olarak homojen olmayabilse de, insan gözüne oldukça tatmin edici gelmektedir.



Şekil 3.7 Optimiz edilmiş heterojenlikle daha düzgün şekilli yapıların oluşması

Heterojenlik için bu üç kriter karıştırılmış bir halde uygulanabilir. 3.2. ve 3.3. formülleri ek olarak genel bir şekil kriterine özetlenir. Özellikle radar gibi yoğun dokulu verilerde, şekil kriterinin düzgün seçilmesi, nesnelerin fraktal şekillenmesini iptal etmeye yardımcı eder. Bu

parametrelerin, iki bitişik segmentin uyumunu belirleyen birleştirme değerlerine nasıl dönüştürüleceği aşağıdaki gibi açıklanabilir.

Segmentasyon algoritmasının sonucunu belirlemek için, kullanıcı çeşitli parametreler tanımlayabilir. Örneğin ölçek parametresi, tekil tabakaların ağırlıkları ve şekil ile gri değerini dikkate alan heterojenlik kriterinin karşılaştırılması. Birleştirme değerinin ölçek parametresiyle karşılaştırılması, parçalanma kriterini tanımlar. Yukarıda bahsedildiği gibi, ölçek parametresi, iki nesnenin birleştirilmesiyle meydana gelebilen, heterojenlikteki maksimum değişim ölçüsüdür. Bu değer karesi alınır ve segmentasyon algoritmasını kesecek sınır değeri olarak kullanılır. Bir çift görüntü nesnesinin muhtemel bir birleştirilmesi gerçekleştirildiğinde, o iki nesne arasında bir birleştirme değeri hesaplanır ve ölçek parametresinin karesiyle karşılaştırılır.

Heterojenlik kriteri gri değeri ve şekil için olmak üzere iki parçadan ibarettir. Spektral kriter, heterojenlikteki değişimdir, iki görüntü nesnesi birleştirildiğinde meydana gelir, ağırlıkları dikkate alarak, spektral değerlerin ağırlıklı standart sapmasındaki değişimle tarif edilir. Şekil kriteri ideal şekilleri tanımlayan iki farklı modele bağlı olarak, şeklin gelişimini tanımlayan bir değerdir.

Sonuçta birleştirme değeri f , spektral heterojenlik h_{renk} ve şekil heterojenliği $h_{şekil}$ ' e bağlı olarak aşağıdaki gibi hesaplanır.

$$f = w.h_{renk} + (1 - w).h_{şekil} \quad (3.4)$$

Burada w , renk için (şekle karşılık) kullanıcı tanımlı ağırlıktır ve $0 \leq w \leq 1$ olarak ifade edilir.

Standart sapmaların kendileri nesne şekillerine göre ağırlıklandırılır.

$$h_{renk} = \sum_c w_c . (n_{brlş} . \sigma^{brlş} - (n_{nesne1} . \sigma^{nesne1} + n_{nesne2} . \sigma^{nesne2})) \quad (3.5)$$

Şekil kriteri yumuşaklık ve bütünlük olmak üzere yine iki alt kriterden ibarettir. Bu kriterlerin hesaplanması kullanıcı tanımlı ağırlıklara bağlı olarak, aşağıdaki gibidir:

$$h_{\text{şekil}} = w_{\text{btm}} \cdot h_{\text{btm}} + (1 - w_{\text{btm}}) \cdot h_{\text{ymş}} \quad (3.6)$$

Bütünlük kriteri için kullanıcı tanımlı ağırlıklı olarak hesaplanır.

Yine birleşmeden dolayı şekil heterojenliğinde meydana gelen değişim, birleştirmeden önceki ve sonraki durumlar arasındaki farkın hesaplanmasıyla değerlendirilir. Bu aşağıdaki yumuşatma ve bütünlüğün hesaplanma metotlarıyla verilir:

$$h_{\text{ymş}} = n_{\text{brlş}} \cdot \frac{l_{\text{brlş}}}{b_{\text{brlş}}} - (n_{\text{nesne1}} \cdot \frac{l_{\text{nesne1}}}{b_{\text{nesne1}}} + n_{\text{nesne2}} \cdot \frac{l_{\text{nesne2}}}{b_{\text{nesne2}}}) \quad (3.7)$$

$$h_{\text{btm}} = n_{\text{brlş}} \cdot \frac{l_{\text{brlş}}}{\sqrt{n_{\text{brlş}}}} - (n_{\text{nesne1}} \cdot \frac{l_{\text{nesne1}}}{\sqrt{n_{\text{nesne1}}}} + n_{\text{nesne2}} \cdot \frac{l_{\text{nesne2}}}{\sqrt{n_{\text{nesne2}}}}) \quad (3.8)$$

Burada n ile nesne büyüklüğü, l ile nesnenin çevre uzunluğu, b ile sınırlayan kutunun çevre uzunluğu ifade edilmektedir.

Segmentasyon aşaması boyunca, tüm görüntü segmentlere ayrılır ve görüntü nesnelere, renk ve şekildeki ayarlanabilir homojenlik veya heterojenlik kriterlerine dayalı olarak üretilirler. Bu şekilde ifade edilen ölçek parametresini ayarlamak, ortalama nesne boyutunu dolaylı yoldan etkiler; daha yüksek bir değer, daha büyük nesnelere yol açarken, daha düşük bir değer, daha küçük nesnelere oluşmasını sağlar.

3.5.3 Alt Nesnelere Çizgi Analizi Amaçlı Segmentasyonu

eCognition, görüntü nesnelere nesne tabanlı çizgisel analizi için değişik özellikler sunar. Bu amaç için, “normal” segmentasyon modu, çoklu segmentasyon işlemini kullanarak alt nesne çıkarmanın özel bir halidir. Bütünlüğü maksimuma çıkartmak için kriterin özel bir şekilde kullanılmasıyla çalışır. Burada ölçek parametresi 0.5 ile 1 arasında, alt nesnelere, aynı üst objenin parçası olmayan komşu piksellere olan en çok ilişkili sınır uzunluğunu belirler.


Şekil 3.8 deki gibi görüntü nesnelерinin analizi için, özel görüntü nesne düzeyi alt segmentlere ayrılabilir. Sonuçlar bütünlük arz eden alt nesnelerdir ki bu nesnelер dış çevreyle olması gereken minimum ve maksimum sınır uzunluklarını garanti ederler. İşlemlerin bu alt objelerin orta noktasından, bir diğerinin orta noktasına yapılması, eğrisel bir çizginin uzunluğunu, ortalama kalınlığını, eğriliğini vb. kolayca analiz etmeyi mümkün kılması anlamına gelir.



Şekil 3.8 Alt segmentlere ayrılmış nesne örneği

3.5.4 Görüntü Nesnelерinin Hiyerarşik Ağ Yapısı

eCognitionda farklı uzaysal çözünürlükteki görüntü bilgilerinin eş zamanlı sunumunu sağlayan, görüntü nesnelерinin hiyerarşik ağ yapısını kurarken farklı segmentasyon teknikleri kullanılabilir. Görüntü nesneleri birbiriyle bağlanmıştır, böylece, her görüntü nesnesi kendi kontekstini (komşuluk), üst nesnesini, alt nesnesini “tanır” (Şekil 3.9). Böylece nesnelер arasındaki ilişkiyi tanımlamak mümkün olabilir. Örneğin “Orman a sınır komşuluğu” ve bu çeşit lokal kontekst bilgisini kullanmak gibi.



Şekil 3.9 Hiyerarşik ağ yapısı

Bu hiyerarşik ağ topolojik olarak sınırlıdır, örneğin bir üst nesnenin sınırı, alt nesnelерinin sınırlarıyla uyumludur. Belirli bir görüntü nesnesiyle gösterilen bir alan, alt nesnelерin

alanları toplamıyla tanımlanır. Teknik olarak, eCognitionda kullanılan segmentasyon tekniklerinin hepsi birleştirme algoritmaları olarak seçildiğinde, tüm bu bağıllık basit olarak işleme etki eder. Her seviye alt nesnelere bağlı olarak kurulur. Örnek olarak alt nesnelere bir sonraki seviyede daha geniş görüntü nesnelere birleştirilirler. Birleştirme ara bir seviyede yapılıyorsa, üst nesnelere sınırlarına kadar yapılabilir ve eğer bitişik görüntü nesnelere farklı üst nesnelere ait alt nesnelere ise birleştirilemezler. eCognitionda, görüntü nesnelere uzaysal olarak istikrarlı şekilde tanımlanırlar.

Görüntü nesnelere hiyerarşik ağ yapısı, aşağıda açıklanan daha yeni teknikler için imkan sağlar:

- a. Farklı ölçeklerdeki yapılar eş zamanlı sunulabilir ve böylece birbirleriyle olan ilişkilerine göre sınıflandırılabilirler.
- b. Farklı hiyerarşik seviyeler, farklı verilere dayalı olarak segmentlere ayrılabilir; bir üst seviye örneğin tematik arazi kayıt bilgilerine göre kurulabilirken, alt seviye uzaktan algılama verisi kullanılarak segmentlere ayrılabilir. Bir üst seviyeyi sınıflandırarak, her bir arazi kayıt nesnesi, sınıflandırılmış alt nesnelere bir araya gelmesi ile analiz edilebilir. Bu teknik mantığıyla, değişik veri tipleri birbirleriyle olan ilişkileriyle analiz edilebilirler.
- c. Görüntü nesnelere şekilleri alt nesnelere yeniden gruplandırılmasına bağlı olarak düzeltilebilir.

Böyle bir durumda segmentlere ayrılan seviyelerin ardışıklığı önemli bir rol oynar. Hangi seviyenin önce yapıldığı bile fark yaratır. Örneğin, önce kadastral seviyeyi kurup sonra alt nesnelere oluşturmak anlam ifade eder. Yine, aynı üst nesnenin alt nesnelere olmayan, bitişik nesnelere birleştirilemez.

Güçlü bir teknik, alt nesnelere dayalı görüntü analizi tekniğidir. Aşağıda sıralanan analizler bu noktada kullanılabilir, basit ama uygulamayı şekillendirecek özellikleri göstermektedir.

- a. Alt nesnelere dayalı doku analizi, bir görüntü nesnesinin tüm alt nesnelere sınıflandırma nitelikleri.
- b. Alt nesnelere dayalı çizgi analizi.
- c. Sınıfa dayalı özellikler: sınıflandırılmış alt nesnelere olan ilişkiler.

Görüntü nesnelere başka bir hiyerarşik ağ yapısı uygulaması, görüntü nesnelere, ayrı ayrı üst nesnelere göre sınıflandırmaktır.

eCognition tarafından sağlanan tüm segmentasyon işlemleri, bu hiyerarşik ağ yapısı içinde keyfi seçilmiş bir seviyede gerçekleştirilir. Piksellerin seviyesi ve tüm görüntünün seviyesi tanımlamayla varken, her bir yeni seviyenin segmentasyonu, bir alt ve bir üst seviyeler arasında bir iç yapılaşmadır. Tüm nesnelere uzaysal şekilleri üzerindeki belirli hiyerarşiyi garanti altına almak için, segmentasyon işlemi iki kural izler:

- a. Nesne sınırları, bir sonraki alt seviyenin nesne sınırlarını takip etmelidir.
- b. Segmentasyon, bir sonraki üst seviyedeki nesnelere sınırlarıyla kısıtlıdır.

3.5.5 Ecognitionda Vektör Bilgisi


eCognition görüntü nesnelere eş zamanlı raster/vektör sunumuna izin verir. Segmentasyondan sonra, vektörleştirme fonksiyonel olarak, her bir görüntü nesnesi için poligonların üretilmesine izin verir. Bu vektör bilgisi farklı çözünürlüklerde ve farklı amaçlar için üretilebilir.

Her bir bağımsız yakınlaştırmada, görüntü nesnelere dış çizgilerinin yeniden çizilmesi için, eCognition raster pikselleri boyunca (Şekil 3.10, a) veya hafifçe kısaltılmış poligonlar (Şekil 3.10, b) üretir. İkinci poligonlar takip eden yapıda, ana poligonlar olarak ele alınır. Bunlar görüntü nesnesinin topolojik yapısına bağlı oluşturulur ve aynı zamanda dışarıya vektör çıkışı sağlamak için kullanılır. Daha çok çıkartılmış vektör bilgisi topolojik yapıya bağlı olmadan görüntü nesnelere şekillerini sunar ve şekil özelliklerinin hesaplanması için kullanılır (Şekil 3.10, c). Bu poligonlar şekil poligonu olarak ifade edilir.



Şekil 3.10 eCognition altında poligonların oluşturulması

Ana poligonların hesaplanması Douglas Peucker algoritması mantığıyla yapılır. Douglas Peucker algoritması poligon çıkarımı için en yaygın kullanılan metotlardan birisidir. Bu yaklaşım yukarıdan-aşağıya bir yaklaşımdır, verilen bir poligon çizgisinden başlar ve onu iteratif olarak küçük parçalara böler. Verilen bir poligon çizgisinin iki uç noktasına göre (eCognitionda bu iki başlangıç noktası topolojik noktalardır, Şekil 3.10,c' de sarı işaretli gösterilmiştir) algoritma, iki uç noktayı birleştiren doğru üzerinde düşeyde poligona olan en uzun mesafedeki noktayı bulur (Şekil 3.11,a). Bulunan bu noktada poligon iki kısa doğruyla gösterilir (Şekil 3.11,b). Bu işlem hesaplanan dik mesafe, verilen bir sınır değerinden küçük oluncaya kadar devam ettirilir (Şekil 3.11,c). Diğer bir tabirle sınır değer, poligonun altta yatan rasterdan olan en büyük sapmayı tanımlar. eCognitionda bu sınır değer "Poligon Oluştur" iletişim kutusunda piksel birimi cinsinden tanımlanabilir.



Şekil 3.11 Douglas Peucker algoritmasının poligonlara uygulanması

Aynı iskelet yapısını benzer olarak eCognition altında iskelet yapısı da oluşturulur. Bu iskelet yapısının ana gövdesi ve nesnenin çıkıntılarına doğru ilerleyen dal yapısı daha sonra sınıflandırma aşamasında seçilecek fonksiyonlar için bir kriter oluşturabilmektedir.

3.5.6 Ecognition Altında Bulanık Sınıflandırma

Bulanık sınıflandırma, belirli bir sınıfa olan üyelik değerini işaret etmek için, temel olarak rasgele seçilmiş özellik değerleri aralığını, 0 ve 1 arasında bulanık değerlere dönüştüren basit bir tekniktir. eCognitionda görüntü nesnelerinin analizi için, bulanık sınıflandırma aşağıda ifade edilen sebeplerden dolayı seçilmiştir;


- a. Özellik değerlerini bulanık değerlere dönüştürerek, çok farklı aralıklarda ve boyutlarda olsa bile, özellikler standartlaştırılmış olur ve bu özelliklerin kombinasyonuna izin verir,
- b. Şeffaf ve uyumlu özellik tanımlamaları sağlar (özellikle sinir ağlarının karşılaştırmasında),
- c. Mantık operasyonlarıyla ve hiyerarşik ağ tanımlamalarıyla, karışık özellik tanımlamalarının formülize edilmesini sağlar,

eCognitionda sınıflandırma tablosundaki formülize edilen her sınıf, bir sınıf tanımlaması içerir. Her sınıf tanımlaması, spesifik özelliklerin ve onların mantık işlemlerinin değerlendirilmesine izin veren, bir bulanık eşitlik setinden ibarettir. Sistemin çıkışı iki katlıdır: ilki sınıf karışımının ve sınıf atamalarının güvenilirliğinin detaylı bilgisini veren bir bulanık sınıflandırma ve ikincisi her nesnenin tam olarak bir sınıfa atandığı (veya hiçbir sınıfa atanmadığı, hiç bir atamanın mümkün olmadığı) kesin bir sonuç sınıflandırma.

Bir bulanıklık kuralı tek bir durum içerebilir veya bir nesnenin bir sınıfa tam olarak atanması için birçok durumun kombinasyonundan meydana gelebilir. eCognitionda durumlar sınıf tanımlamalarının içine yerleştirilen eşitliklerle tanımlanır. Eşitlikler üyelik fonksiyonları, sınıflara benzerlik veya en yakın komşuluk olabilir.

Bu şekilde nesnelerin eCognition altında sınıflara üyeliğinin sağlanması için, belirlenen sınıflara ait örnekler seçilebilir veya direkt olarak sınıf üyelik fonksiyonları sınıf tanımlamaları altında belirtilebilir. Örneklerin seçilmesi durumunda da yine, en yakın komşuluk gibi örneklemeyle bağlı sınıflandırıcılar sınıf tanımlaması altında belirtilmelidir. Sınıf tanımlamaları altında belirtilen özellikler için kullanılan eşitlikler değişik

fonksiyonlarla ifade edilebilir. Bu noktada seçilen fonksiyon nesnenin o özelliği için karşılık gelecek üyelik değerini belirlemede direk rol oynar. Örneğin sinüs eğrisine benzer yapıda bir eğri kullanmak daha yumuşak geçişli sonuçlar verirken dikdörtgensel fonksiyonlar kullanmak daha sert, geçişe izin vermeyen sonuçlar verir. Şekil 3.12 de eCognition programı altında bu fonksiyonların nasıl gösterildiği verilmektedir.



Şekil 3.12 eCognition altında kullanılan fonksiyon çeşitleri

Bundan sonra yapılması gereken sınıf atamalarının yapılabilmesi için, o sınıf içine dahil edilmesi gereken nesnelere için uygun öznitelikleri belirlemektir. Bu öznitelikler Şekil 3.13’ de ifade edilen fonksiyonlarla birlikte uygun sınıf içinde tanımlanır. Fonksiyonların sınıf değerleri bu sınıfa dahil edilecek nesnelere başka sınıflara ait nesnelere karşımasını engellemek açısından çok önemlidir. Ayrıca düşük seçilebilecek fonksiyon sınır değerleri de o özelliği tam yansıtamayan ama gerçekten o sınıfta olması gereken nesnelere sınıfa dahil edilmemesiyle sonuçlanabilir. eCognition altında tanımlanmış bu öznitelik bilgileri aşağıdaki ana başlıklar altında toparlanabilir.

Nesne Özellikleri:

Tabaka değerleri: Bu özellik bir görüntünün bantlarından alınan piksel değerleri üzerine çalışır.

Şekil: Bu özellikle görüntü nesnesinin kendisinin veya alt nesnelere ait olması gereken şekilleri tanımlanabilir. (Örneğin bina sınıfı için dikdörtgensellik koşulu gibi)

Doku: Doku özelliği bir görüntü nesnesinin dokusunu ya alt nesnelere ya da Haralick’ ten sonraki nesne piksellerinin gri değeri birlikte oluşum matrisine (GLCM), gri değeri fark vektörüne (GLDV) bağlı olarak değerlendirir.

Hiyerarşi: Bu özellikler, tüm görüntü nesnesi içine yerleşmesiyle ilgili bilgiler sağlar.

Tematik Nitelikler: Bunlar tematik tabaka nesnelерinin nitelikleridirler. Bu özellik ancak projeye bu şekilde bir tematik tabaka yerleştirilmişse mümkündür.

Sınıf Bağımlı Özellikler:

Komşu Nesne Bağımlı İlişkiler: Bu özellikler görüntü nesnesi hiyerarşisinde aynı seviyedeki görüntü nesnelерinin sınıf atamalarını işaret eder.

Alt Nesne Bağımlı İlişkiler: Bu özellikler görüntü nesnesi hiyerarşisinde bir alt seviyedeki görüntü nesnelерinin sınıf atamalarını işaret eder.

Üst Nesne Bağımlı İlişkiler: Bu özellikler görüntü nesnesi hiyerarşisinde bir üst seviyedeki görüntü nesnelерinin sınıf atamalarını işaret eder.

Bir Sınıfa Üyelik: Bazı durumlarda bir çok sınıfa üyelik değerlerini, bir sınıfa üyelik değerleri altında toplamak gerekebilir. Bu işlev farklı sınıflara olan üyelik değerlerinin açık bir şekilde adreslenmesine olanak tanır.

Sınıflandırılmışlık: Bu özellikteki ana fikir, bir sınıfa üyelik değerine bağlı olmaksızın sınıflandırmayı dikkate almaktır.

Sınıflandırma Değeri: Bazı durumlarda birçok sınıfa olan üyelik değerinin bir sınıf altında toplanması önem arz edebilir. Bu özellik üyelik değerlerini açıkça başka sınıflara yönlendirmemize izin verir. “Bir sınıfa üyelik” özelliğine karşın, sadece üç en yüksek değeri kullanmak yerine, sınırsız bütün sınıflara olan üyelik değerlerini kullanmak mümkündür.

Global Özellikler:

Global Çalışma Alanı Bağımlı: Tüm görüntü alanı üzerine kurulu bazı istatistiksel değerlendirmelerden oluşur.

Global Sınıf Bağımlı: Tüm bir sınıf veya grup için yapılan bazı istatistiksel değerlendirmelerden oluşur.

Terimler:

Standart En Yakın Komşuluk

En Yakın Komşuluk

Sınıflara Benzerlik

Mantık Tanımlamaları

Bu şekilde uygun öznitelik ve uygun fonksiyon şeklinin seçilmesiyle sonuç sınıflandırmaya ulaşılmaya çalışılır. Bunun yanında bu özelliklerden bazıları yukarıda da bahsedildiği gibi sınıf özellikleridir ve bunların hesabın işine katılabilmesi için sınıf bağımlı seçeneğinin etkin hale getirilmesi gerekir. Sınıf bağımlı işlem birkaç kere tekrarlanabilir, bu tamamen kullanıcıya bağlıdır. Ancak unutulmamalıdır ki işlemlerin artması demek, sınıflandırma sürecinin de uzayacağı anlamına gelir.

BÖLÜM 4

QUICKBIRD UYDUSU VE ÜRÜNLERİ

4.1 QUICKBIRD UYDUSU

QuickBird uydusu mevcut ticari uydular arasında en geniş tarama alanına, en geniş veri kapasitesine ve en yüksek çözünürlüğe sahip bir uydudur. QuickBird geniş alanları yüksek konumlama hassasiyetiyle, verimli bir şekilde görüntüler. Uydu, 75 milyon km² lik bir alanı (ki bu alan Kuzey Amerika' nın 3 katından fazla) görüntüleyebilecek yapıdadır. Çizelge 4.1'de QuickBird uydusuna ait teknik ayrıntılar verilmektedir.

Çizelge 4.1 QuickBird Uydusu Teknik Özellikleri

Fırlatma Yeri ve Zamanı	Vandenberg Hava Kuv. Üssü, Kaliforniya, 2001
Araç	Boeing DELTA II
Yörünge Yüksekliği	450 Km
Yörünge Eğimi	97°.2 Güneş Uyumlu
Hız	7.1 km/sn
Ekvator Geçişi	10:30 am (Alçalan Düğüm Noktası)
Yörünge Zamanı	93.5 dk.
Tekrar Geçiş Süresi	1-3.5 gün enleme bağlı olarak (30° nadirden farkla)
Tarama Genişliği	16.5 km (nadir)
Metrik Doğruluk	23 metre yatay
Çözünürlük	0.61m. Pan (nadir) 2.44m. Çok bantlı (nadir) 0.72m. Pan - 25° (off-nadir) 2.88m. Çok bantlı - 25° (off-nadir)
Spektral Bant Genişliği	450'den 900 nanometre'ye kadar Pan: 450 - 900 nm Mavi: 450 - 520 nm Yeşil: 520 - 600 nm Kırmızı: 630 - 690 nm Yakın Kızılötesi: 760 - 900 nm
Dijital Kayıt Formatı	Her piksel için 11bit

4.2 QUICKBIRD ÜRÜNLERİ

QuickBird uydusuna ait görüntüler ilgili firma tarafından kullanıcılara birkaç farklı düzeyde sunulmaktadır. Görüntü düzeyleri ve bunlara ait bazı teknik bilgiler Çizelge 4.2’de gösterilmiş olup bu ürünlere ait açıklamalar aşağıdaki alt bölümlerde ele alınmaktadır.

Çizelge 4.2 QuickBird Uydusu Görüntüleri

Ürün Düzeyi	İşlem	Mutlak Doğruluk		Konumsal Mümkünlük
		CE90%	RMSE	
Temel Görüntü (Basic Imagery)	Sensör Düzeltmeli (RAW)	23 metre	14 metre	Dünya Çapında
Standart Görüntü (Standart Imagery)	Geometrik Düzeltilmiş	23 metre	14 metre	Dünya Çapında
Orto 1:50000	Orto Düzeltmeli	25.4 metre	15.4 metre	Dünya Çapında
Orto 1:12000	Orto Düzeltmeli	10.2 metre	6.2 metre	US ve Kanada
Orto 1:5000	Orto Düzeltmeli	4.23 metre	2.6 metre	Dünya Çapında
Orto 1:4800	Orto Düzeltmeli	4.1 metre	2.5 metre	US ve Kanada
Özel Orto	Orto Düzeltmeli	Değişebilir	değişebilir	Dünya Çapında

4.2.1 Temel Görüntü Ürünü

Bu görüntüler, QuickBird ürünleri arasında en az işlenmiş ve gelişmiş görüntü işleme imkanları olan kullanıcılar için tasarlanmış görüntülerdir. Temel görüntü, sağlanan durum, efemeris ve kamera modeli bilgileriyle, ortorektifikasyon gibi gelişmiş fotogrametrik işlemler için uygundur.

İşlem: Temel görüntü ürünleri radyometrik açıdan düzeltilmiştir ve sensör düzeltmesi yapılmıştır, ancak ne geometrik düzeltmesi yapılmış ne de bir kartografik projeksiyona veya elipsoide indirgenmiştir. Görüntü çözünürlüğü nadir açısına bağlı olarak, pankromatik görüntüler için 61 cm ile 72 cm arasında, çok bantlı görüntüler için de 2.44 m ile 2.88 m arasında değişmektedir. Görüntü ideal temel görüntü kamera modeline göre tanımlanan bir koordinat sistemine yeniden örneklenir. Sonuç GSD (Ground Sampling Distance – Yer Örnekleme Aralığı), görüntü işlemi sırasındaki durum ve efemerisin bir fonksiyonu olarak çeşitlilik gösterir. Temel görüntü ürününün pan-sharp yapılmış versiyonu bulunmamaktadır.

Temel görüntü ürününe uygulanan radyometrik düzeltmeler aşağıdaki gibidir:

- a. Dedektörler arasındaki bağıl radyometrik karşılığa göre: Pikseller arasındaki hassasiyet varyasyonlarından oluşan farklılıkları ortadan kaldırır.
- b. Karşılık vermeyen dedektör dolumu: Veri toplamayan dedektörlerden dolayı, görüntü üzerindeki boş değerleri doldurur.
- c. Mutlak radyometriye dönüştürme: Bilinen radyometrik sinyallere karşılık bütün dedektör cevaplarını kalibre eder.

Sensör düzeltmeleri de şu şekilde verilebilir:

- a. İç dedektör geometrisi: Entegre edilmiş 6 dijital çipi sanal bir diziye birleştirir.
- b. Optik distorsiyon: Sensör optiklerinden ileri gelen görüntü distorsiyonlarını düzeltir.
- c. Çizgi oranı çeşitliliği: Pankromatik tarama oranındaki çeşitliliği düzeltir.
- d. Çok bantlı alımın kaydı: Tüm renkli bantlar birbirini takip eder, ancak pankromatik ve renkli bantlar birbirine uygun gelmez.

Temel görüntü alımında her bir çalışma alanı ayrı ayrı işlenir, bu yüzden, çoklu çalışma alanlı temel görüntü ürünleri ne uzaysal olarak ne de spektral olarak mozaiklendirilmez. Temel görüntü ürünleri 16.5km x 16.5km büyüklüğünde bir alan kaplar.

Temel görüntü ürünü uydu referans sistemindedir, yer konumlamasına bağlı değildir ve bu yüzden doğruluğu olmayan, geometrik olarak işlenmemiş diye bahsedilir. Bununla birlikte, veri sağlanacak bir görüntü destek verisi (ISD- Image Support Data) ile ve kullanıcı tarafından sağlanacak bir SYM(Sayısal Yükseklik Modeli) ile coğrafi konumlama doğruluğu CE%90 da 23m olur. Bu verilerden daha iyi konumsal doğruluk elde etmek için kullanılacak farklı modeller mevcuttur. İleriki bölümlerde bu görüntü için uygulanabilecek bu gibi modellerden söz edilecektir.

4.2.2 Standart Görüntü Ürünü

Standart görüntü ürünü, tutarlı mutlak doğruluk ve/veya geniş alanda çalışılmayı gerektiren kullanımlar için uygundur. Standart görüntü ürünü kullanıcıları genellikle yeterince görüntü işleme aracına ve çeşitli uygulamalar için görüntüyü beceri ve başarıyla işleme bilgisine sahip uzmanlardır.

İşlem: Standart görüntü ürünleri radyometrik olarak düzeltilmiştir, sensör düzeltmesi yapılmıştır, geometrik olarak düzeltilmiştir ve bir kartografik projeksiyona indirgenmiştir. Standart görüntü ürünleri siyah-beyaz, renkli, pan-sharp yapılmış olarak 60-70cm GSD ile veya çok bantlı olarak 2.4-2.8m GSD ile edinilebilir. Standart görüntü ürünleri tüm görüntüde baştan sona değişmeyen piksel aralığına sahiptir.

Standart görüntü ürüne uygulanan radyometrik düzeltmeler şunlardır:

- a. Dedektörler arasındaki bağıl radyometrik karşılık,
- b. Karşılık vermeyen dedektör dolumu,
- c. Mutlak radyometriye dönüşüm.

İç dedektör geometrisi için kullanılan sensör düzeltmeleri;

- a. Optik distorsiyon,
- b. Tarama distorsiyonu,
- c. Çizgi oranı çeşitliliği,
- d. Pankromatik ve çok bantlı kaydın yapılmasıdır.

Geometrik düzeltmeler uydu yörünge konumunu ve belirsiz durumlarını, dünya hareketlerini ve eğriliğini ve panoramik distorsiyonu ortadan kaldırır.

Standart görüntü iki çeşit olabilir:

Standart Görüntü: Standart görüntü, topoğrafik rölyef ile referans elipsoide indirgemek için kullanılan SYM'ne sahiptir. Bu indirgemenin derecesi bağıl olarak küçüktür. Böylece bu ürünün yersel düzeltmeleri olması yanında,

ortorektifikasyonu yapılmış sayılmaz. Doğruluk açısından bakıldığında, standart görüntü ürünleri herhangi bir yer değiştirme veya nadir dışı görüntü açısı haricinde CE90%' da 23m ortalama mutlak konumlama doğruluğuna sahiptir. Yer konumlaması düzenlenmiş uydu durumundan ve efemeris bilgisinden YKN'ler (Yer Kontrol Noktası) gerekmeden hesaplanır.

Orto Hazır Standart Görüntü: Orto hazır standart görüntü, ortorektifikasyona uygunluğunu sağlamak için herhangi bir topoğrafik düzeltmeye sahip değildir. Orto hazır standart görüntü çalışma alanının ortalama yüksekliği olarak hesaplanan bir yüksekliğe projekte edilir. Doğruluk açısından bakıldığında, orto hazır standart görüntü ürünleri herhangi bir yer değiştirme veya nadir dışı görüntü açısı haricinde CE90%' da 23m mutlak konumlama doğruluğuna sahiptir. Görüntüyle birlikte sağlanan RPC'ler yüksek kaliteli bir SYM ve metre altı doğruluklu YKN'ler kullanıldığında, doğruluklar çok daha iyi RMSE değerlerine ulaşabilir. Yersel düzeltmenin dışında, orto hazır standart görüntü ürünüyle, standart görüntü ürünü aynı özelliklere sahiptir.

Temel, standart ve orto hazır standart görüntülerin karşılaştırılması söz konusu olduğunda aşağıdaki ifadeler açıklıkla kullanılabilir;

Temel Görüntü: Temel görüntü, QuickBird Rigorous Sensör Modeli veya RPC'leri kullanarak ortorektifikasyona izin verir. Sonuçlar QuickBird Rigorous Sensör Modeli ile biraz daha iyidir. Ortorektifikasyon her bir çalışma alanına bağlı olarak yapılmalıdır.

Standart Görüntü: Standart görüntü, arazi düzeltmesi yapılmamış, yer koordinatlı görüntü gerektiren uygulamalar için çok kullanışlıdır.

Orto Hazır Standart Görüntü: Orto hazır standart görüntü, basit olarak RPC'leri kullanarak bölgeye bağlı ortorektifikasyon için tasarlanmış, yer koordinatlandırılmış bir üründür. Ulaşılabilir doğruluklar temel görüntü ve RPC'ler kullanılarak ulaşılanlarla karşılaştırılabilir. Eğer ortorektifikasyon amaç değilse, standart görüntü tercih edilmelidir. Orto hazır standart görüntü, görüntüsü veya görüntüleri alınan alanın ortalama yüksekliğine projekte edilir. Böylece çalışılan

bölgeye bir yaklaşım gösterir. Bununla birlikte eğer kullanıcı arazi düzeltmelerini uygulamazsa, özellikle yüksek alanlarda yer yer birkaç yüz metreye kadar farklar olabilir.

4.2.3 Orto Görüntü Ürünü

Orto görüntü ürünleri CBS'ye hazır ürünlerdir ve çok geniş amaçlı uygulamalar için görüntü tabanlı harita gibi kullanılabilirler. Orto görüntü ürünleri harita ve CBS veritabanlarının oluşturulması ve güncellenmesi veya mevcut katmanların kaydı için uygun bir altlıktır. Bu ürünler aynı zamanda değişim analizi veya diğer yüksek düzeyde mutlak doğruluk gerektiren analitik uygulamalarda kullanılabilirler.

İşlem: Orto görüntü ürünleri, radyometrik olarak düzeltilmiş, sensör düzeltmeleri yapılmış, geometrik olarak düzeltilmiş, ortorektifiye edilmiş ve kartografik bir projeksiyona ve datuma indirgenmiştir. Orto görüntü ürünleri 60-70 cm GSD ile, siyah-beyaz, renkli veya pan-sharp olarak alınabilir veya 2.4-2.8m GSD ile çok bantlı olarak sağlanabilir.

Orto görüntü ürününe uygulanan radyometrik düzeltmeler şu şekilde sıralanabilir;

- a. Dedektörler arasındaki bağıl radyometrik karşılık,
- b. Karşılık vermeyen dedektör dolumu,
- c. Mutlak radyometriye dönüşüm.

İç dedektör geometrisi için kullanılan sensör düzeltmeleri;

- a. Optik distorsiyon,
- b. Tarama distorsiyonu,
- c. Çizgi oranı çeşitliliği,
- d. Çok bantlı kaydın yapılmasıdır.

Bu görüntüde de geometrik düzeltmeler uydu yörünge konumunu ve belirsiz durumlarını, dünya hareketlerini ve eğriliğini ve panoramik distorsiyonu ortadan kaldırır.

Bir řeritten fazlasını gerektiren alıřmalarda, kullanıcılar rnlerini uzaysal olarak mozaiklendirilmiş ve/veya renk dengelemesi yapılmıř olarak isteme opsiyonuna sahiptirler. Renk dengelemesi, ereveler arasındaki radyometrik farkları minimum yapmayı saęlarken, grnty mozaikleme, řeritlerin sınır uyumlu olmalarını saęlar.

Orto grnt rnleri rlyef yer deęiřtirmeyi gidermek ve her pikseli doęru harita konumuna yerleřtirmek iin SYM ve/veya YKN gerektirir. Bir orto grnt rn isteęinin kabulnden nce, retici firma, istenilen rnn yapılması iin uygun destek verisinin ierilip ierilemeyeceęini kararlařtırır. SYM'nin ve/veya YKN'lerin doęruluęu, her bir grnty, istenilen orto grnt rnnn leęine baęlı olarak retmek iin kullanılır. Belirtilen doęrulukta orto grnt rnleri (1:50000, 1:12000, 1:5000, 1:4800) iin, rn hazırlamada gerekli olacak destek verisini saęlama sorumluluęu retici firmaya aittir. Firma ayrıca kullanıcılara, zel orto grnt rn isteme imkanı da sunar. Bu rnleri oluřturmak iin, QuickBird grntlerini ortorektifiye etmede, kullanıcı tarafından saęlanan destek verisi kullanılır.

zel grnt rnleriyle iliřkilendirilmiş sabit doęruluk yoktur, nk sonu rnn kalitesi ve doęruluęu, doęrudan destek verisinin kalitesine ve doęruluęuna baęlıdır. SYM'leri ve YKN'ler kullanıcıların grnty reten firmaya saęladıęı en tipik destek veri eřitleri olarak gsterilebilir. Mevcut orto veriler veya yksek doęruluklu CBS verisi gibi alternatif kontrol formları da aynı řekilde kabul edilebilir.

Doęruluk aısından bakıldıęında orto rnler, harita leęine baęlı olarak deęiřen mutlak konumlama doęruluklarına sahiptirler. Yer konumu, sonu harita leęine baęlı olarak, yer kontrol noktalarıyla birlikte dzenlenmiř uydu durumundan ve efemeris bilgisinden hesaplanır.

BÖLÜM 5

UYGULAMA

5.1 GENEL

Bu bölümde tez kapsamında ele alınan, yüksek çözünürlüklü uydu görüntüsü üzerinden kentsel ayrıntıların hangi yöntemle ne kadar çıkarılabildiğine ilişkin kullanılan yazılımlar ve işlem adımları detaylı bir şekilde anlatılmaya çalışılmaktadır.

5.2 TEST ALANI

Zonguldak Test Alanı; Türkiye'nin Kuzeybatısında yer alan, Kuzeyinde Karadeniz ve Güneyinde ormanlık alanlar arasında dar bir sahil şeridinde kurulmuş bir endüstri şehridir. Bölge; madencilik, demir-çelik ve orman endüstri merkezidir. Ancak, yıllar boyu maden sektörünün de getirdiği kısıtlamalar ile kentsel alan açısından ve konut sayısı açısından fazlaca genişleyememiştir. Alan oldukça engebeli, değişken bir topoğrafyaya sahiptir. Şehir bir tarafında denizle iç içeyken diğer tarafında yer yer 800 metre yüksekliğe varan sık ormanlarla kaplı dağlarla çevrilidir. Uygulamada kullanılan QuickBird Standart Orto Hazır görüntüsü Zonguldak Merkez ve yakın çevresini içine almaktadır (Şekil 5.1).



Şekil 5.1 Zonguldak Test Alanı

5.3 KULLANILAN VERİLER VE YAZILIMLAR

Uygulama çalışmalarında QuickBird Standart Orto Hazır görüntüsü kullanılmıştır. Bu görüntünün geometrik düzeltilmesi ve radyometrik geliştirilmesi için PCI Geomatica yazılımı kullanılmış, görüntü daha sonra değişik CAD yazılımlarında ve nesne-tabanlı yaklaşım kullanan eCognition yazılımında değerlendirilerek sonuç ürünler karşılaştırılmıştır. Kullanılan görüntünün ve yapılan uygulamanın detayları aşağıda başlıklar halinde verilmektedir.

5.3.1 Uydu Görüntüsü

Çalışmada kullanılan QuickBird Standart OrthoReady görüntüsünün teknik özellikleri çizelge 5.1’de verilmiştir.


Çizelge 5.1 QuickBird Standart OrthoReady görüntüsü teknik özellikleri

Çekim Tarihi	23/05/2004
Görüntü boyutu (piksel: satır - sütun)	24.572 x 25.500 pan 6143 x 6375 ms
Gün, Zaman	08:39:55 GMT
Düzeyi	Referans Yüksekliğine Projekte (Quickbird Standart Ortho Ready)
Referans yüksekliği (m)	265.66
Elipsoid	WGS84
Yer Örnekleme Aralığı	0.60m Pan - 2.4m Ms
Firma	DigitalGlobe
Kaplanan Alan	14.7x15.3 km ²
Format	GeoTIF
Görüntüleme Aralığı	11bit (görüntüleme sırasında) 16bit (pazarlanırken)
Nominal azimut (derece)	61.0
Nominal yükseklik açısı (derece)	85.9
Güneş azimutu (derece)	139.1
Güneş yükseklik açısı (derece)	64.7
Nadir açısı (derece)	3.9

5.3.2 Yer Kontrol Noktaları

Görüntü, ilk alındığı zaman, düzenli bir şekilde yayılmış uygun YKN seçimi için analiz edilmiştir. Bu belirleme sonucunda, 33 farklı YKN GPS ölçmeleri ile yaklaşık 3 cm

doğrulukla ölçülmüştür. Bu noktaların görüntü üzerinde çok iyi görülebilir olmasından dolayı, noktalar, bina köşeleri, kavşaklar vb. olarak seçilmiştir. QuickBird görüntüsünün yüksek çözünürlüğünden dolayı, birçok kültürel özellikler tanınmış ve YKN olarak kullanılmıştır. YKN'nın görüntü koordinatlarının ölçülmesi, PCI Geomatica-Orto Engine yazılımının YKN Ölçme Arayüzü (GCP Collection Tool) ile gerçekleştirilmiştir. Görüntü üzerine dağılmış olan noktaların görünümü Şekil 5.2'de verilmektedir.



Şekil 5.2 Test Alanı üzerinde yer kontrol noktalarının dağılımı

5.3.3 Kullanılan Yazılımlar

Çalışmanın amacı düşünüldüğünde kullanılan yazılımlar da haritalardaki değişik düzeyleri oluşturan katmanlar gibi birbirinden ayrılabilir. İşlemlerde öncelikle görüntünün geometrik

ve radyometrik açıdan hazır hale getirilmesi, ardından içeriğin çıkarılması aşamaları yer alır. Bu noktada görüntü sırasıyla aşağıda anlatılan işlem adımlarından geçer:

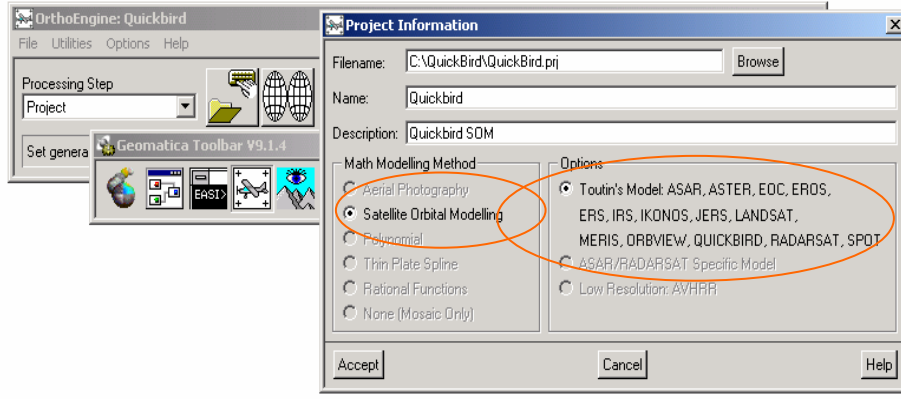
- a. PCI Geomatica OrthoEngine V 9.1.4 ticari yazılımında yeni bir proje içinde tanımlanmış, bu yazılım içinde lisanslandırılmış olan SOM yöntemiyle geometrik açıdan doğruluğu incelenmiştir. Ardından aynı program içinde birkaç farklı SYM denenerek görüntü orto görüntü haline getirilmiştir. Burada birkaç farklı SYM'nin kullanılma nedeni rölyef etkisinin minimum olmasını sağlamaktır.
- b. İkinci aşamada yine aynı programın, Dr. Yun Zhang tarafından geliştirilmiş algoritması olan Pan-Sharpning modülü kullanılmıştır. Bu şekilde yüksek çözünürlüklü renkli uydu görüntüsü üzerinden daha ayrıntılı detay çıkarımı mümkün hale getirilmiştir.
- c. Son aşama görüntü üzerinden elle ve nesne-tabanlı yaklaşımla detayların çıkartılarak karşılıklı analizlerin yapılmasıdır. Ekran üzerinden elle çıkarım için farklı CAD yazılımları denenmiştir. Her yazılımın kendisine göre uygulama kolaylıkları mevcuttur. Ancak hangisinin kullanıldığı önem arz etmemektedir. Sonuçta elde edilen vektörler yapı itibarıyla birbirinin aynısıdır. Bunun dışında otomatik yaklaşımda, eCognition yazılımı kullanılmıştır. QuickBird görüntüsünün geometrik ve radyometrik yapısına uygun program parametreleri belirlenmiş ve son olarak çıkarılan detaylar vektör formatında CAD yazılımları üzerinde üst üste veya yan yana konularak değerlendirilmeleri yapılmıştır.

5.3 YAZILIM ORTAMINDA DEĞERLENDİRME

Yukarıda adı geçen yazılımlar altında yapılan işlemler bu bölümde ayrıntılı biçimde ele alınacaktır. Her bir işlem yazılım adından ziyade, uygulanan düzeltme ve dönüşüme göre isimlendirilecektir.

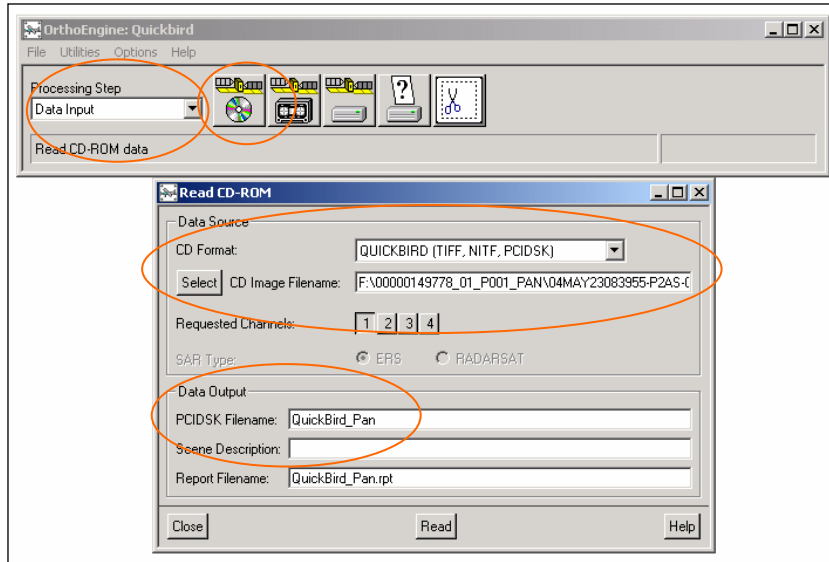
5.3.1 Geometrik Düzeltme

PCI Geomatica OrthoEngine V 9.1.4 yazılımı altında yeni proje tanımlanmış ve projede SOM seçeneği altında görüntüye uyan kısım seçilmiştir (Şekil 5.3).



Şekil 5.3 PCI Geomatica OrthoEngine V 9.1.4 yazılımı altında proje tanımlanması

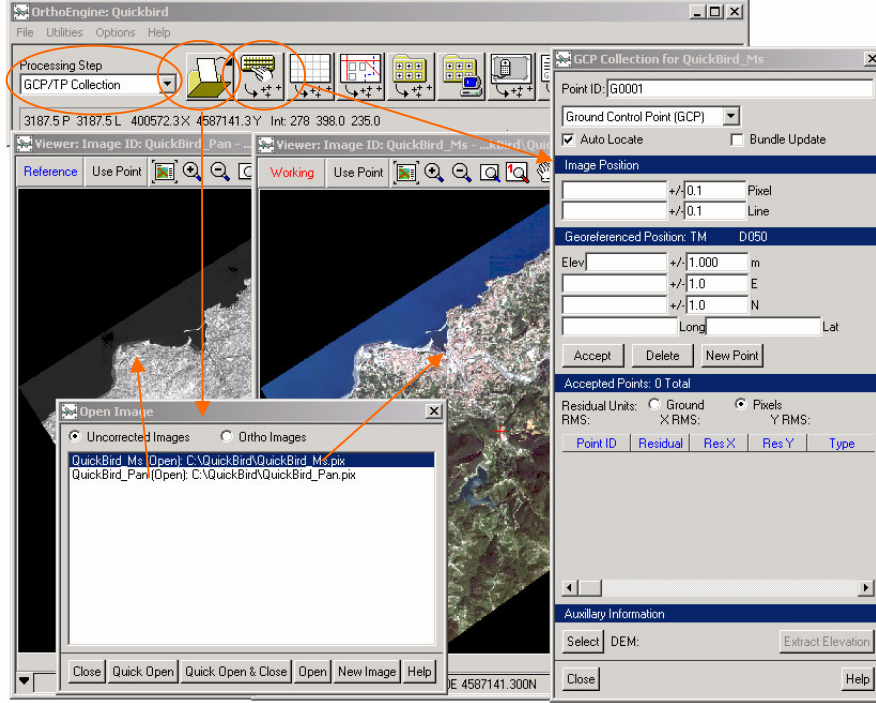
Proje tanımlamasıyla birlikte programa o proje için gerekli olan projeksiyon ve datum bilgileri de girilir. Bu proje için Transverse Mercator projeksiyonu ve ED50 datumu tanımlanmıştır. Bundan sonraki işlem cd veya dvd ortamında gelen görüntüleri bilgisayar ortamına aktarmaktır. Bu amaçla programın “Data Input” menüsü altından “Read CD-Rom Data” işlemiyle taşınabilir media ortamındaki GeoTiff görüntü dosyası uygun isim verilerek sabit disk altında pix görüntü formatıyla kaydedilir. Şekil 5.4’te görüntünün aktarım anı gösterilmektedir.



Şekil 5.4 PCI Geomatica OrthoEngine V 9.1.4 yazılımı altında görüntünün okutulması

Böylece sabit diske aktarılan görüntüler eğer raw görüntü değilse, başlık bilgisinde verilen koordinat tanımlamalarıyla pix dosyası olarak kaydedilir. Pix dosyaları hem görüntünün radyometrik bilgilerini hem de konum bilgilerini içermektedir. Bundan sonra yapılacak

işlem yer kontrol noktalarını seçmek ve görüntünün geometrik doğruluğunu sağlamaktır. Şekil 5.5'te görüntünün Yer Kontrol Noktası Toplama Arayüzü (GCP Collection Tool) altında açılması ve yer kontrol noktasının tanımlandığı ekran gösterilmektedir.



Şekil 5.5 Yer Kontrol Noktası Toplama Arayüzü ile noktaların girilmesi

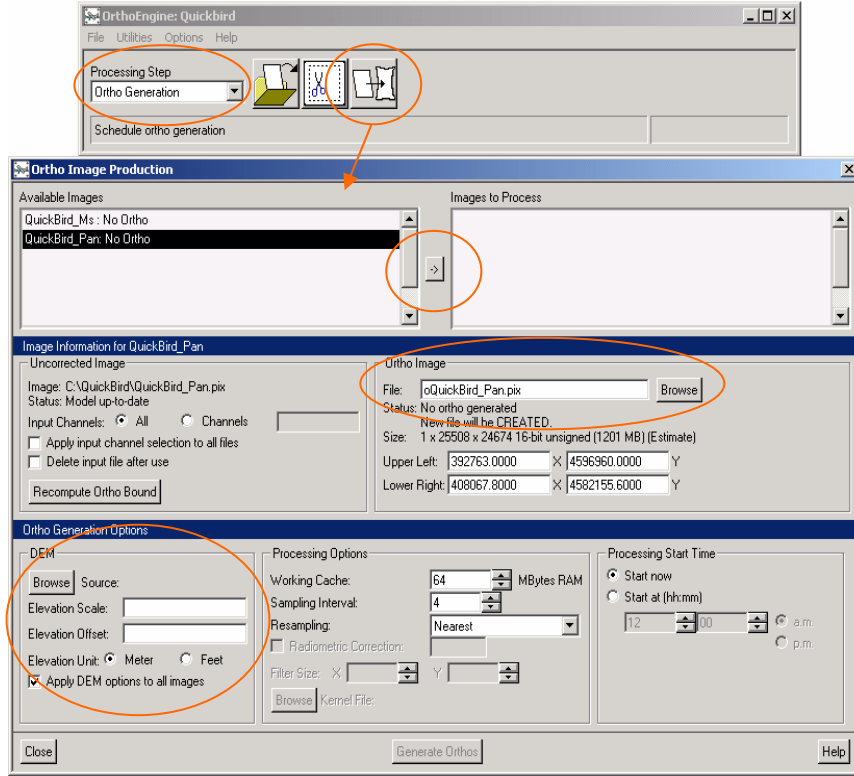
Uygulamada 33 farklı YKN kullanılmış, hem pan hem de ms görüntü için piksel altı doğruluk elde edilmiştir. Şekil 5.6'da pan görüntü için elde edilen yaklaşık yarım piksellik doğruluk değeri görülmektedir.

Accepted Points: 33 Total				
Residual Units: <input type="radio"/> Ground <input checked="" type="radio"/> Pixels				
RMS: 0.59 X RMS: 0.43 Y RMS: 0.40				
Point ID	Residual	Res X	Res Y	Type
13	0.16	-0.07	0.15	GCP
21	0.49	-0.48	-0.07	GCP
33	0.90	0.65	-0.62	GCP
42	0.33	0.30	0.14	GCP
51	0.27	-0.11	-0.25	GCP
61	0.63	0.42	0.46	GCP
62	0.51	0.36	-0.35	GCP


Şekil 5.6 Girilen YKN' bağlı olarak elde edilen doğruluk değeri

Bundan sonra yapılan işlem, görüntülerin orto hale getirilmesidir. Bunun için çalışmada birkaç farklı SYM kullanılmıştır. Kullanılan SYM'leri 25000, 5000 ölçekli ülke

haritalarından ve Zonguldak'ta 1927 yılında taş baskı olarak hazırlanmış olan 1/2000 ölçekli haritalardan sayısallaştırılmış olan eş yükseklik eğrilerinden üretilmiş SYM'lerdir. 1927 yılına ait haritalardan üretilen SYM kullanılarak oluşturulan orto görüntü halihazır haritayla en iyi örtüşmeyi sağladığı için bu SYM tercih edilmiştir. Şekil 5.7'de orto görüntülerinin yazılım altında hazırlanma aşaması, Şekil 5.8'de ise orto için kullanılan 1927 yılına ait SYM görülmektedir.



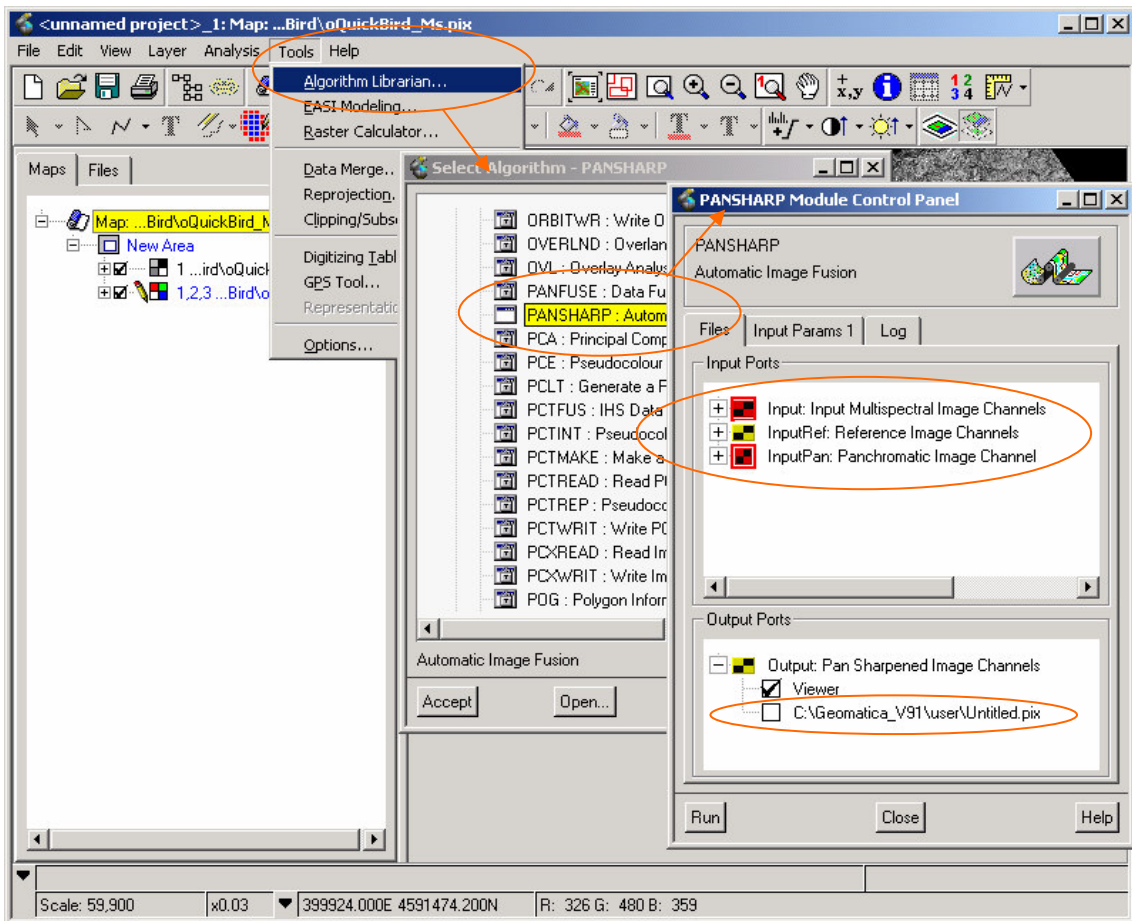
Şekil 5.7 Yazılım altında orto görüntünün üretim anı



Şekil 5.8 Orto için kullanılan 1927 yılına ait SYM

5.3.2 Radyometrik Geliştirme

Yukarıdaki işlemler sonucunda görüntüler her hangi bir harita altlık ihtiyacını karşılayabilecek düzeye gelmiştir. Ancak yapılan çalışmanın daha iyi sonuçlar vermesi için daha önceki bölümlerde de belirtildiği gibi pan-sharp algoritması kullanılmıştır. PCI Geomatica V 9.1.4 yazılımı altındaki algoritma oldukça basitleştirilmiş bir algoritmadır. Algoritmaya yazılımın “Focus” arayüzünde “Tools” sekmesinde yer alan “Algorithm Librarian” ya da Xpace arayüzü altından ulaşılabilir. Algoritma Focus altından çalıştırılmışsa öncelikle Focus altında görüntüler açılarak; Xpace altından çalıştırılmışsa, algoritma altında direkt olarak renkli ve pankromatik bantlar belirtilerek işlem başlatılacaktır. Böylece herhangi bir ek parametreye ihtiyaç duymadan görüntü pan-sharp hale getirilmiş olur. Focus altında algoritma ekranı Şekil 5.9’da gösterilmiştir.



Şekil 5.9 Yazılım altında pan-sharp algoritmasının çalıştırılması

Görüntünün bu aşamada tüm düzeltmeleri yapılmış haldedir. Bundan sonra yapılacak olan işlemler, ya görüntünün sınıflandırılması ya da başka teknikler kullanılarak görüntü

üzerinden algılanabilecek detayların çıkarılmasıdır. Bu noktada dikkat edilmesi gereken husus, görüntünün oldukça büyük bir alanı kaplaması ve içeriğin çözünürlükle birlikte yansıtılabilmesinden dolayı çok fazla ayrıntının görüntü içerisinden çıkarılabilesidir. Bu noktada görüntünün içeriğinden çıkarılabilecek tüm sınıfları içerecek bir bölge çalışma için kesilmiş ve uygulama bu kısımda sürdürülmüştür. Şekil 5.10’da seçilen bu bölge gösterilmektedir. Bu bölgenin en büyük karakteristiği, Zonguldak’taki yapılaşmanın en fazla olduğu bölge olması ve sol kısmında Zonguldak Karaelmas Üniversitesi Merkez Kampüsü’nü içermesidir.



Şekil 5.10 Çalışmaya esas olan uygulama bölgesi

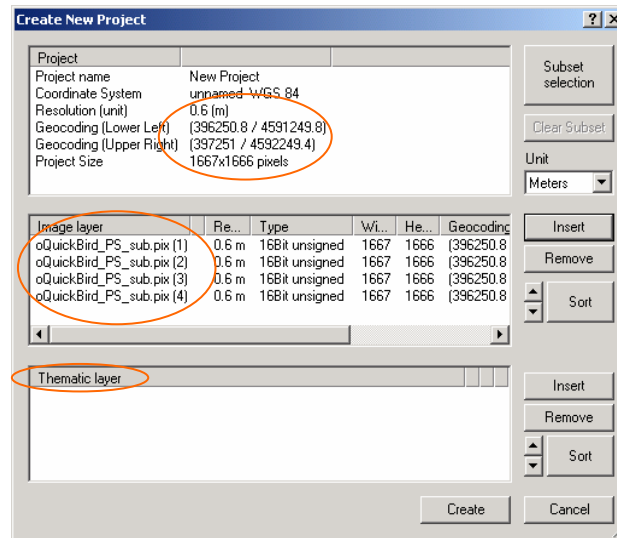
Bu şekilde görüntü NetCAD, AutoCAD gibi yazılımlar üzerinde açılmış ve elle ekran üzerinden sayısallaştırma uygulaması ile tüm detaylar vektör hale getirilmiştir. Burada her bir detay grubu için farklı katmanlar oluşturulmuştur. Sonuç vektör ürünlerin birbirinden farkı olmadığı için hangi programda vektörleştirildiği bu noktada önemini yitirmektedir. Şekil 5.11’ de bu görüntü üzerinden vektörleştirilmiş olan detaylar, görüntü üzerine bindirilerek verilmiştir.



Şekil 5.11 Görüntü üzerinden elle sayısallaştırılmış detaylar

Bundan sonra yapılan işlem eCognition yazılımı altında nesne-tabanlı yaklaşımı sağlamaktır. Bu yazılımın kullanılma nedeni veya yazılımdan ziyade nesne-tabanlı yaklaşımın kullanım nedeni, otomatikleştirmeyi sağlamaktır. Bu yazılım için ve kullanılan bu görüntü için parametreleri belirlemek, aynı programda, aynı özelliklere sahip yeni bir görüntünün yalnızca programın yürütüm süresi kadar bir zamanda vektör haritaya dönüşümü anlamına gelir.

Bu bağlamda eCognition programı altında yeni bir proje tanımlanmıştır. Açılan projenin koordinat bilgileri, o projeye dahil edilen görüntülerin koordinat bilgilerini kapsamaktadır. Proje tanımlanması sırasında görüntünün sınıflandırılmasında şekil bazında yardım edebilecek tematik altlıklar da eklenebilir. Bu altlıklar vektör veya raster formatta olabilir. Şekil 5.12’de eCognition yazılımında proje tanımlanma penceresi gösterilmektedir.




Şekil 5.12 eCognition altında projenin tanımlanması ve görüntünün açılması

eCognition altında iki farklı veri seti kullanılmıştır. İlkinde yalnızca görüntünün kendisi, ikincisinde ise görüntüyle birlikte, segmentlerin şekillerine yardımcı olacak vektör harita kullanılmıştır.

Bundan sonraki aşama sınıflandırmaya esas olacak görüntü segmentlerini oluşturmaktır. Bunun için “Image Objects” sekmesi altından “Multiresolution Segmentation” düğmesi tıklanmış ve açılan pencerede gerekli segmentasyon parametreleri girilmiştir. Çizelge 5.2’de uygun segmentasyon yapısının oluşturulması için yazılıma girilmiş olan parametre değerleri verilmiştir. Kullanılan değerler hem vektörlü hem de vektörsüz uygulama için aynıdır. Şekil 5.13’de Çizelge 5.2’de verilen değerlerden D sütununa karşılık gelen segmentasyon sonucu üzerindeki birkaç ayırım belirtilmektedir.

Çizelge 5.2 Uygulamada kullanılan segmentasyon parametreleri

Katman	A	B	C	D	E	F
Ölçek par.	10	20	30	35	60	30
Renk	0.5	0.7	0.3	0.5	0.5	Spectral Difference
Biçim	0.5	0.3	0.7	0.5	0.5	
Yumuşaklık	0.5	0.5	0.5	0.5	0.5	
Bütünlük	0.5	0.5	0.5	0.5	0.5	
Seg. modu	Normal	Normal	Normal	Normal	Normal	



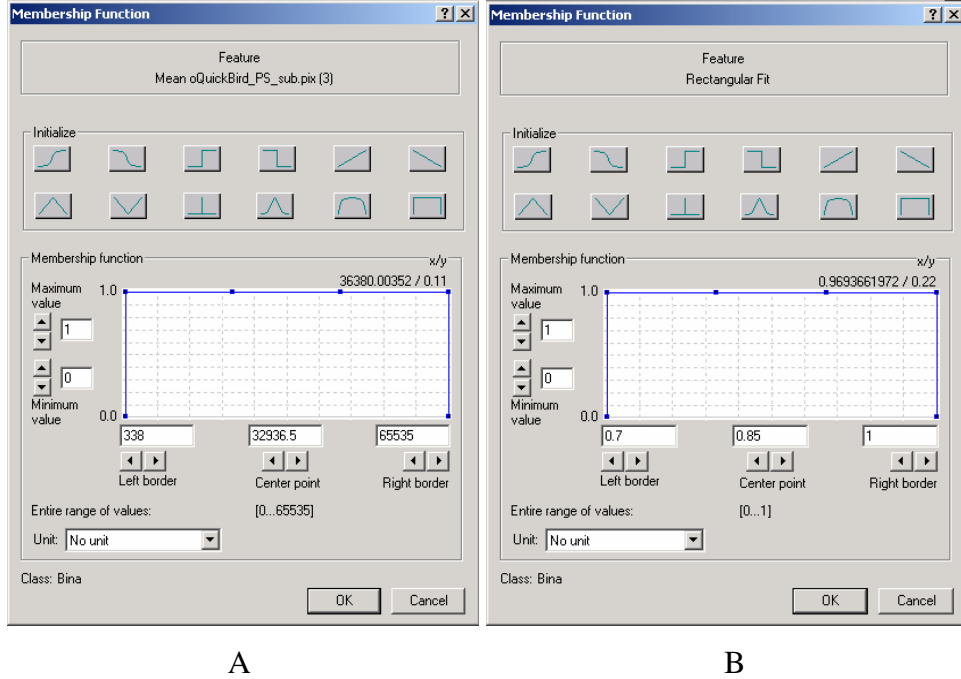
A

B

Şekil 5.13 Aynı parametrelerle oluşturulmuş vektörlü ve vektörsüz segmentasyon (A=Vektör Yapılı, B=Vektör yapısız)

Uygulamanın geri kalanında düzgün yapıdaki segmentasyonundan dolayı vektörlü veri seti kullanılmıştır. Bu aşamadan sonra yapılması gereken sınıfların oluşturulması ve bu sınıflara dahil edilecek segmentler için uygun üyelik özelliklerinin, bunlar için hazırlanacak fonksiyonların ve fonksiyonlara girilecek sınır değerlerinin belirlenmesidir. Bu noktada uygulama alanı için 4 ayrı sınıf oluşturulmuştur. Bunlar; Bina, Yol, Yeşil Alan ve Deniz sınıflarıdır.

Bu sınıflar için birçok üyelik özelliği tanımlanmış ve bunların fonksiyon aralıkları yazılıma girilmiştir. Şekil 5.14'te örnek olarak Bina sınıfı için girilmiş iki özellik ve fonksiyon tanımlaması gösterilmektedir.



Şekil 5.14 Sınıf atamaları için kullanılan özellikler ve bunlara ait fonksiyonlar (A=Üçüncü banda ait yansıma değerlerini kullanan dikdörtgenel fonksiyon, B=Dikdörtgenel şekil uyusumunu kullanan dikdörtgenel fonksiyon)

Şekil 5.14'ten de görülebileceği gibi biri üçüncü banda (kırmızı bant) duyarlılığı 338 ve üzeri olan segmentleri, diğeri dikdörtgenselliği 0.7 ile 1 arasında olan segmentleri ifade etmektedir. Ayrıca görüldüğü gibi ikisi içinde dikdörtgenel bir fonksiyon kullanılmıştır. Bunun anlamı bu şartı sağlayan nesnelerin %100 bu sınıfa dahil olacağı anlamına gelir. Bunun dışında diğer nesnelerle komşuluk ilişkileri ve daha birçok kriter kullanılmıştır. Ayrıca Çizelge 5.2, E sütununa karşılık gelen segmentasyon katmanıyla deniz gibi büyük yapılar tek bir segment yapısında elle sınıflandırılmış ve diğer alt katmanlara hiyerarşik olarak yansıtılmıştır. Bu anlamda "sınıf bağımlı" seçeneği seçilerek yapılan sınıflandırma sonucu Şekil 5.15'de gösterilmektedir. Bunun anlamı daha büyük ölçek parametresiyle oluşturulan katmanlardan veya o sınıf içinde daha öncesinde veya o sınıflandırma anında ilk aşamada sınıflandırmaya cevap vermiş olan nesnelerle ilgili durum analizlerinin, sınıflandırma işlemi içine katılmasıdır.



Şekil 5.15 Nesne-tabanlı sınıflandırma sonucu

Bu yapının üzerine vektör harita oturtulmuş hali Şekil 5.16’da gösterilmektedir.



Şekil 5.16 Nesne-tabanlı sınıflandırma sonucu ile vektör haritanın çakıştırılmış hali (Sarı çizgiler vektör haritada bulunan binaları, mavi çizgiler de yolları ifade etmektedir)

Şekil 5.17’de ise görüntü üzerine elle sayısallaştırılmış vektör yapı oturtulmuş hali gösterilmektedir. Şekilden de anlaşılacağı gibi koyu çatılı birkaç yapı dışında bütün bina detayları nesne-tabanlı yaklaşımda da çıkarılabilmektedir. Ağaçlık alanlardaki bazı binalar elle sayısallaştırmada da görülememiştir. Nesne-tabanlı yaklaşımla mevcut hali hazır harita karşılaştırıldığında çalışma bölgesindeki binaların %85’i çıkartılabilmektedir.



Şekil 5.17 Elle vektörleştirme ve nesne-tabanlı yaklaşım sonucunun üst üste gösterimi

BÖLÜM 6

SONUÇ VE ÖNERİLER

Yapılan bu çalışmada kullanılan QuickBird Standart OrthoReady görüntüsü üzerinden Zonguldak kentsel alanındaki ayrıntıların elle sayısallaştırma ve nesne-tabanlı yaklaşımla ne kadar çıkarılabildiği test edilmeye çalışılmıştır.

Bu amaçla kullanılan görüntü öncelikle bilgisayar ortamına alınmış ve geometrik olarak düzeltilmesi yapılmıştır. Bunun için ortalama 3cm doğrulukla ölçülmüş 33 GPS noktası kullanılmış ve bu noktalar yazılım ortamında Dr. Toutin tarafından geliştirilen SOM algoritması yardımıyla görüntüyle ilişkilendirilmiştir. Geometrik açıdan son olarak, 1927 yılında üretilen taş baskı haritalardan elde edilen SYM ile ortorektifikasyonu yapılmıştır.

Bu noktadan sonra elde edilen görüntülerin, veri çıkarımına en uygun hale getirilebilmesi için radyometrik zenginleştirilmesi yapılmıştır. Bunun için Dr. Zhang tarafından geliştirilmiş olan UNB pan-sharp algoritması kullanılmıştır. Bu algoritma sonunda elde edilen 60cm yer örnekleme aralıklı renkli görüntü, 1/1000 ölçekli haritanın içeriğini yansıtabilen ayrıntılar çıkarmıştır. Ancak konumsal doğruluğu düşünüldüğünde bugün QuickBird görüntülerinden elde edilecek görüntüler 1/1000 ölçekli bir haritanın içeriğini karşılayamamaktadır. Bu noktada söylenebilecek şey; 1/5000-1/6000 ölçeğinde bir haritanın bu görüntülerle üretilebileceğidir.

Bu uygulama kapsamında karşılaşılan sorunlar aşağıdaki maddeler halinde sıralanabilir.

- a. Geometrik doğruluk aşamasında yer kontrol noktalarıyla herhangi bir problem yaşanmamış ancak kullanılan SYM'inin hassasiyeti istenilen orto ürün hassasiyetini karşılayamamıştır. Bu şekilde oluşan görüntü mevcut halihazır haritayla karşılaştırıldığında yer yer 5-6 metrelere varan hatalar göstermiştir.

- b. Radyometrik açıdan incelendiğinde hareketli nesnelere ve diğer problemlerden dolayı görüntü üzerinde anlamsız pikseller oluşmaktadır. Bu problemler ileriki değerlendirme aşamalarını etkileyebilmektedir.
- c. Görüntü geometrik ve radyometrik açıdan düzeltildiğinde yeni bir problem ortaya çıkmaktadır. Bu da görüntünün inceleneceği programların hepsinde 16bit desteğinin olmamasıdır.
- d. Elle sayısallaştırmada kişisel deneyimlerin işlem içine katılmasına karşın, nesne-tabanlı yaklaşımda tamamen bağımsız bir çıkarım yapılmaktadır. Bu da elle sayısallaştırmayı biraz daha üstün kılmaktadır. Örneğin binalardan kaynaklanan küçük gölgeler yolun üzerine düştüğünde, kişisel deneyimlerle yol devam ettirilebilirken nesne tabanlı yaklaşımda alt detaylar ortaya çıkmaktadır.
- e. Nesne-tabanlı yaklaşımda tematik harita kullanılması çıkarımı kolaylaştırmasına karşın, SYM'nden kaynaklanan problemler üst üste örtüşümü bozmakta ve bu nedenle kullanılmaları problemlere yol açabilmektedir.
- f. eCognition altında 16bitlik görüntü kullanılabilir. Ancak bir önceki maddede belirtilen hatanın giderilmesi için CAD ortamında işlem yapılabilir fakat bu şekildeki bir yaklaşım için görüntünün 8bite yeniden örneklenmesi gerekmektedir. Böyle bir yaklaşım sonucunda zengin bilgi içeriğinin ele alınması mümkün olmamaktadır.
- g. Son olarak eCognition ortamında sınıflar için belirlenen özelliklere ait fonksiyonların sınır değerleri bazı problemlere yol açabilmektedir. Örneğin geniş aralık seçimi o sınıfta olmaması gereken nesnelere ifade edebilirken, dar aralık seçimi de, spektral nedenlerden dolayı tam yansımayı verememiş olan nesnelere o sınıfta olması gerektiği halde dışarıda bırakılmasına neden olabilmektedir.

Sonuç olarak tüm bu yaklaşımlar ve ele alınan problemler ışığında aşağıda sıralanan çözüm yolları önerilebilir:

- a. Tam geometrik doğruluğun sağlanabilmesi için piksel altı doğruluk verebilecek noktalar ve geometrik konum doğruluğunu tam olarak sağlayabilecek hassas SYM kullanılmalıdır.
- b. Radyometrik açıdan daha verimli bir çalışma için filtreleme teknikleri kullanılabilir.
- c. Bu çalışma kapsamında incelenen tüm CAD tabanlı yazılımlar görüntüyü ancak 8bit örnekli desteklemektedir. Bu noktada görüntünün yeniden örneklenmesi sonucunda elde edilebilecek detaylar göz önünde bulundurulmalıdır.
- d. Görüntünün tematik haritalarla uyum problemleri giderilerek çok daha olumlu sonuçlar alınabilecektir. Bunun için öncelikle görüntüyle tematik haritanın uyumunu sağlanmalıdır. Ancak görüntünün CAD programına aktarılmasında alt çözünürlüğe örneklenmesi gerektiği ve uyarlamada seçilen dönüşüm nesnelere dışındaki detayların bu dönüşümden olumsuz etkilenebileceği göz önünde bulundurulmalıdır.
- e. Son olarak eCognition altında seçilen sınıf özelliklerine atanan sınır değerleri ya tam olarak belirlenmeli ya da yardımcı parametrelerle tüme tamamlanmalıdır. Örneğin geniş aralık seçildiğinde fonksiyonun içine dahil olacak yanlış sınıf elemanları ek spektral veya şekil bilgileriyle sınıftan çıkarılmalı veya bir fonksiyonla belirlenememiş sınıf elemanları için ek fonksiyonlar tanımlanmalıdır.

KAYNAKLAR

- Abdel-Aziz, Y. I. and Karara, M.** (1971) Direct linear transformation from comparator coordinates into object space coordinates in close-range photogrammetry, *American Society of Photogrammetry Symposium on Close-Range Photogrammetry*, pp. 420-475.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. ve Heynen, M.** (2003) Multi-Resolution, Object-Oriented Fuzzy Analysis of Remote Sensing Data for Gis-Ready Information, *ISPRS Journal of Photogrammetry & Remote Sensing*, pp.239-258
- Büyüksalih, G., Oruç, M. and Koçak, M. G.** (2003) Geometric Accuracy Testing of Ikonos Geo-Product Mono Imagery Using Different Sensor Orientation Models, *Turkish Journal of Engineering Enviromental Science*, Vol. 27, pp 347-36.
- Büyüksalih, G.** (2004) Kişisel görüşme, ZKÜ Müh. Fak., Jeodezi ve Fotogrametri Mühendisliği Bölümü, Zonguldak.
- eCognition User Guide 4** (2005) Definiens Imaging, pp.3.2,1-108.
- Hofmann, T.; Puzicha, J. & J. Buhmann** (1998) Unsupervised texture segmentation in a deterministic annealing framework, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, Nr. 8, S. 803-818.
- Hofmann, P.** (2001a) Detecting Buildings and Roads from Ikonos Data Using Additional Elevation Information, *GIS Geo-Information-System*, 6/2001.
- Hofmann, P.** (2001b) Detecting Informal Settlements from Ikonos Image Data Using Methods of Object Oriented Image Analysis - An Example From Cape Town (South Africa), Jürgens, Carsten (Editor): *Remote Sensing of Urban Areas / Fernerkundung in urbanen Räumen. (Regensburger Geographische Schriften, Heft 35)*, Regensburg.
- Hofmann, P.** (2001c) Detecting Urban Features From Ikonos Data Using an Object-Oriented Approach, *Geomatics, Earth Observation and the Information Society*.
- Karakış, S., Topan, H., Büyüksalih, G., Marangoz, A. M. and Jacobsen, K.** (2005) Semantic Analysis of Space Imagery for Mapping Purposes, *IIth Conference of Recent Advances on Space Technologies*, 9-11 June, İstanbul, Turkey.
- Marangoz, A. M., Oruç, M. ve Büyüksalih, G.** (2004) Object-Oriented İmage Analysis and Semantic Network for Extracting The Roads and Buildings from Ikonos Pan-Sharpned İmages, *Proceedings of the XXth Congress of International Society for Photogrammetry and Remote Sensing*, 12-23 July, İstanbul, Turkey.

KAYNAKLAR (devam ediyor)

- Padwick, C.** (2005) Pan Sharpening of High Resolution Satellite Imagery, DigitalglobeWEB, <http://www.digitalglobe.com>
- Topan, H.**, (2004) Yörünge Düzeltmeli IRS-1C/1D Mono Görüntüsünün Geometrik Doğruluk ve Bilgi İçeriği Açısından İncelenmesi, Yüksek Müh. Tezi, ZKÜ Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, Zonguldak, 77 s
- Toutin, T.** (2003) Error tracking in Ikonos geometric processing using a 3D parametric model, *Photogrammetric Engineering & Remote Sensing*, Vol. 69, pp. 43-51.
- Wang, Y.** (1999) Automated triangulation of linear scanner imagery, *Joint Workshop of ISPRS WG I/1, I/3 and IV/4 Sensors and Mapping from Space*, Hannover, Germany.
- Zoej M. J. V.** (1997) Photogrammetric Evaluation of Space Linear Array Imagery for Medium Scale Topographic Mapping, Ph.D. Thesis, University of Glasgow, Faculty of Science, Glasgow, United Kingdom, 303 p.

ÖZGEÇMİŞ

Serkan KARAKIŞ, 1979 yılında İzmir’de doğdu. İlk ve orta öğrenimini İzmir’de, Lise öğrenimini Ankara’da tamamladı. Ankara Tapu Kadastro Meslek Lisesi’nden mezun olduktan sonra 1998 yılında Zonguldak Karaelmas Üniversitesi Mühendislik Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümü’ne girdi. 2002 yılında mezun olarak, aynı yıl Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı’nda yüksek lisans programına başladı. Halen aynı programa devam etmektedir.

ADRES BİLGİLERİ

Adres: Zonguldak Karaelmas Üniversitesi
Mühendislik Fakültesi
Jeodezi ve Fotogrametri Mühendisliği Bölümü
67100 ZONGULDAK

Tel: (372) 2572996
Faks: (372) 2574023
E-posta: jeodezi@hotmail.com