

**YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**UYDU GÖRÜNTÜLERİNDEN KENTSEL AYRINTILARIN  
NESNE-TABANLI SINIFLANDIRMA YÖNTEMİYLE  
BELİRLENMESİ VE CBS ORTAMINDA  
BÜTÜNLEŞTİRİLMESİ**

Jeodezi ve Fotogrametri Yük. Müh. Aycan Murat MARANGOZ

**FBE Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı  
Uzaktan Algılama ve CBS Programında Hazırlanan**

**DOKTORA TEZİ**

**Tez Savunma Tarihi** : 22 Ekim 2009  
**Tez Danışmanı** : Prof. Dr. Zübeyde ALKIŞ (YTÜ)  
**İkinci Tez Danışmanı:** Doç. Dr. Gürcan BÜYÜKSALİH (İBB)  
**Jüri Üyeleri** : Prof. Dr. Ahmet YAŞAYAN (YTÜ)  
: Prof. Dr. Sıtkı KÜLÜR (İTÜ)  
: Prof. Dr. Derya MAKTAV (İTÜ)  
: Doç. Dr. Naci YASTIKLI (YTÜ)

**İSTANBUL, 2009**

**YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**UYDU GÖRÜNTÜLERİNDEN KENTSEL AYRINTILARIN  
NESNE-TABANLI SINIFLANDIRMA YÖNTEMİYLE  
BELİRLENMESİ VE CBS ORTAMINDA  
BÜTÜNLEŞTİRİLMESİ**

Jeodezi ve Fotogrametri Yük. Müh. Aycan Murat MARANGOZ

**FBE Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı  
Uzaktan Algılama ve CBS Programında Hazırlanan**

**DOKTORA TEZİ**

**Tez Savunma Tarihi** : 22 Ekim 2009  
**Tez Danışmanı** : Prof. Dr. Zübeyde ALKIŞ (YTÜ)  
**İkinci Tez Danışmanı:** Doç. Dr. Gürcan BÜYÜKSALİH (İBB)  
**Jüri Üyeleri** : Prof. Dr. Ahmet YAŞAYAN (YTÜ)  
: Prof. Dr. Sıtkı KÜLÜR (İTÜ)  
: Prof. Dr. Derya MAKTAV (İTÜ)  
: Doç. Dr. Naci YASTIKLI (YTÜ)

**İSTANBUL, 2009**

# İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ .....	v
KISALTIMA LİSTESİ .....	vi
ŞEKİL LİSTESİ .....	vii
ÇİZELGE LİSTESİ .....	x
ÖNSÖZ .....	xi
ÖZET .....	xii
ABSTRACT .....	xiii
1. GİRİŞ.....	1
1.1 Çalışmanın Amacı ve Kapsamı .....	3
2. UYDU GÖRÜNTÜLERİNİN SAĞLADIĞI BİLGİ İÇERİĞİ KAVRAMI.....	7
2.1 Normal ve Etkin YÖA Değeri .....	8
2.2 Uydu Görüntülerinin Sağladığı Bilgi İçerikleri.....	10
2.3 Değerlendirme .....	16
3. GEOMETRİK DÜZELTME ve GÖRÜNTÜ ZENGİNLEŞTİRME .....	18
3.1 Uydu Görüntülerinin Geometrik Düzeltmesi .....	18
3.1.1 Parametrik Olmayan Matematiksel Modeller.....	19
3.1.1.1 Çeşitli Polinom Derecelerini Kullanan İki Boyutlu Yaklaşım .....	20
3.1.1.2 Yükseklik Değerini Kullanan Afin Dönüşüm .....	23
3.1.1.3 DLT .....	24
3.1.1.4 RFM.....	25
3.1.2 Parametrik Matematiksel Modeller .....	26
3.1.2.1 SOM.....	26
3.2 Uydu Görüntülerinin Zenginleştirilmesi .....	26
3.2.1 Pan-sharp Algoritması ve Kullanılan Diğer Algoritmalar.....	27
3.2.1.1 IHS Sharpening Algoritması .....	29
3.2.1.2 PCA Sharpening Algoritması .....	31
3.2.1.3 GS Sharpening Algoritması.....	31
3.2.1.4 Wavelet Sharpening Algoritması.....	32
3.2.1.5 UNB Sharpening Algoritması .....	32
4. GÖRÜNTÜ SINIFLANDIRMA YAKLAŞIMLARI.....	35
4.1 Sınıflandırma Kavramı ve Sınıflandırıcılar .....	35
4.1.1 Bulanık Sınıflandırma Sistemleri .....	37
4.1.1.1 Bulanıklaştırma.....	38

4.1.1.2	Bulanıklık Kural Tablosu .....	39
4.1.1.3	Durulama .....	41
4.2	Klasik Piksel-Tabanlı Sınıflandırma Yaklaşımı .....	41
4.2.1	Maksimum Benzerlik Sınıflandırma Yöntemi .....	42
4.2.2	Minimum Uzaklık Sınıflandırma Yöntemi .....	42
4.2.3	Paralelyüz Sınıflandırma Yöntemi .....	43
4.3	Nesne-Tabanlı Sınıflandırma Yaklaşımı .....	44
4.3.1	Görüntü Yorumlamada Temel Bileşenler .....	46
4.3.1.1	Görüntü İşlemede Yaklaşık Ölçek .....	46
4.3.1.2	Görüntü Semantikleri – Görüntü Nesneleri Arasındaki Karşılıklı İlişkiler .....	48
4.3.2	Segmentasyon .....	50
4.4	Ecognition Yazılımı Altında Nesne-Tabanlı Görüntü Analizi .....	52
4.4.1	Görüntü Nesnelerinin Çoklu Segmentasyonu .....	54
4.4.2	Segmentasyonun Uygulanması .....	56
4.4.2.1	Heterojenlik Kriterinin Belirlenmesi .....	57
4.4.3	Alt Nesnelerin Çizgi Analizi Amaçlı Segmentasyonu .....	60
4.4.4	Görüntü Nesnelerinin Hiyerarşik Ağ Yapısı .....	60
4.4.5	Ecognition'da Vektör Bilgisi .....	62
4.4.6	Ecognition Altında Bulanık Sınıflandırma .....	63
5.	MEVCUT VERİLER, ÜRETİLEN VEKTÖR ÜRÜNLER ve MEVCUT REFERANS VEKTÖR HARİTALAR .....	66
5.1	Kullanılan Uydu Görüntüleri .....	66
5.1.1	IKONOS Uydu ve Görüntü Verileri .....	66
5.1.2	QuickBird Uydu ve Görüntü Verileri .....	68
5.2	Test Alanına Ait Mevcut ve Üretilen Diğer Vektör Ürünleri .....	70
6.	UYGULAMA .....	73
6.1	Test Alanı .....	73
6.2	Kullanılan Yazılımlar .....	74
6.3	Görüntülerin Geometrik Olarak Düzeltilmesi .....	75
6.4	Görüntülerin Zenginleştirilmesi .....	76
6.5	Görüntülerin Ekran Üzerinden Elle Vektörleştirilmesi .....	77
6.6	Görüntülerin Farklı Sınıflandırma Yaklaşımlarıyla Değerlendirilmesi .....	78
6.6.1	Piksel-Tabanlı Sınıflandırma Sonucu Elde Edilen Ürünler .....	78
6.6.1.1	Sonuç Ürünlerin Doğruluk Analizleri .....	79
6.6.2	Nesne-Tabanlı Sınıflandırma Sonucu Elde Edilen Ürünler .....	79
6.6.2.1	QuickBird Uydu Görüntüsünden Nesne-Tabanlı Detay Çıkarımları .....	81
6.6.2.1.1	Sonuç Ürünlerin Doğruluk Analizleri .....	84
6.6.2.2	IKONOS Uydu Görüntülerinden Nesne-Tabanlı Detay Çıkarımları .....	84
6.6.2.2.1	Sonuç Ürünlerin Doğruluk Analizleri .....	87
6.6.3	Nesne-Tabanlı Sınıflandırma Sonuçlarının Vektör Ürün Haline Çevrilmesi .....	88
6.7	CBS Ortamında Karşılaştırmalı Analizler .....	89
6.7.1	QuickBird Uydu Görüntüsü için Analiz Sonuçları .....	90
6.7.1.1	Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının Karşılaştırılması .....	90
6.7.1.2	Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması .....	92
6.7.2	2002 Yılına Ait IKONOS Uydu Görüntüsü için Analiz Sonuçları .....	94
6.7.2.1	Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının	



	Karşılaştırılması .....	94
6.7.2.2	Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması.....	96
6.7.3	2008 Yılına Ait IKONOS Uydu Görüntüsü İçin Analiz Sonuçları .....	98
6.7.3.1	Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının Karşılaştırılması .....	98
6.7.3.2	Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması.....	100
6.7.4	CBS Ortamındaki Karşılaştırılmalı Analiz Sonuçlarının İrdelenmesi.....	102
7.	SONUÇ ve ÖNERİLER .....	109
KAYNAKLAR.....		114
ÖZGEÇMİŞ.....		119

## SİMGE LİSTESİ

$A$	Düzeltilme denklemlerinin katsayılar matrisi
$b$	Ecognition'da nesnenin muhtemel en kısa fiili sınır uzunluğu
$c$	Kamera odak uzaklığı
$f_i$	Ecognition'da birleştirme değeri
$f$	odak uzaklığı
$d$	Odak düzlemi uzaklığı
$dx$	Dengeleme bilinmeyenleri vektörü
$h$	Ecognition'da nesnenin heterojenlik değeri
$(h/b)$	Yükseklik-baz oranı
$h_u$	Uçuş yüksekliği
$h_{ae}$	Elipsoidal yükseklik
$h_{\text{renk}}$	Ecognition'da spektral heterojenlik
$h_{\text{şekil}}$	Ecognition'da şekil heterojenliği
$l$	Ecognition'da nesnenin fiili sınır uzunluğu
$m$	Ecognition'da nesneyi şekillendiren piksel sayısı
$m_0$	Birim ağırlıklı ölçünün karesel ortalama hatası
$m_h$	Düşey doğruluk
$m_x, m_y$	$x$ ve $y$ görüntü koordinatına ait soncul karesel ortalama hata
$n$	Toplam YKN sayısı
$p$	Paralaks
$N$	Polinom derecesi
$L_d$	Dengeli görüntü koordinatları vektörü
$L_{\tilde{o}}$	Ölçülen görüntü koordinatları vektörü
$u$	Matematiksel modelin bilinmeyen sayısı
$v$	Düzeltilmeler vektörü
$v_{x,y}$	$x$ ve $y$ yönündeki görüntü koordinatlarına getirilecek düzeltilmeler
$w$	Ecognition'da renk için (şekle karşılık) kullanıcı tanımlı ağırlık
$w_c$	Ecognition'da tabaka ağırlığı
$x, y$	Görüntü koordinatları
$X, Y, Z$	Yer koordinatları
$\gamma$	Nadirden sapma açısı
$\mu$	Üyelik derecesi
$\sigma_c$	Ecognition'da tabakadaki spektral değerlerin ağırlıklı standart sapması

## KISALTIMA LİSTESİ

ATRC	Affine Terrain Relief Corrected - Yükseklik Değerini Kullanan Afin Dönüşüm
CAD	Computer Aided Design – Bilgisayar Destekli Tasarım
CBS	Coğrafi Bilgi Sistemi
CCD	Charge Coupled Device – Yüklenme İliştirilmiş Aygıt
CCRS	Canada Center for Remote Sensing – Canada Uzaktan Algılama Merkezi
DLT	Direct Linear Transformasyon - Doğrudan Lineer Dönüşüm
GPS	Global Positioning System - Küresel Konumlama Sistemi
GS	Gramm Schmidt Sharpening - Gramm Schmidt Keskinleştirilmesi
YÖA	Yer Örnekleme Aralığı - Ground Sampling Distance (GSD)
EKK	En Küçük Kareler
IHS	Intensity Hue Saturation Sharpening – Yoğunluk, Renk ve Doygunluk Keskinleştirilmesi
IFOV	Instantaneous Field of View - Anlık Görüş Açısı
MMS	Multi Spectral Scanner – Çok Bandlı Tarayıcı
MRF	Markov Rassal Field - Markov Rassal Alanı
MS	Multispectral – Çok Bandlı
PAN	Pancromatic – Siyah/beyaz
PCA	Principal Components Analysis - Temel Bileşenler Analizi
RGB	Red-Green-Blue – Kırmızı-Yeşil-Mavi
RFM	Rational Functions Model – Rasyonel Fonksiyon Modeli
SDLT	Self-Calibrating DLT – Kendi Kendine DLT
SI	Space Imaging
SOM	Satellite Orbital Modelling – Uydu Yörünge Modellemesi
SYM	Sayısal Yükseklik Modeli
STANAG	Standardisation Agreement – Standardizasyon Anlaşması
TDI	Time Delay Integration – Zaman Geciktirme ve Entegrasyonu
UNB	University of New Brunswick – New Brunswick Üniversitesi
YKN	Yer Kontrol Noktası

## ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1 Ötelenmiş CCD dizinleri, piksel ve YÖA ilişkileri (Topan, 2006).....	8
Şekil 2.2 TDI teknolojisi .....	9
Şekil 2.3 Zonguldak şehir merkezine ait farklı uydu görüntüleri (Karakış vd., 2005).....	11
Şekil 2.4 KOMPSAT-1 ve SPOT-5 görüntüleri .....	12
Şekil 2.5 IRS-1C ve KVR-1000 görüntüleri .....	12
Şekil 2.6 SPOT-5 ve IRS-1C görüntüleri için vektörleştirme sonuçları .....	13
Şekil 2.7 SPOT-5 ve IRS-1C görüntüleri .....	13
Şekil 2.8 IKONOS Pan, renkli ve pan-sharp görüntüleri .....	14
Şekil 2.9 Farklı güneş yükseklik açılarındaki IKONOS pankromatik ve pan-sharp (1.0m YÖA) görüntüleri .....	15
Şekil 2.10 QuickBird renkli ve pan görüntüleri ve harita yapımı amaçlı karşılaştırma .....	16
Şekil 3.1 Polinom terimlerinin X (sol) ve Y (sağ) eksenlerdeki etkisi.....	21
Şekil 3.2 İki boyutlu afin dönüşümünde koordinat eksenleri.....	21
Şekil 3.3 QuickBird uydusuna ait doğrusal dizi sensörlerin şekilsel yapısı.....	27
Şekil 3.4 Odak düzleminde sensörlerin algılama durumu ve yeryüzünden yansıma alım anı	27
Şekil 3.5 QuickBird uydusunun dört bantta ayrı ayrı yapmış olduğu alım .....	28
Şekil 3.6 Uydu hareketinden kaynaklanan bantlar arasındaki paralaks .....	28
Şekil 3.7 IHS Algoritmasıyla üretilmiş pan-sharp QuickBird görüntüsü.....	29
Şekil 3.8 Yoğunluk bandıyla pankromatik band arasındaki parlaklık farkı .....	30
Şekil 3.9 Yoğunluk bandıyla birlikte görünür pankromatik bandın gösterimi.....	30
Şekil 3.10 Görünür pan iyileştirmesi uygulanmış IHS Algoritması sonucu .....	30
Şekil 3.11 PCA Algoritmasıyla hazırlanmış pan-sharp görüntü .....	31
Şekil 3.12 QuickBird pan, renkli ve pan-sharp görüntüleri (Cheng vd., 2003) .....	33
Şekil 3.13 GS, PCA ve UNB Algoritmalarının karşılaştırılması .....	34
Şekil 3.14 Wavelet ve UNB Algoritmalarının karşılaştırılması .....	34
Şekil 4.1 Üyelik fonksiyonlarına örnek (Baatz vd., 2005) .....	39
Şekil 4.2 Birbirleri içine giren fonksiyonlarla bulanıklığın sağlanması (Baatz vd., 2005).....	39
Şekil 4.3 Özelliğin her bir sınıfa karşılık vermesi, ancak bir sınıfa baskın çıkması (Baatz vd., 2005) .....	40
Şekil 4.4 Birbirine yakın değerler nedeniyle sınıf tayininin yapılamaması (Baatz vd., 2005). 41	41
Şekil 4.5 Olasılık yoğunluk fonksiyonları (Oruç, 2003) .....	42
Şekil 4.6 Minimum uzaklık sınıflandırma yöntemi (Oruç, 2003) .....	43
Şekil 4.7 İki boyutta paralelyüz sınıflandırma (Oruç, 2003).....	43
Şekil 4.8 Heterojen nesnelere örnek çatılar ve yeşil alan (Baatz vd., 2005) .....	54
Şekil 4.9 Üç ayrı katmanda oluşturulan görüntü segmentasyonu sonrasındaki görüntü nesnelerinin hiyerarşik ağ yapısı (Karakış vd., 2005) .....	56
Şekil 4.10 Düşük heterojenlik sonucu geometrik anlamda bozuk şekillerin oluşması .....	57
Şekil 4.11 Optimize edilmiş heterojenlikle daha düzgün şekilli yapıların oluşması (Baatz vd., 2005) .....	58
Şekil 4.12 Alt segmentlere ayrılmış nesne örneği (Baatz vd., 2005) .....	60

Şekil 4.13 Hiyerarşik ağ yapısı (Baatz vd., 2005).....	61
Şekil 4.14 Ecognition altında poligonların oluşturulması (Baatz vd., 2005) .....	63
Şekil 4.15 Douglas Peucker Algoritmasının poligonlara uygulanması (Baatz vd., 2005) .....	63
Şekil 4.16 Ecognition altında kullanılan fonksiyon çeşitleri (Baatz vd., 2005) .....	64
Şekil 5.1 Zonguldak bölgesine ait IKONOS görüntüleri .....	67
Şekil 5.2 Test alanına ait pan-sharp IKONOS görüntüleri.....	68
Şekil 5.3 Zonguldak bölgesine ait QuickBird görüntüsü .....	69
Şekil 5.4 Test alanına ait pan-sharp QuickBird görüntüsü.....	69
Şekil 5.5 1/5000 ölçekli referans vektör haritadaki bina ve yol yapıları.....	70
Şekil 5.6 2002 yılı IKONOS görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları.....	70
Şekil 5.7 2002 yılı IKONOS görüntüsünden elle vektörleştirme sonucu elde edilen ürün.....	71
Şekil 5.8 2008 yılı IKONOS görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları.....	71
Şekil 5.9 2008 yılı IKONOS görüntüsünden elle vektörleştirme sonucu elde edilen ürün.....	71
Şekil 5.10 2004 yılı QuickBird görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları (Marangoz vd., 2007).....	72
Şekil 5.11 2004 yılı QuickBird görüntüsünden elle vektörleştirme sonucu elde edilen ürün (Marangoz vd., 2007).....	72
Şekil 6.1 Test alanı (Pan-sharp QuickBird görüntüsü).....	74
Şekil 6.2 Test alanı üzerinde YKN'lerin dağılımı .....	76
Şekil 6.3 Test alanının pan-sharp QuickBird görüntüsünün elde edilmesi .....	77
Şekil 6.4 Kullanılan görüntülerin piksel-tabanlı sınıflandırma sonuçları.....	79
Şekil 6.5 Ecognition altında projenin tanımlanması ve görüntünün açılması .....	80
Şekil 6.6 QuickBird görüntüsü için beş değişik ölçek parametresi kullanılarak yapılan görüntü segmentasyonu (Ölçek parametresi : A = 10, B = 20, C = 30, D = 35 ve E = 60).....	82
Şekil 6.7 Sınıf atamaları için kullanılan özellikler ve bunlara ait fonksiyonlar (A:Üçüncü banda ait yansıma değerlerini kullanan dikdörtgensel fonksiyon, B:Dikdörtgensel şekil uyumunu kullanan dikdörtgensel fonksiyon) .....	82
Şekil 6.8 QuickBird uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları .....	83
Şekil 6.9 2002 yılına ait IKONOS uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları .....	86
Şekil 6.10 2008 yılına ait IKONOS uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları .....	86
Şekil 6.11 QuickBird görüntüsünün nesne- tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler .....	88
Şekil 6.12 2002 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler .....	89
Şekil 6.13 2008 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler .....	89
Şekil 6.14 Bina yapılarının QuickBird görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler .....	90
Şekil 6.15 Yol yapılarının QuickBird görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler .....	91

Şekil 6.16 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler.	92
Şekil 6.17 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler..	93
Şekil 6.18 Bina yapılarının 2002 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler.....	94
Şekil 6.19 Yol yapılarının 2002 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler.....	95
Şekil 6.20 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler.....	96
Şekil 6.21 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler.....	97
Şekil 6.22 Bina yapılarının 2008 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler.....	98
Şekil 6.23 Yol yapılarının 2008 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler.....	99
Şekil 6.24 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler.....	100
Şekil 6.25 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler.....	101
Şekil 6.26 26 Görüntülerden farklı yaklaşımlarla elde edilen sonuçların referans harita ile geometrik olarak karşılaştırılması – 2002 IKONOS örneğinde bina yapıları.....	102
Şekil 6.27 Referans vektör harita ve QuickBird görüntüsünden üretilen vektör haritanın karşılaştırılması.....	104
Şekil 6.28 QuickBird görüntüsünden bina yapılarının elle vektörleştirme ve nesne-tabanlı sınıflandırma sonuçları.....	105
Şekil 6.29 QuickBird görüntüsünden yol yapılarının elle vektörleştirme ve nesne-tabanlı sınıflandırma sonuçları.....	105
Şekil 6.30 Farklı güneş yükseklik ve azimut açılarına sahip görüntülerin aynı alandaki gösterimi.....	107

## ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Kenar Belirleme ile hesaplanan etkin YÖA değerleri.....	9
Çizelge 2.2 Görüntü yorumlama için yeterli görülen YÖA değerleri.....	17
Çizelge 2.3 Pankromatik görüntülerden nesne tanımına ilişkin yeterli görülen YÖA değerleri .....	17
Çizelge 5.1 IKONOS görüntülerinin özellikleri.....	66
Çizelge 5.2 Çalışma alanına ait QuickBird uydu görüntüsünün özellikleri .....	68
Çizelge 6.1 Piksel-tabanlı sınıflandırmalar için genel doğruluk ve Kappa değerleri.....	79
Çizelge 6.2 QuickBird görüntüsü için segmentasyon parametreleri .....	81
Çizelge 6.3 QuickBird görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi ...	84
Çizelge 6.4 2002 yılına ait IKONOS görüntüsü için segmentasyon parametreleri.....	85
Çizelge 6.5 2008 yılına ait IKONOS görüntüsü için segmentasyon parametreleri.....	85
Çizelge 6.6 2002 yılına ait IKONOS görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi.....	87
Çizelge 6.7 2008 yılına ait IKONOS görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi.....	87
Çizelge 6.8 Referans vektör haritadaki ve QuickBird görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları .....	92
Çizelge 6.9 Referans vektör haritadaki ve QuickBird görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları.....	93
Çizelge 6.10 Referans vektör haritadaki ve 2002 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları .....	96
Çizelge 6.11 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları .....	97
Çizelge 6.12 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları .....	100
Çizelge 6.13 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları .....	101
Çizelge 6.14 Test alanındaki yol ve bina yapılarının, referans vektör haritadaki ve görüntülerden değişik yöntemlerle elde edilen vektör ürünlerindeki alan ve uzunluk bilgileri .....	103
Çizelge 6.15 Kullanılan görüntülerin sahip olduğu bazı özellikler.....	106
Çizelge 6.16 Bina ve yol yapılarının, görüntülerden değişik yöntemlerle bulunma ve tanınma değerlendirmeleri .....	108

## ÖNSÖZ

Tez konusunun seçiminden, sonuçlandırma aşamasına kadar tüm görüş ve yorumlarıyla beni yönlendiren, her türlü yardım, destek ve ilgisi ile yapmış olduğum bu çalışmaya büyük katkıda bulunan, kendisi ile çalışma imkanı bulduğum için çok mutlu olduğum, tez danışmanım Sayın Hocam Prof. Dr. Zübeyde ALKIŞ'a saygı ve teşekkürlerimi belirtmek istiyorum. Kendileri çok yapıcıydı, oldukça uzun süren bu süreçte hep moral verdi, sabır gösterdi.

Lisans, yüksek lisans ve doktora eğitimim boyunca her yönünü örnek aldığım, Fotogrametri ve Uzaktan Algılama branşını tanımamda ve sevmemde büyük rol oynayan, çalışmama yapmış olduğu çok değerli bilgi ve katkılarından dolayı Sayın Hocam Prof. Dr. Ahmet YAŞAYAN'a, yine aynı şekilde çalışmam süresince daha yakından tanıma fırsatı bulduğum, cesaretlendirici ve yol gösterici, ciddi ve yapıcı eleştirilerde bulunan Sayın Hocam Prof. Dr. Sıtkı KÜLÜR'e teşekkür ederim.

Doktora eğitimimin başlangıcından beri hiçbir desteğini esirgemeyen, bilgi ve birikimiyle yol gösteren Sayın Hocam Prof. Dr. Şenol KUŞÇU'ya, birlikte çalışma fırsatı yakaladığım, çalışmamın her aşamasında yardım gördüğüm ve bu konuya yönelmemde büyük rol oynayan Sayın Hocam Doç. Dr. Gürcan BÜYÜKSALİH'e, kendisinden çok şeyler öğrendiğim, özellikle tüm hayatımız boyunca çok çalışmamızın ve araştırmamızın gerekli olduğunu öğrendiğim, yine bu mesleği bana sevdiren Sayın Hocam Prof. Dr. Erdal KOÇAK'a, ayrıca yüksek lisans ve doktora eğitimime başlamamdaki ilgi ve destekleri sebebiyle Sayın Hocam Prof. Dr. Ayhan ALKIŞ ve Prof. Dr. Ömer AYDIN'a da saygı ve şükranlarımı sunarım.

Bu eğitimim süresince ilgi, motivasyon ve desteği ile bana yardımcı olan Yıldız Teknik Üniversitesi'ndeki tüm hocalarım ve arkadaşlarıma, özellikle sevgili arkadaşım Arş. Gör. Dr. Mehmet Ali YÜCEL'e, Zonguldak Karaelmas Üniversitesi'ndeki tüm hocalarım ve arkadaşlarıma, özellikle Sayın Hocam Yrd. Doç. Dr. Hakan AKÇİN'a, ayrıca tezin uygulama kısmındaki katkılarından dolayı mesai arkadaşlarım Arş. Gör. K. Sedar GÖRMÜŞ, Arş. Gör. Serkan KARAKIŞ ve Uzman Murat ORUÇ'a teşekkür ederim.

Aynı şekilde bu süreçte manevi desteklerini her zaman arkamda hissettiğim sevgili arkadaşlarım İnşaat Yüksek Müh. Özgür MURATOĞLU, Jeo. ve Fot. Yüksek Müh. Üst Teğmen Murat ARSLANOĞLU ve Jeo. ve Fot. Yüksek Müh. Teğmen Hakan ŞAHİN'e ve adını saymadığım tüm dostlarıma çok teşekkür ederim. Ayrıca hep yanımda olan, moral veren, sıkıntılarımı paylaşan çok sevdiğim arkadaşım Çiler SUIÇMEZ'e de çok şey borçluyum.

Son olarak, hayatım boyunca karşılaştığım iyi ve kötü anlarda hep yanımda olan, aldığım kararlarda beni destekleyen, maddi ve manevi katkılarını hissettiğim, her şeyim olan sevgili aileme; babama, anneme ve ablama minnettarım. Sürekli sabırlı ve sevgi dolu oldunuz.

Hepinize teker teker yürekten teşekkürler.

Kasım 2009

Aycan Murat MARANGOZ



## ÖZET

Bu çalışmada, günümüzde yüksek çözünürlüklü uydu görüntüleri kapsamına giren 0.6-1.0m yer örnekleme aralığına sahip görüntülerin neden yoğun olarak kullanılmaya başlandığı ve bu görüntülerden konumsal bilgi elde etmede etken olan görüntünün bilgi içeriği kavramı örnekler verilerek incelenmiştir. Sonrasında, görüntülerin herhangi bir haritacılık uygulamasına altlık olacak şekilde düzenlenmesi için; geometrik olarak düzeltilmeleri ve zenginleştirilmeleri konusunda mevcut yöntem, algoritma ve yapılan işlemler anlatılmıştır. Görüntülerden çıkarılacak bilgi içeriğinin elde edilmesinde yararlanılan sınıflandırma yaklaşımlarından bahsedilmiş ve özellikle son yıllarda sıkça kullanılan nesne-tabanlı görüntü işleme analizi incelenmiştir.

Bu amaçla yapılan uygulamada, Zonguldak Bölgesini kaplayan yüksek çözünürlüklü 2004 yılına ait QuickBird, 2002 ve 2008 yıllarına ait IKONOS uydu görüntüleri kullanılmıştır. Görüntülerdeki bina ve yollar gibi kentsel ayrıntılar eCognition v4.0.6 yazılımı ile nesne-tabanlı sınıflandırma yaklaşımı kullanılarak bulunmuş, tanınmış ve çıkarılmıştır. Elde edilen ürünler, test alanının mevcut 1/5000 ölçekli referans vektör haritası ile karşılaştırılmış, analiz ve sorgu işlemleri yapılarak diğer bir yöntem olan görüntünün ekran üzerinden elle vektörleştirilmesi yöntemiyle elde edilen vektör ürünlerine karşı başarısı CBS ortamında analiz edilmiştir. Bu değerlendirmeler doğrultusunda, yüksek çözünürlüklü uydu görüntülerinin geometrik ve semantik içeriğinden yararlanarak günümüz yerel yönetimler ve kamu tarafından kullanılan 1/5000 ölçekli haritaların yapımı ve güncelleştirilmesi konusunda gerekli sonuçlar sunulmuş ve yorumlar yapılmıştır.

**Anahtar Kelimeler:** Uzaktan Algılama, Yüksek Çözünürlüklü Uydu Görüntüleri, Bilgi İçeriği, Segmentasyon, Nesne-Tabanlı Sınıflandırma.

## **ABSTRACT**

In this study, the fact that why the images having ground sampling distance of 0.6-1.0m recently regarded as the high resolution remote sensing images are widely used has been discussed, and the concept of information contents of the image required for obtaining spatial data has been investigated by various examples. Secondly with regard to the arrangement of remote sensing images for any mapping applications, the existing methods, algorithms and the processes for their geometric corrections and enhancements have been presented, respectively. The approaches of classification utilized to obtain information contents of the images have been pointed out and the object-based image analysis widely used in recent years has been investigated.

Thus in the application regarding this goal, the high resolution QuickBird image of 2004 and IKONOS satellite images of 2002 and 2008 covering Zonguldak region have been used. The urban details like buildings and roads in the images have been detected recognized and extracted using Cognition v4.0.6 software and the object-based classification approach. The results have been compared with the reference vector maps scale of 1/5000 of testfield, and the success of object-based image analysis of final results compared and contrasted respectively with other vector products, which had been obtained by the method of on-screen digitizing results, has been tested by GIS software. Consequently, the results and discussions about the production and updating of maps at the scales of 1/5000, which are recently and widely used by local authorities and public organizations, have been presented.

**Key Words:** Remote Sensing, High Resolution Satellite Images, Image Contents, Segmentation, Object-Based Classification.

## 1. GİRİŞ

Günümüzde, arazinin kullanımı ve konum bilgisi ile ilgili doğru, gerçek ve güncel bilgilere en kısa zamanda ulaşmak, arazi uygulamalarında ana hedef haline gelmiştir. Bu yeni bir uygulama ya da daha önce yapılmış bir uygulamanın revize edilmesi aşamasında zaman ve ekonomiklik açısından büyük önem arz etmektedir. Bu sebeple bir uygulama başlamadan, kullanılacak bilgilere en kısa zamanda ulaşmalı ve amaca yönelik olarak kullanılacak bilginin doğruluğu uygulamanın gidişatını aksatacak şekilde olmamalıdır. Bu durum uzaktan algılama teknolojilerinin kullanımına zemin hazırlamaktadır (Çelik, 2006).

Özellikle günümüzde zengin bilgi içeriği sunan uydu görüntülerinin varlığı ve teknolojik gelişmelere bağlı olarak bu görüntülerin işlenebilmesi, uzaktan algılama teknolojilerinin sahadaki kullanım yerini sağlamlaştırmaktadır. Ancak yapılacak uygulamada uygun bilgi içeriği sunan ekonomik görüntülerin kullanılması uygulamanın ekonomikliği açısından dikkate alınmalıdır. Dikkat edilmesi gereken diğer bir husus da, görüntü maliyetinin yanında bu görüntüyü uygulamada kullanıma hazır hale getirecek ve gerekli bilgiyi elde etmek için kullanılacak yazılım ve donanım maliyetlerinin hesaba katılmasıdır. Bu aşamada, uygulanacak metot bile farklılıklar ortaya koyacaktır. Örneğin bu görüntülerdeki detayları ekran üzerinden elle vektörleştirmek veya bazı algoritmalar kullanarak otomatik veya yarı otomatik çıkarmak bile yazılımlar arasında teknik ve mali farklar oluşturacaktır (Karakış, 2005).

Uydu görüntüleri, uygun ölçekte harita yapımı ve güncellenmesi, planlama, risk yönetimi, analiz ve benzeri birçok alandaki uygulamalara altlık teşkil edebilmektedir. Yukarıda bahsedilen uygulamalardaki kritik kararların alınabilmesi için güncel, hızlı ve düşük maliyetlerle elde edilebilen verilere ihtiyaç duyulması, uydu görüntülerinin bu alanlarda kullanılmasında tercih sebebidir.

Bu uygulamalarda, kullanılacak bilgi içeriğinin uydu görüntülerinden elde edilmesi için manuel (elle), yarı otomatik ve tam otomatik çeşitli yaklaşım ve algoritmalar geliştirilmiştir. Tam otomatik algoritmaların temeli görüntü işleme tekniklerine dayanırken, yarı otomatik algoritmalar da bu görüntü işleme algoritmalarına operatör desteği ve yorumu da katılmaktadır. Manuel yaklaşımda ise, operatörün yorumu ve işgücü ön plana çıkmaktadır (Çelikoyan ve Altan, 2005).

Yukarıda bahsedilen ve bilinen en eski yöntem olan manuel yaklaşım, ekran üzerinden görüntüdeki detayların sınırlarından vektör çizgilerin elle çizilmesiyle yapılan vektörel

çizimdir. Oluşturulan bu vektörlerin detayların nesneyi öznitelik bakımından ifade eden katmanlara dahil edilmesiyle gerçekleştirilmiş olur. Ancak görüntüdeki her bir detayın vektörel çizgilerle ifade edilmesi göz önüne alındığında, bu oldukça uzun bir işlemdir. Böylelikle uygulanan bu yaklaşımda, doğrudan bilgisayar desteğinin olmaması ve dolayısıyla operatör gücüne bağlı olması, yapılan uygulamalarda zaman ve işgücü kaybına yol açmaktadır.

Temeli görüntü işleme tekniklerine dayanan yarı ve tam otomatik yaklaşımlarla görüntü analizleri için çeşitli sınıflandırma teknikleri kullanılır. Halen güncel olan ve günümüze kadar kullanılmış yaklaşım, işlem birimi piksel olan piksel-tabanlı sınıflandırma yaklaşımlarıdır. Bu yaklaşımlarda pikselle ait renk değerleri ve piksellerin birbiri ile olan komşuluk ilişkileri ele alınmaktadır.

Günümüz görüntü işleme ve dolayısıyla uzaktan algılama teknolojilerinde, piksel-tabanlı sınıflandırma yaklaşımlarının yanında nesne-tabanlı sınıflandırma yaklaşımları da kullanılmaya başlanmıştır. Bunun en önemli nedeni, yüksek çözünürlüklü görüntülerde mevcut olan zengin bilgi içeriğinin, piksel-tabanlı sınıflandırma yaklaşımları sonucunda tam olarak yansıtılmaması olarak gösterilebilir (Wong vd., 2003). Örneğin IKONOS ve QuickBird uydu görüntüleri, piksel-tabanlı yaklaşımlarda tutarsız sınıflandırma sonuçları vermekte ve görüntüdeki istenen detayların çıkarımında beklentileri karşılayamamaktadır. Bahsedilen klasik sınıflandırma yaklaşımların yapısından dolayı, bu durum, yeni ve nesne-tabanlı görüntü analizi algoritmalarının kullanımını gerektirir. Bu tür algoritmalar, sınıflandırmaların düzenlenmesi konusunda görüntü segmentlerini daha uygun hale getirmek için, spektral bilginin yanında yapısal veya dokusal ek bilgilerle daha uygun çözümler sunmaktadır (Antunes vd., 2003).

Piksel-tabanlı sınıflandırma yaklaşımlarının aksine, nesne-tabanlı sınıflandırma yaklaşımı; yapıyı, dokuları, spektral bilgileri ve nesne büyüklüğünü birlikte dikkate alır. Bu yaklaşımda sınıflandırma aşaması, komşu piksellerin gruplandırılmasının, sınıflandırmanın sonraki basamağında ele alınabilir anlamlı bölgelere dönüştürülmesi ile başlar. Bu tür görüntü segmentasyonu ve topoloji oluşumu, çözünürlüğe ve görüntüdeki çıkarılması düşünülen detaylarının ölçeğine göre ayarlanmalıdır. Bu yaklaşımla, 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. Segmentasyon aşamasından sonra görüntüden çıkarılması istenen sınıflar oluşturulmakta ve bu sınıfların içine dahil olacak

segmentler için uygun fonksiyonlar belirlenerek, bulanık mantıkla çalışan sınıflandırma işlemi tamamlanmaktadır (Baatz vd., 2004).

### 1.1 Çalışmanın Amacı ve Kapsamı

Son yıllardaki uydu teknolojileri alanındaki gelişmeler, özellikle büyük alanların kapsamlı olarak incelenmesine ve bu bağlamda doğru, güvenilir ve kapsamlı güncel bilgilerin en hızlı şekilde üretilmesine olanak tanır hale gelmiştir. Böylece özellikle kentsel alanlardaki hızlı gelişim ve değişimleri takip edilebilmekte, bu gelişim ve değişimleri yönlendirme stratejileri oluşturulabilmektedir. Yukarıda bahsedilen ve bir çok uygulamaya altlık oluşturabilecek uydu görüntülerinin özellikleri, yapılan çalışmanın içeriğini doğrudan etkilemektedir. Bununla birlikte uydu görüntülerinin, görüntü işleme teknikleriyle değerlendirilmesi sonucunda uygun ölçeklerde harita yapımının gerçekleştirilmesi çalışma konusudur. Örneğin Jacobsen, (2002) ve (2003)'de yapmış olduğu çalışmalar ile, özellikle engebesiz alanlarda, yüksek çözünürlüklü IKONOS ve QuickBird görüntülerinden yaklaşık 1/6000 ve 1/10000 ölçekleri arasında haritalar üretilbildiğini göstermiştir.

Zengin bilgi içeriğine sahip yüksek çözünürlüklü uydu görüntüleri, görsel olarak çok fazla bilgi sunmasına rağmen uygulamalara altlık oluşturabilmesi için görüntülerdeki tüm detayların bilgilerinin çıkarılması gerekmektedir. Bu gereksinim mevcut bilgi işlem teknolojilerine bağlı olarak gelişmiş görüntü analiz ve sınıflandırma yaklaşımlarını da beraberinde getirmiştir. Böylelikle bu çalışma ile, son yıllarda sıkça kullanılan nesne-tabanlı görüntü analizi ve sınıflandırma yaklaşımının; uydu görüntülerini kullanarak, detay çıkarımı, arazi değişiminin belirlenmesi, harita yapımı ve harita bilgilerinin revizyonunun yapılması konularındaki başarısının test edilmesi amaçlanmıştır. Bu amaçla,

- Yüksek çözünürlüklü uydu görüntülerinin sağladığı bilgi içeriği kavramının belirlenmesi,
- Bu görüntülere görüntü işleme analizleri öncesi uygulanan geometrik düzeltme ve görüntü zenginleştirme işlemlerinin irdelenmesi,
- Görüntü sınıflandırması için kullanılan klasik piksel-tabanlı ve nesne-tabanlı sınıflandırma yaklaşımlarının tanımlanması, özellikle nesne-tabanlı yaklaşımların dayandığı temel esasların irdelenmesi, bulanık mantıkla çalışan sınıflandırma işlemlerinin incelenmesi,

- Uygulama bölümüne altlık olacak şekilde, mevcut uydu görüntülerinin belirlenmesi, belirlenen görüntülerden elle vektörleştirme sonucu ürünlerin elde edilmesi ve mevcut referans vektör haritaların belirtilmesi,
- Belirlenen görüntüler kullanılarak, tezin amacına uygun şekilde piksel-tabanlı ve nesne-tabanlı sınıflandırma uygulanması, elde edilen detayların ne ölçüde derlenebileceği, bu amaçla yapılması gereken işlem adımlarının belirtilmesi, farklı yaklaşımlarla yapılabilecek çıkarımların birbirine göre ve eldeki mevcut ürünlere göre başarısının incelenmesi, karşılaştırmalar yapılarak analiz sonuç ve yorumlarının verilmesi,
- Elde edilen tüm sonuçlara göre, uydu görüntülerinden harita yapımı ve harita bilgilerinin güncelleştirilmesi konularında bilgilerin verilmesi ve gerekli yorumların yapılması hedeflenmiştir.

Tezin Giriş bölümünden sonra; uydu görüntülerinden elde edilebilecek bilgi içeriği kavramı detaylı olarak anlatılmış ve günümüz yüksek çözünürlüklü uydu görüntülerinin bilgi içerikleri hakkında bilgi verilmiştir. Bu görüntülerden, Zonguldak kentsel alanına ait yüksek çözünürlüklü SPOT-5, KVR-1000, IKONOS, QuickBird, WorldView-I ve benzeri uydu görüntülerinin bilgi içeriğinin araştırılması ve uygun görüntülerdeki çıkarılması istenen kentsel ayrıntıların belirlenmesi konularında bilgiler verilmiştir. Bu bağlamda, hangi görüntüden hangi kentsel ayrıntıların ne ölçüde derlenebileceği belirtilmiştir.

Üçüncü bölümde; ham uydu görüntülerinin geometrik düzeltilmesi, zenginleştirilmesi ve bunlara bağlı olan algoritmalar anlatılmıştır. Bunun için, mevcut görüntülere uygulanması gereken öncelikle geometrik işlemlerin tasarlanması ve uygulanması, ardından istenilen bilgi içeriğinin tam çıkarılması için yapılabilecek görüntü zenginleştirilme işlemlerinin irdelemesi yapılmıştır. Kullanılacak uydu görüntülerinin değişik sensör yöneltme modelleriyle rektifikasyonu detaylı olarak anlatılmış ve bu bağlamda verilerin geometrik değerlendirilmesi, Global Positioning System (GPS) gözlemleriyle konumlandırılan noktaların kullanılarak ve bu noktaların PCI Geomatica OrthoEngine v9.1.4 yazılımında kullanılan, Canada Center for Remote Sensing (CCRS)' den Dr. Thierry TOUTIN tarafından geliştirilmiş olan Satellite Orbital Modelling (SOM) yaklaşımında Yer Kontrol Noktası (YKN) olarak kullanılarak anlatılması sağlanmıştır. Ayrıca, yüksek çözünürlüklü görüntülerinin pankromatik ve renkli bantlarının kombinasyonu sonucunda özel bir algoritma ile oluşturulan, yüksek çözünürlüklü ve renkli görüntü ürününü sağlayan pan-sharp algoritmaları üzerinde durulmuştur.

Dördüncü bölümde; uzaktan algılamada sınıflandırma kavramı ve sınıflandırıcılar tanımlanmış, klasik piksel-tabanlı sınıflandırma yaklaşımına değinilmiş ve yüksek çözünürlüklü uydu görüntülerinden kentsel ayrıntıların çıkarımında yararlanılan nesne-tabanlı sınıflandırma yaklaşımı detaylı olarak incelenmiştir. Bu yaklaşım ile çalışan “Ecognition” yazılımı anlatılmış ve bununla birlikte yazılımda ilgili olan, görüntü yorumlamada temel bileşenler, özellikle ölçek kavramı, segmentasyon ve nesne-tabanlı görüntü analizi altında sınıflandırma kavramları irdelenmiştir.

Beşinci bölümde; Zonguldak test alanına ait yüksek çözünürlüklü IKONOS ve QuickBird uydularının özellikleri ve görüntü verilerinin incelenmesi yapılacak, bu görüntü verilerinin ekran üzerinden elle vektörleştirme sonucu elde edilecek vektör haritalardan bahsedilecektir. Ayrıca ilgili alana ait üretilmiş ve referans veri olarak kullanılacak olan 1/5000 ölçekli vektör haritalardaki mevcut kentsel ayrıntıların vektörel katmanlarının düzenlenmesi sağlanmıştır.

Altıncı bölümde; tezin amacına uygun olarak, Zonguldak kentsel alanına ait 2002 ve 2008 yıllarına ait yüksek çözünürlüklü IKONOS ve 2004 yılına ait yüksek çözünürlüklü QuickBird uydu görüntülerinin; değişik sensör yöneltme modelleriyle geometrik düzeltilmesi, zenginleştirilmesi, bu görüntüler üzerinden ilgili alanı kapsayan bölgedeki kentsel detaylar olan bina ve yolların, nesne-tabanlı görüntü analizi yazılımı olan Ecognition yazılımı kullanılarak çıkarımı sağlanmıştır. Böylelikle Nobrega vd. (2006)’daki gibi, görüntülerden ne tür ayrıntıların ne düzeyde çıkarılabildiği ve elde edilen sınıflandırma sonuçları irdelenmiştir. Ayrıca, güncel durumun Coğrafi Bilgi Sistemi (CBS) ortamına aktarımı, bu ortamda diğer verilerle bütünleştirilmesi ve güncelleme çalışmalarını yapılması da uygulamanın diğer bir adımı olmuştur. Nesne-tabanlı sınıflandırma sonuçlarının vektör yapıya çevrilmesi sağlanmış, bu sonuç verilerle birlikte, test alanına ait mevcut 1/5000 ölçekli vektör haritalar ve görüntüler üzerinden elle vektörleştirme sonuç ürünlerinin bir CBS yazılımı altında toplanmasıyla detaylı analiz ve sorgulamalar yapılmıştır. CBS tabanlı analiz ve karşılaştırmalarının yapılarak, güncel durum ortaya koyulmuştur. Bu sayede, yüksek çözünürlüklü görüntülerin, hem geometrik, hem de semantik içeriğinden yararlanarak, günümüz yerel yönetimler ve kamu tarafından kullanılmakta olan büyük ölçekli haritaların (örneğin 1/5000 ölçekli) yapımı ve güncelleştirme olanaklarının araştırılması sağlanmıştır. Yapılan araştırmanın değerlendirilmesi ile elde edilen sonuç ve öneriler tezin yedinci bölümde sunulmuştur.

Bu çalışmada kullanılan görüntü verileri, TÜBİTAK–Türkiye ve Julich Araştırma Merkezi–Almanya tarafından desteklenen “Geometric and Semantic Analysis of Space Imagery for Topographic Mapping & Database Construction of Selected Experimental Test Ares in

Turkey” konulu alıřmadan ve ZKÜ Arařtırma Fonu tarafından desteklenen “Kentsel Geliřim Alanının Yksek öznrlkl Uydu Grntleriyle CBS Tabanlı Analizi” konulu alıřmadan saėlanmıřtır. Ayrıca referans vektr veri olarak kullanılan 1/5000 lekli vektr harita verisi de “Zonguldak ve Kilimli Belediyesi Fotogrametrik Hali Hazır Yapım Projesi” kapsamında retilmiř ve tez alıřmasında kullanılmıřtır.



## 2. UYDU GÖRÜNTÜLERİNİN SAĞLADIĞI BİLGİ İÇERİĞİ KAVRAMI

Günümüzde, yüksek çözünürlüklü uydu görüntülerinin mühendislik uygulamalarında ve konumsal bilgi elde etmede yoğun olarak kullanılmaya başlanmasının en önemli nedeni, bu görüntülerin Yer Örnekleme Aralığının (YÖA) küçülmesidir. Bu durum görüntünün geometrik çözünürlüğünün artması ve nesnelerin daha ayrıntılı olarak görüntülerden seçilmesi anlamına gelmektedir. YÖA değerinin yanı sıra görüntülerin radyometrik ve spektral çözebilirlikleri de bilgi içeriğini etkilemekte, değişim belirleme gibi çalışmalarda zamansal çözebilirlik de ön plana çıkmaktadır. Bilgi içeriğini etkileyen bu çözebilirlik kavramlarına ek olarak, görüntülerin etkin YÖA, atmosferik durum, güneş yükseklik açısı, görüntüleme sisteminin bakış açısı ve ilgi alanındaki nesnelerin durumu ve aralarındaki kontrast da bilgi içeriğini etkileyen parametrelerdir.

Uzaktan algılama görüntülerinden konumsal bilgi elde etmede görüntülerin geometrik doğruluğu ve bilgi içeriği düzeyi iki önemli etkendir. Geometrik doğruluk, sistemin görüntü alım geometrisi ile yakından ilişkilidir ve büyük ölçekli topoğrafik haritaların konum doğruluğuna ulaşmada herhangi büyük bir sorun yaşanmamaktadır. Geometrik doğruluk kendi içerisinde yatay ve düşey konum doğruluğu olarak ikiye ayrılabilir. Burada, gözün ayırma gücü dikkate alındığında gösterimde uygulanmakta olan 0.20 mm kuralına göre 1/5000 ölçekli bir haritanın yatay konum hassasiyeti  $\pm 1.0\text{m}$  düzeyinde olmaktadır. Düşey konum doğruluğu ise,

$$m_h = \frac{h_u}{c} \frac{h_u}{b} m_{px} \quad (2.1)$$

bağıntısıyla hesaplanabilir. Burada,

$m_h$ : Düşey doğruluk,

$h_u$ : Uçuş yüksekliği,

$c$ : Kamera odak uzaklığı,

$(h/b)$ :Yükseklik-baz oranı,


$m_{px}$ : Yatay paralaksın doğruluğudur.

Uydu görüntüleri veya hava fotoğraflarından topoğrafik harita üretimi, piksel boyutu ile harita ölçeği arasında uygun bir ilişkiyi gerektirir. Kazanılan deneyimlerden elde edilen durum, haritanın ölçeği ile YÖA arasında 0.05–0.10 mm gibi bir ilişkinin olduğudur. Buna göre

1/10000 ölçekli bir harita için 50cm-1.0m olarak hesaplanacaktır. Burada, YÖA değerinin bir aralık olarak verilmesinin nedeni, görüntü detayı ve içeriğindeki değişikliklerdir.

## 2.1 Normal ve Etkin YÖA Değeri

YÖA değeri, komşu piksellerin merkezleri arasındaki uzaklığın yeryüzündeki fiziksel karşılıkları olarak tanımlanabilir. Bu komşu pikseller, birbirleri üzerine binebilmekte veya bunların aralarında bazı boşluklar da olabilmektedir. Şekil 2.1’de gösterildiği gibi birbirine göre yarım piksel ötelenmiş CCD dizinleri sayesinde yarım piksel boyutunda YÖA’ya sahip görüntüler elde edilebilir. Örneğin SPOT-5 pankromatik bantta 5 m yer piksel boyutuna sahipken, bu teknik sayesinde 2.5m YÖA değerine sahip Supermode görüntüsü elde edilebilir. Benzer şekilde OrbView-3 pankromatik bandında piksel boyutu 2m iken YÖA değeri 1 m’dir. Bu teknik sayesinde CCD dizinlerdeki piksellerin boyutlarını fiziksel olarak küçültmeye gerek kalmamakta, böylece görüntüleme sistemlerinin yapım maliyetleri düşmektedir (Jacobsen, 2006).



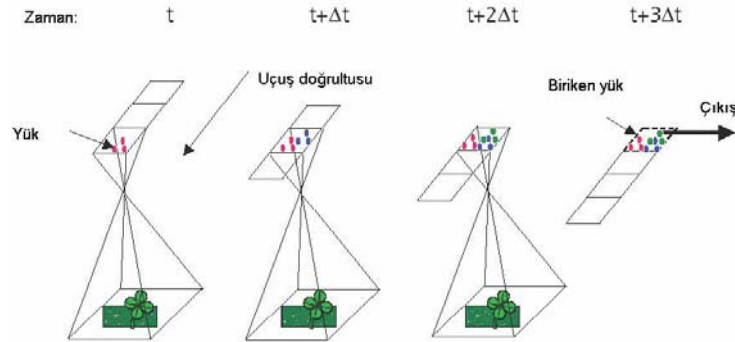
Şekil 2.1 Ötelenmiş CCD dizinleri, piksel ve YÖA ilişkileri (Topan, 2006)

Uydu görüntülerinin geometrik çözünürlüğünden söz edilirken genellikle normal YÖA değerinden bahsedilir. Oysa etkin YÖA, görüntülerin asıl sahip oldukları geometrik çözünürlük değeridir. Görüntüleme sistemine ve atmosferik duruma bağlı olarak görüntülerin normal ve etkin YÖA değerleri arasında fark olması muhtemeldir. Bu farkın belirlenebilmesi için gri değeri değişim grafiğinden yararlanılabilir. Görüntü üzerinde, örneğin bir bina veya havuz kenarında gri değerlerinin ortalamaları arasındaki fark, kenarda en büyük değerlerini alacak ve bu değişim bir normal dağılım eğrisi çizecektir. Bu eğrinin yüksekliğinin yarısının eğriyi kestiği noktalarının piksel karşılıklarının yarısı, etkin YÖA değerini vermektedir. Buna örnek olarak, aşağıdaki çizelgede Zonguldak test alanına ait bazı uydu görüntülerinin normal ve etkin YÖA değerleri verilmiştir (Çizelge 2.1).

Çizelge 2.1 Kenar Belirleme ile hesaplanan etkin YÖA değerleri

Uydu Görüntüsü	Normal YÖA Değeri (m)	Etkin YÖA Değeri (m)
TK-350	10	13
KVR-1000	1.6	2.2
ASTER	15	15
KOMPSAT-1	6.6	6.6
IRS-1C	5.7	6.9
SPOT-5	5	5
IKONOS	1	1
QuickBird	0.6	0.6

Çizelge 2.1’de gösterilen TK-350 ve KVR-1000 görüntüleri ilk olarak fotoğraf filmi üzerine kayıt edilmiş ve taranmak suretiyle sayısal hale getirilmişlerdir. Bu sebeple, bu iki görüntünün normal ve etkin YÖA değerleri arasında belirli bir fark oluşmuştur. Fakat IRS-1C için bu durum farklıdır, bunun nedeni ise bu görüntülerin, 6 bit (64 gri değeri) ile örneklenmesi sonucu düşük radyometrik çözebilirliğe sahip olmalarıdır. Ayrıca burada etkin YÖA değeri atmosferik durumundan da etkilenmiş olabilmektedir. Aynı büyüklükteki normal ve etkin YÖA değerlerine sahip IKONOS ve QuickBird görüntülerinin elde edilmesinde ise Time Delay Integration (TDI) teknolojisini kullanmaktadır. Bu teknolojiye, görüntünün oluşması için gereken zaman, uydunun ileri hareketi ile arttırılmakta ve böylece sensörlerin üzerinde toplanan enerji miktarı çoğaltılmaktadır (Şekil 2.2).




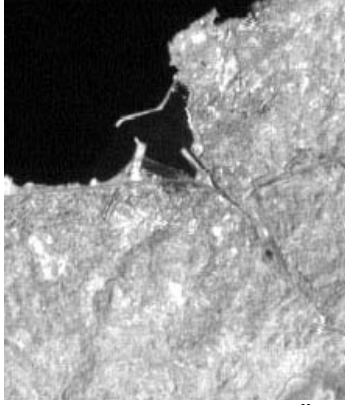

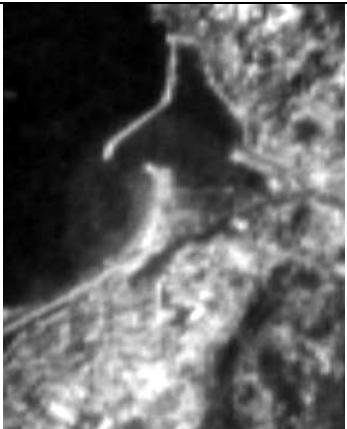
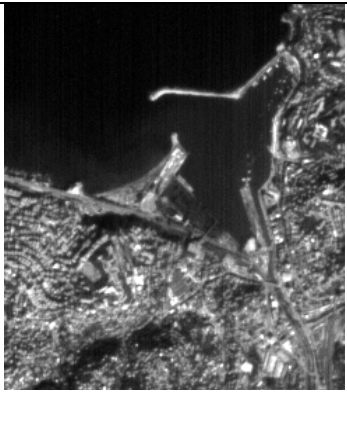



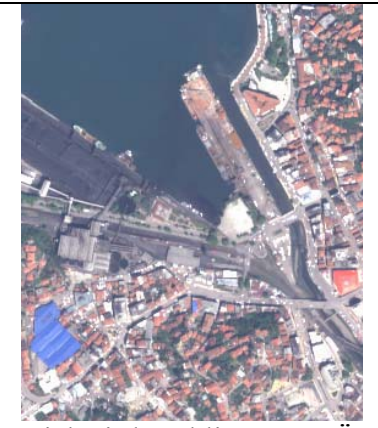
Şekil 2.2 TDI teknolojisi

Farklı test alanlarında ise EROS-A1 ve OrbView-3 görüntüleri test edilmiştir. 1.8m normal YÖA değerine sahip EROS-A1 görüntüsü için 2.4m etkin YÖA değeri belirlenmiştir. OrbView-3 görüntüsü için etkin ve normal YÖA değerleri aynı değerdedir (Topan, 2005).


Görüntünün bilgi içeriği kavramını daha anlaşılır hale getirmek için aşağıda Zonguldak test alanına ait, radyometrik ve spektral çözebilirliğe sahip uydu görüntülerinin sağladıkları bilgi içeriklerinin analizi örnek olarak verilmiştir.

## 2.2 Uydu Görüntülerinin Sağladıkları Bilgi İçerikleri

Bu incelemede, Zonguldak şehir merkezine ait değişik uydu görüntülerinin YÖA değerlerinin büyük önem taşıdığı gösterilmek istenmiştir. Bununla birlikte, radyometrik çözünürlüğün önem taşıdığı ve renkli görüntünün de yorumlama için önemli olduğu vurgulanmıştır. Şekil 2.3’de Zonguldak şehir merkezine ait farklı uydu görüntüleri, sahip oldukları YÖA değerleri ile birlikte verilmiştir.

		
Landsat 7 renkli, 30m YÖA	Landsat-7 pan, 15m YÖA	ASTER, 15m YÖA
		
TK 350, 10m (13m) YÖA	KOMPSAT-1, 6.6m YÖA	IRS-1C pan, 5.7m YÖA
		
SPOT-5 pan, 5m YÖA	IKONOS renkli, 4m YÖA	QuickBird renkli, 2.4m YÖA






Şekil 2.3 Zonguldak şehir merkezine ait farklı uydu görüntüleri (Karakış vd., 2005)

30m YÖA değerine sahip LANDSAT-7 Multispectral Scanner (MSS) görüntüsü, içerdiği nesnelerin sınıflandırılmasında kullanılmasına karşın, harita yapımı için uygun değildir. Bunun yanında LANDSAT-7 MSS görüntüsü, renk bilgisinin sağladığı avantajlarla, 15m YÖA değerine sahip LANDSAT-7 pan görüntüsüyle neredeyse aynı bilgi içeriği sunmaktadır. 15m YÖA değerine sahip ASTER görüntüsü daha fazla detay içermektedir. Görüntünün kontrastının daha iyi olmasının yanında, yeşil, kırmızı ve yakın kızılötesi band ile özellikle ormanlık alanlarda iyi bir ayırma olanak vermesi, LANDSAT-7 pan görüntüsüne karşı üstünlük kurmaktadır. LANDSAT-7 görüntüsünde ana yollar, yerleşim ve orman alanları ayırt edilebilmekte fakat daha fazla detayı görmek mümkün olamamaktadır. Bu nedenle bu görüntüler, ancak 1/100000 ölçekli bir harita üretimine izin verebilmektedir (Jacobsen ve Büyüksalih, 2006).

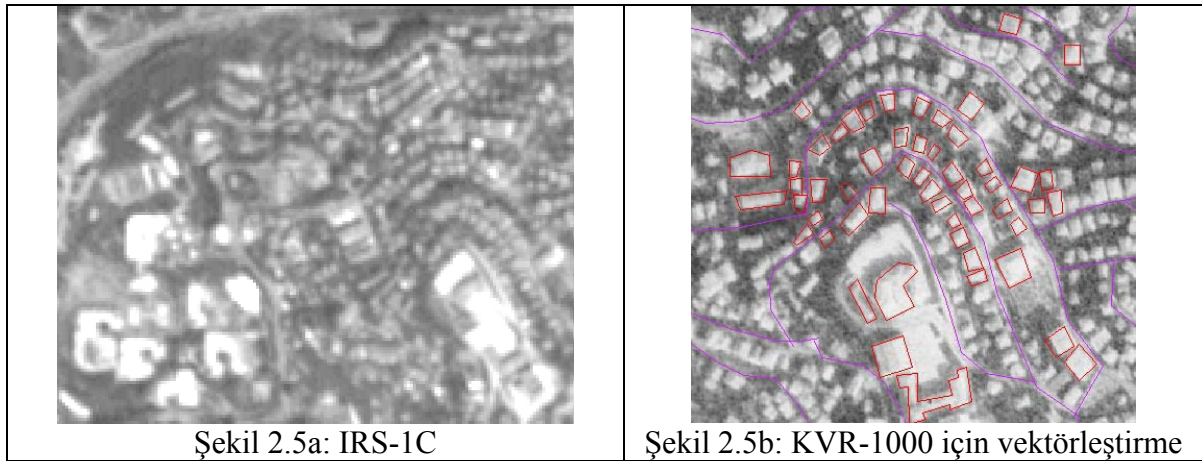
ASTER görüntüsü ile hemen hemen aynı YÖA değerine sahip olan bu TK-350 görüntüsü, kontrastının çok iyi olmaması yüzünden ASTER görüntüsüne nazaran daha az detay içeriği

sunmaktadır. Stereo-görüntü özelliğinden dolayı, Sayısal Yükseklik Modeli (SYM) üretmek için uygun olan TK-350 görüntüsü, bu haliyle doğrudan topoğrafik harita yapımına olanak vermemektedir.

Mikro-uydu KOMPSAT-1 ile çekilen görüntüler, 6.6m normal YÖA değerine sahiptirler ve topoğrafik harita yapımı için önemli bir görüntü verisi haline gelmişlerdir. Yakın YÖA düzeyleri ile KOMPSAT-1 ve SPOT-5 görüntülerinin genel detay çıkarım kapasiteleri birbirlerine yakındır. Şehir merkezindeki ana yol ağları bu görüntülerden çıkarılabilmekte, bina düzeyinde ise blok binalar tespit edilebilmektedir. haritaları yapılabilmektedir. Bu durum SPOT-5 ve KOMPSAT-1 görüntüleri ile yaklaşık 1/40000-1/50000 ölçekli haritaların yapımı için yeterli olmaktadır, ancak daha büyük ölçekli haritaların üretimine olanak vermemektedir (Jacobsen ve Büyüksalih, 2006) (Şekil 2.4).




Şekil 2.4 KOMPSAT-1 ve SPOT-5 görüntüleri




Şekil 2.5 IRS-1C ve KVR-1000 görüntüleri

KOMPSAT-1, SPOT-5 ve IRS-1C pan görüntüleri yaklaşık aynı YÖA değerleri üretmelerine rağmen farklı radyometrik düzey sergilemektedirler (Şekil 2.4a, 2.4b ve 2.5a). IRS-1C görüntüsünün 64 gri değerine sahip olması yüzünden SPOT-5 görüntüsünden daha fazla

detay çıkarılması olasıdır (Şekil 2.6). Bu görüntüden blok halindeki binalar, büyük tek binalar, ana ve ara yollar, kıyı çizgisi, açık ve yeşil alanlar rahatlıkla tanınabilmektedir. Fakat IRS-1C görüntüsünde büyük tek binaların ve ara yolların belirlenmesi SPOT-5 görüntüsündeki kadar kolay olmamaktadır. Şehir merkezinde durum bu şekildeyken, kırsal bir alanda her iki görüntüde de yerleşim ve yollar görülebilmektedir (Şekil 2.7). Aynı şekilde, SPOT-5 üzerinden daha rahat detay çıkarımı yapılabilmektedir. Yukarıda da belirtildiği gibi, her iki görüntü, yaklaşık 1/40000-1/50000 ölçekli bir harita yapımı için kullanılabilir (Jacobsen ve Büyüksalih, 2006). Ancak IRS-1C görüntüsünün 6.9m etkin YÖA değerine ve 64 gri değerine sahip olduğu ve bu nedenle sorunlar yaşanabileceği unutulmamalıdır.



Şekil 2.6 SPOT-5 ve IRS-1C görüntüleri için vektörleştirme sonuçları




Şekil 2.7 SPOT-5 ve IRS-1C görüntüleri

Tekli binaların ve yolların rahatlıkla belirlenmesi ise, 2.2m etkin YÖA değerine sahip olan KVR-1000 pan görüntüsü ile sağlanabilmektedir (Şahin vd., 2004 ve 2005) (Şekil 2.5b).



IKONOS görüntüleri, 1m pan ve 4m renkli görüntüleriyle oldukça iyi bir detay zenginliğine sahiptir. Pan görüntüler, yüksek geometrik çözebilirlikleri sayesinde nesnelerin gerçek boyutlarıyla algılanmasını sağlamakla birlikte, renkli görüntüler içerdikleri renk nedeniyle nesnelere arasındaki renk farklılıklarını ortaya koymaktadır (Şekil 2.8a ve 2.8b). Bu nedenle renk bilgisi, görüntüde nesnelerin daha iyi tanınmasına yardımcı olur. Zonguldak şehrindeki binalar genelde kırmızı çatılı binalardır, böylelikle 4m YÖA değerine sahip renkli IKONOS görüntüsü ile bu tekli binaların tanınması daha rahat olmaktadır, fakat bu binalar tekli çizimler için çok küçüktür.

Genelde, değişik nesnelerin elle sınıflandırma işlemi renk tarafından desteklenmektedir ve harita yapımı pan görüntülerle daha kolay yapılmaktadır. Renkli IKONOS görüntüleri ana yolların tanınmasına olanak vermektedir.




Şekil 2.8 IKONOS Pan, renkli ve pan-sharp görüntüleri (Marangoz, 2004)

IKONOS pan görüntüsünde binalar, yollar ve diğer unsurlar birbirlerinden geometrik çözebilirliğin yüksek düzeyde olması nedeniyle ayırt edilebilmektedir. Fakat görüntü renkli olmadığı için burada renk bilgisinden yararlanılamamaktadır. Renk bilgisini veren renkli IKONOS görüntüsü ise 4.0m YÖA değerine sahiptir ve dolayısıyla nesnelerin renkleri yardımıyla nesne ayırımı ön plana çıkmaktadır.

IKONOS pan ve renkli görüntülerinin “pan-sharp” algoritmasıyla birleştirilmesiyle elde edilen pan-sharp IKONOS görüntüsü Şekil 2.8c’de verilmiştir. Bu şekilde her iki görüntünün birleştirilerek pan-sharp görüntü oluşturulması, hem 1.0m YÖA değerini, hem de renk bilgisi içermesi bakımından oldukça sık tercih edilmektedir. Bahsedilen “pan-sharp” metodu tez çalışmasının üçüncü bölümünde detaylı bir biçimde anlatılmıştır.




Şekil 2.9'de ise, görüntülerdeki nesnelerin tanınmasında önemli etken olan güneşin yükseklik açısının etkisi gösterilmiştir. Güneş yükseklik açısı  $41^\circ$  olan görüntüde bina gölgelerinden dolayı yolların tanınması güçtür. Bina çatılarında güneşin yansımaları olduğu için, binaların çıkarılmasında herhangi bir sorun bulunmamaktadır. Fakat Zonguldak'taki sıralı binalar birbirlerine çok yakın olduğu için, bazen yol ve ev bahçeleri birbirlerinden ayırt edilememektedir. Güneş yükseklik açısının yanında, güneş azimutu değerinin de önemi büyüktür. Örneğin, Şekil 2.9c'de, yolların vektörleştirilmesi daha kolaydır. Şekil 2.9d'de verilen pan-sharp IKONOS görüntüsü ile binaların tanınması kolaylaşmaktadır, fakat renk bilgisinin avantajı 1m YÖA değeri için sınırlı kalmıştır.



Şekil 2.9 Farklı güneş yükseklik açılarındaki IKONOS pan ve pan-sharp (1.0m YÖA) görüntüleri

Kısacası, binaların ve diğer yüksek nesnelerin gölgelerinde kalan nesneler görüntüde seçilememekte ve dolayısıyla bu durum, görüntülerin verdiği bilgi içeriğini azaltmaktadır. Bu bakımdan güneş yükseklik açısı ve güneş azimutu, nesne çıkarımında dikkate alınması gereken etkenlerdir.



Şekil 2.10 QuickBird renkli ve pan görüntüleri ve harita yapımı amaçlı karşılaştırma

2.4m YÖA değerine sahip QuickBird renkli görüntüsü, doğru açılı binaların ve yollara paralel olmayan binaların doğru şekilde çıkarılmasına olanak vermemektedir (Şekil 2.10a). Buna karşın, 0.6m YÖA değerli pan görüntüsü ile bina detaylarını çıkarmada bir sorun bulunmamaktadır (Şekil 2.10b). Sonuç olarak denilebilir ki, özellikle engebesiz bölgelerde IKONOS görüntüleri, yaklaşık olarak 1/10000 ölçekli bir haritanın bilgi içeriğine sahipken, QuickBird görüntüleri, pan bandda 0.6m, renklide ise 2.4m YÖA değerleriyle, yaklaşık olarak 1/6000 ölçekli bir haritanın bilgi içeriklerini vermektedir (Jacobsen ve Büyüksalih, 2008).

### 2.3 Değerlendirme

Uydu görüntülerinden topoğrafik harita yapımı, YÖA değeri ve harita ölçeği arasında yeterli bir ilişki gerektirir. Günümüzde haritalar, ulusal koordinatlarıyla bir CBS ortamında bulunsalar bile, bilgi içerikleri ve harita yapımlarının düzeyi üretim ölçeğiyle ilişkilidir. İstenen semantik bilgi harita ölçeğine bağlıdır. Örneğin, tekli binalar 1/50000 ölçekli haritada gösterilmezken, bu ölçekte sadece bölgenin genel yapısı sunulmaktadır. Tabii ki bu durum, binaların mevcut olduğu 1/1000 ölçekli haritalarda farklıdır. Normal koşullar altında, uydu görüntülerinden harita yapım doğruluğu ile ilgili bir problem bulunmamakla birlikte, gerçek sınırlama görüntünün bilgi içeriklerinden kaynaklanmaktadır. Bunun anlamı, yorumlama sırasında hangi nesnenin tanınabildiğidir. Burada halen, nesnenin bulunması ve yorumlanması arasında fark mevcuttur. Görüntüde bir çizgi tanınmakla birlikte, yorumlama esnasında bu çizginin, tarımsal bir bölgeye ait sınır çizgisi, bir patika veya bir yol olup olmadığı hakkında bazı sorunlar yaşanmaktadır (Topan, 2004).

Askeri amaçlı harita yapımı için sivil topoğrafik haritalarda gösterilmeyen nesnelere durumları hakkında bir ayırım yapılmaktadır (NATO STANAG 3769 standartları). Bunlar;

- **Bulma (Detection):** Görüntü yorumlamada, nesnenin tanınmadan varlığının belirlenmesi,
- **Tanıma (Recognition):** Görüntüdeki tank, hava aracı gibi bir özelliğin veya nesnenin kimliğinin grup tipi halinde kararlaştırılması kabiliyeti (Recognition, detection' a ihtiyaç duyar),
- **Adlandırma (Identification):** Görüntüdeki bir özelliğin veya nesnenin kimliğinin tam olarak kararlaştırılması kabiliyeti (örneğin T-54 Tankı, MIG-217J hava aracı gibi),
- **Detaylandırma:** Görüntüdeki bir özelliğin, nesne veya bir elemanın tam olarak tanımlanma kabiliyetidir.

Çizelge 2.2’de NATO STANAG 3769 standartlarında verilen görüntü yorumlama için yeterli görülen YÖA değerleri verilmiştir.

Çizelge 2.2 Görüntü yorumlama için yeterli görülen YÖA değerleri

Nesne	Bulma	Tanıma	Adlandırma	Detaylandırma
Bölgesel Özellikler	~800m	90m	3m	0.75m
Yerleşim Alanları	60m	15m	3m	0.75m
Yollar	6m	4.5m	1.5m	0.38m
Demiryolları	15m	4.5m	1.5m	0.38m
Köprüler	6m	4.5m	1.5m	0.3m

Çizelge 2.2’de gösterilen STANAG 3769’e göre yeterli görülen YÖA değerleri, kullanılan görüntünün özelliğini dikkate almaz ve bu nedenle sivil harita yapımı için geçerli olamaz. Bunun yanında Jacobsen ve Büyüksalih (2008) ise, Zonguldak bölgesindeki incelenen testlere dayanarak, nesne çıkarımına ilişkin bulunan bazı kuralları belirtmiştir (Çizelge 2.3).

Çizelge 2.3 Pankromatik görüntülerden nesne tanımına ilişkin yeterli görülen YÖA değerleri

Nesne Yapıları	Yeterli Görülen veya En Küçük YÖA Değeri (m)
Kentsel binalar	2
Patika	1-2
Ara yollar	5
Demir yolları	5
Su yapıları	5
Ana yollar	10
Blok halindeki binalar	10

Çizelge 2.3’deki değerlere göre, kentsel binaların 5m YÖA değerine sahip görüntülerden çıkarılamayacağı, fakat blok halindeki binaların rahatlıkla tanınabileceği görülmektedir.

### 3. GEOMETRİK DÜZELTME ve GÖRÜNTÜ ZENGİNLEŞTİRME

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 görüntülerin, uygulamaya geçilmeden önce geometrik olarak düzeltilmesi ve zenginleştirilmesi gerekmektedir (Topan, 2004). 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.

#### 3.1 Uydu Görüntülerinin Geometrik Düzeltilmesi

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:

- İki boyutlu parametrik olmayan modellerde yatay konum bilgisi kullanılmakta, bu yüzden yükseklikten kaynaklanan hatalar giderilememektedir.
- 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.

- 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.
- 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.

### 3.1.1 Parametrik Olmayan Matematiksel 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:

$$\begin{aligned} x_i &= F_1(X_i, Y_i, Z_i) \\ y_i &= F_2(X_i, Y_i, Z_i) \end{aligned} \quad (3.1 \text{ a,b})$$

veya iki boyutlu uzayda,

$$\begin{aligned} x_i &= F_1(X_i, Y_i) \\ y_i &= F_2(X_i, Y_i) \end{aligned} \quad (3.2 \text{ a,b})$$

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).

### 3.1.1.1 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:


$$\begin{aligned} x_i &= \sum_{j=0}^N \sum_{k=0}^{N-j} a_{jk} X_i^j Y_i^k \\ y_i &= \sum_{j=0}^N \sum_{k=0}^{N-j} b_{jk} X_i^j Y_i^k \end{aligned} \quad (3.3 \text{ a,b})$$

şeklinindedir. 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:

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


Yukarıdaki terimlerin her iki eksendeki etkisi Şekil 3.1'de görülebilir (Zoej, 1997).



Şekil 3.1 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 (Topan, 2004).

Yukarıda genel yapısı ile verilen polinomal dönüşümün en yaygın kullanım şekli ve birinci dereceden polinom eşitliği afin dönüşümü vermektedir (3.5 a,b). Dönüşümde koordinat eksenlerinin durumu Şekil 3.2'de gösterilmektedir.



Şekil 3.2 İki boyutlu afin dönüşümünde koordinat eksenleri

$$x_i = a_{00} + a_{10}X_i + a_{01}Y_i$$

$$y_i = b_{00} + b_{10}X_i + b_{01}Y_i$$

(3.5 a,b)

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

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} 1 & 0 & X_i & Y_i & 0 & 0 \\ 0 & 1 & 0 & 0 & X_i & Y_i \end{bmatrix} \begin{bmatrix} a_{00} \\ b_{00} \\ a_{10} \\ a_{01} \\ b_{10} \\ b_{01} \end{bmatrix} \quad (3.6)$$

$$\mathbf{L}_d = \mathbf{L}_{\ddot{o}} + \mathbf{v} = \mathbf{A} \mathbf{d} \mathbf{x} \quad (3.7)$$

bağıntısı yazılabilir. Bağıntıda geçen terimlerin açıklamaları aşağıdaki gibidir:

$\mathbf{L}_d$ : Dengeli görüntü koordinatları vektörü,

$\mathbf{L}_{\ddot{o}}$ : Ölçülen görüntü koordinatları vektörü,

$\mathbf{A}$ : Düzeltme denklemlerinin katsayılar matrisi,

$\mathbf{d} \mathbf{x}$ : Dengeleme bilinmeyenleri vektörü,

$\mathbf{v}$ : Düzeltmeler vektörüdür.

$\mathbf{d} \mathbf{x}$  bilinmeyenler vektörü ve  $\mathbf{v}$  düzeltmeler vektörünün çözümü aşağıdaki gibidir:

$$\mathbf{d} \mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{L}_{\ddot{o}} \quad (3.8)$$

$$\mathbf{v} = \mathbf{A} \mathbf{d} \mathbf{x} - \mathbf{L}_{\ddot{o}} \quad (3.9)$$

Birim ağırlıklı ölçünün karesel ortalama hatası ( $m_0$ ),

$$m_0 = \pm \sqrt{\frac{\sum_{i=1}^{2n} v v}{2n - u}} \quad (3.10)$$

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

$$m_x = \pm \sqrt{\frac{\sum_{i=1}^n v_x v_x}{n - \frac{u}{2}}} \quad (3.11)$$

$$m_y = \pm \sqrt{\frac{\sum_{i=1}^n v_y v_y}{n - \frac{u}{2}}} \quad (3.12)$$



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 Yükseklik Değerini Kullanan Afin Dönüşüm (ATRC), ikincisi Direct Linear Transformation (DLT) ve sonuncusu ise Rational Functions Modeli (RFM)'dir. (Topan 2004).

### 3.1.1.2 Yükseklik Değerini Kullanan Afin Dönüşüm

ATRC, afin dönüşüm gibi doğrusal bir yapıya sahiptir ve sekiz parametrelidir (Büyüksalih vd., 2003). Bu yöntemde kullanılan koordinat sistemlerinden görüntü koordinat sistemi iki boyutludur ve burada 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:

$$\begin{aligned} x_i &= a_1 + a_2X_i + a_3Y_i + a_4Z_i \\ y_i &= b_1 + b_2X_i + b_3Y_i + b_4Z_i \end{aligned} \quad (3.13 \text{ a,b})$$

Bu dönüşüm modelinin En Küçük Kareler (EKK) Dengelemesiyle çözülebilmesi için, uygun dağılıma sahip en az beş YKN noktasının görüntü ve yer koordinatlarına gereksinim duyulmaktadır. (3.13 a,b) eşitlikleri, matris gösterimi ile yazılırsa,

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} 1 & 0 & X_i & Y_i & Z_i & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & X_i & Y_i & Z_i \end{bmatrix} \begin{bmatrix} a_1 \\ b_1 \\ a_2 \\ a_3 \\ a_4 \\ b_2 \\ b_3 \\ b_4 \end{bmatrix} \quad (3.14)$$

şeklinde olacaktır.  $dx$  bilinmeyenler vektörü ve  $v$  düzeltmeler vektörünün çözümü (3.8) ve (3.9) bağıntılarında olduğu gibidir. Soncul karesel ortalama hatalar da (3.10), (3.11) ve (3.12) bağıntılarında olduğu gibi hesaplanabilir (Topan 2004).

### 3.1.1.3 DLT

Bu yöntem, fotogrametride sıkça kullanılan kolinearite bağıntılarının metrik olmayan fotogrametrik kameralar ile uygulanan 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 ve Karara, 1971).

DLT yönteminin on bir parametrelili genel eşitliği,

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

$$y_i = \frac{L_5 X_i + L_6 Y_i + L_7 Z_i + L_8}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1}$$
(3.15 a,b)

şeklindedir. (3.15 a,b) eşitlikleri matris gösterimiyle,

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} X_i & Y_i & Z_i & 1 & 0 & 0 & 0 & 0 & x_i X_i & x_i Y_i & x_i Z_i \\ 0 & 0 & 0 & 0 & X_i & Y_i & Z_i & 1 & y_i X_i & y_i Y_i & y_i Z_i \end{bmatrix} \begin{bmatrix} L_1 \\ L_2 \\ L_3 \\ L_4 \\ L_5 \\ L_6 \\ L_7 \\ L_8 \\ L_9 \\ L_{10} \\ L_{11} \end{bmatrix}$$
(3.16)

şeklinde olacaktır.

Wang (1999), DLT yöntemini yüksek çözebilirlikli uydu görüntüleri (IKONOS, QuickBird vb.) için yeniden organize edilmiş bir fazla parametre taşıyan Self-Calibrating DLT (SDLT)

yöntemini geliřtirmiřtir. SDLT'ye ait bağıntılar ařağıda verilmektedir:

$$x_i = \frac{L_1 X_i + L_2 Y_i + L_3 Z_i + L_4}{L_9 X_i + L_{10} Y_i + L_{11} Z_i + 1} \quad (3.17)$$

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

DLT ve SDLT için  $dx$  bilinmeyenler vektörü ve  $v$  düzeltmeler vektörünün çözümü (3.8) ve (3.9) bağıntılarında olduđu gibidir. Soncul karesel ortalama hatalar da (3.10), (3.11) ve (3.12) bağıntılarında olduđu gibi hesaplanabilir (Topan 2004).

### 3.1.1.4 RFM

RFM, günümüzde IKONOS ve QuickBird görüntüleri için kullanılmakta ve uydu yörünge bilgileri yerine RFM'lere ait katsayılar, görüntüyü sađlayan řirketlerce kullanıcıya verilmektedir. (3.18 a,b) bağıntılarıyla gösterilen RFM yaklařımı, YKN'lere ait  $Z$  deđerini de kullanmaktadır:

$$x_{ij} = \frac{P_{i1}(X, Y, Z)_j}{P_{i2}(X, Y, Z)_j} \quad (3.18 \text{ a,b})$$

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

Burada;

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

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

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

$$P_{i4}(X, Y, Z)_j = d_1 + d_2 Y_j + d_3 X_j + d_4 Z_j + \dots + d_{20} Z_j^3 \quad (3.19 \text{ a,b,c,d})$$

řeklinde-dir.

Parametrik matematiksel modeller, fotogrametrinin perspektif geometrisinin modellenmesi olan temel kolinearite eřitliđinin geniřletilmiř, yani deđiřtirilmiř řeklidir. Bu eřitliklerde sensör iç ve dıř yöneltme parametrelerine ek olarak yörünge bilgileri iç-erilmekte ve sensörün her bir dođrusal dizini için ayrı bir eřitlik yazılmaktadır. Halbuki RFM yaklařımında kullanıcıya sensör iç ve dıř yöneltme bilgileri verilmemekte; sadece bu parametrelerden üretilmiř olan 80 adet katsayı verilmektedir. Kullanıcı böylece karmařık matematik

eşitliklerle çalışmaya ihtiyaç duymamaktadır. Space Imaging (SI) şirketinden alınan son bilgiye göre IKONOS-2 uydu görüntülerinden hiçbir YKN kullanılmadan, verilen katsayılarla herhangi bir nesne, 3-4 m doğrulukla konumlandırılabilir (Topan, 2004). Bu, RFM'nin sağladığı yüksek duyarlılığı göstermektedir.

### **3.1.2 Parametrik Matematiksel 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.

#### **3.1.2.1 SOM**

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

- Görüntüleme sistemini taşıyan uydunun konum, hız ve dönüklük değişimleri,
- Görüntüleme süresindeki değişimler, bakış açısı ve Instantaneous Field of View (IFOV)'dan kaynaklı etkiler,
- Yerin küreselliği,
- Harita projeksiyonundan kaynaklanan etkiler yörünge parametreleriyle birlikte dikkate alınmaktadır.

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


### **3.2 Uydu Görüntülerinin Zenginleştirilmesi**

Bu bölümde, görüntülerin zenginleştirilmesi için uygulanan değişik metotlar ve kullanılan algoritmalara değinilecek, pan-sharp görüntülerinin üretilmesi amacıyla yoğun şekilde kullanılan pan-sharp algoritması anlatılacaktır. Bu konunun aktarılmasının amacı, yüksek çözünürlükte çalışmanın sağlayacağı avantaj dolayısıyla, renkli görüntüden alınabilecek bilgi içeriğinin, pankromatiğe olan üstünlüğüne bağlı olarak bir görüntü birleştirme tekniği olan pan-sharp algoritmasının tez çalışmasındaki uygulamada kullanılacak olmasıdır (PCI Geomatica yazılımı altında bulunan pan-sharp algoritması, University of New Brunswick

(UNB)'den Dr. Yun Zhang tarafından geliştirilmiş ve lisanslandırılmıştır. DigitalGlobe 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) (Karakış, 2005).

### 3.2.1 Pan-Sharp Algoritması ve Kullanılan Diğer Algoritmalar

Pan-Sharp algoritmasının anlatımından önce görüntü verilerinin sağlandığı sensörler ve görüntü alımları hakkında bilgi vermek gerekir. Tarama (pushbroom) teknolojisini kullanan IKONOS ve QuickBird uydularının sensörleri her bir spektral bant için ayrı bir doğrusal dizi kullanırlar. Örnek olarak Şekil 3.3'de QuickBird uydusunun doğrusal dizi sensör yapısı gösterilmektedir.




Şekil 3.3 QuickBird uydusuna ait doğrusal dizi sensörlerin şekilsel yapısı


QuickBird uydusu  $16.5 \times 16.5$  km'lik bir alanı yaklaşık olarak 4 saniyede toplamaktadır. QuickBird sensörleri aşağıda gösterilen bantlarda alım yaparlar:

- Pankromatik (Siyah-beyaz)
- Çok Bantlı (Renkli – Mavi, Yeşil, Kırmızı ve Yakın kızılötesi)

Şekil 3.4'de odak düzleminde sensörlerin oluşturduğu yapı, Şekil 3.5'de ise her bantta yapılmış bir alımın ayrı ayrı gösterimi yer almaktadır.



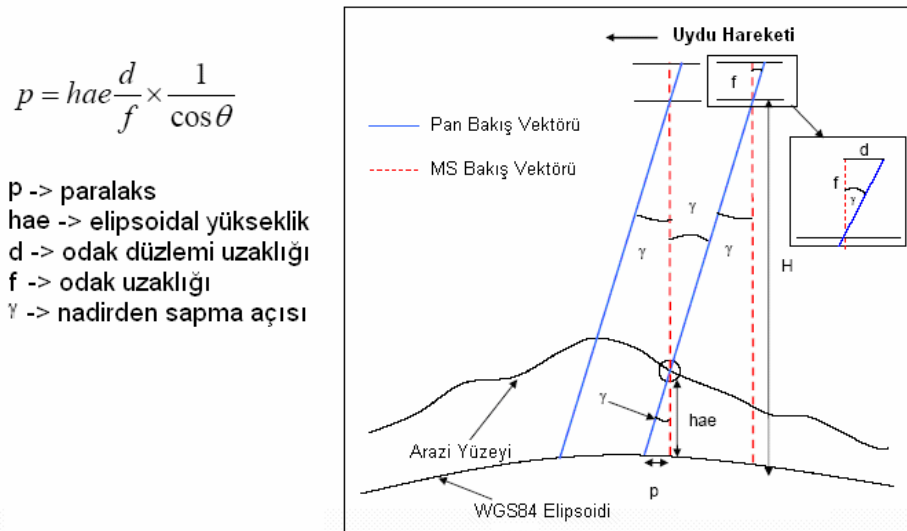
Şekil 3.4 Odak düzleminde sensörlerin algılama durumu ve yeryüzünden yansıma alım anı



Şekil 3.5 QuickBird uydusunun dört 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;  $0.2 \times 7.5\text{km/sn} = 1.5\text{km}$  büyüklüğündeki uzaklığa karşılık gelir. Diğer bir ifadeyle, uydu alımlar arasında yörüngesinde 1.5km hareket eder.

Alımlar arasında uydunun belirsiz hareketleri pan ve renkli bantların örtüşmemesine neden olur ve örtüşmeme sonucunda da bulanık bir pan-sharp görüntü oluşur. Ek olarak bantlar arasındaki paralaks da özellikle yükseklik modelinde hatalar olduğu zaman örtüşmemeye neden olabilir. Şekil 3.6’da oluşan paralaks durumu gösterilmektedir (Padwick 2005).



Şekil 3.6 Uydu hareketinden kaynaklanan bantlar arasındaki paralaks

Pan-sharp yöntemi bir çeşit görüntü birleştirmedir. Yüksek çözünürlüklü pankromatik görüntü, ondan daha düşük çözünürlüklü renkli görüntüyle birleştirilir. Sonuç ürün, yüksek çözünürlüklü renkli görüntüdür. Günümüzde birçok yazılımda çalışabilen çeşitli pan-sharp algoritmaları mevcuttur. En yaygın kullanılan pan-sharp algoritmaları aşağıda verilmiştir:

- Intensity Hue Saturation (IHS) Sharpening Algoritması
- Principal Components Analysis (PCA) Sharpening Algoritması
- Gramm Schmidt (GS) Sharpening Algoritması
- Wavelet Sharpening (WS) Algoritması
- UNB Sharpening Algoritması (DigitalGlobe firması tarafından kullanılan algoritma)


### 3.2.1.1 IHS Sharpening Algoritması

IHS Algoritması yoğunluk-renk-doygunluk üzerine kuruludur. Düşük çözünürlüklü RGB görüntü yüksek çözünürlüğe örneklenir ve IHS görüntüye çevrilir. Daha sonra yoğunluk bandı yerine pankromatik görüntü yerleştirilir ve IHS görüntü yeniden Red-Green-Blue (RGB)'ye çevrilir. Şekil 3.7'de IHS Algoritmasıyla yapılmış bir pan-sharp görüntü verilmiştir. Şekilden de görüldüğü gibi yeşil alanlar yansıtılmamaktadır. Yeşil alanlara görünen ışıktaki bakıldığında koyudur (düşük yansımaya). Eğer yakın kızılötesinde bakılırsa çok parlaktır (yüksek yansımaya). 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 3.8'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 3.7 IHS Algoritmasıyla üretilmiş pan-sharp QuickBird görüntüsü






Şekil 3.8 Yoğunluk bandıyla pankromatik band arasındaki parlaklık farkı

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

$$\text{GörünenPan(piksel gri değeri)} = \text{Pan(piksel gri değeri)} - 0.240 \times \text{NIR(piksel gri değeri)} \quad (3.20)$$

Şekil 3.9’da yoğunluk bandı ve görünür pan bandı birlikte görülmektedir. Şekil 3.10’den de anlaşılacağı gibi iyileştirme biraz daha iyi sonuç alınmasını sağlamıştır.



Şekil 3.9 Yoğunluk bandıyla birlikte görünür pankromatik bandın gösterimi




Şekil 3.10 Görünür pan iyileştirmesi uygulanmış IHS Algoritması sonucu



IHS 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.

### 3.2.1.2 PCA Sharpening Algoritması

PCA Algoritması kovaryans matrisinin ters-simetrik matrise (tüm diyagonal elemanları 0) dönüşmesi üzerine kuruludur. İlk temel bileşen bilginin çoğunu içerir. Pankromatik bant ilk temel bileşen yerine koyulur ve görüntü eski haline döndürülür. Şekil 3.11’de bu algoritmaya bir örnek gösterilmektedir.



Şekil 3.11 PCA Algoritmasıyla hazırlanmış pan-sharp görüntü

PCA sonuçları IHS sonuçlarına göre çok daha iyidir. Anlam ifade edebilecek uyumsuzluklar 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. Renk dönüşümü tam olarak orijinal renkli 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 (Karakış, 2005).

### 3.2.1.3 GS Sharpening Algoritması

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 algorithma da özellikle çalışma alanında yeşil alanın fazlalığı sağlam sonuçlar almada problem yaratmaktadır.

### 3.2.1.4 Wavelet Sharpening Algoritması

Diğerlerine göre daha yeni olan Wavelet Algoritmasında dalgaların kullanımı söz konusudur. Bu algortmada düşük çözünürlüklü renkli görüntü, pankromatik görüntünün çözünürlüğüne yeniden örneklenir ve IHS görüntüye çevrilir. Pankromatik görüntü içerisinde yüksek frekans bilgisi çıkarılarak yoğunluk bandına eklenir. Sonuç görüntü tekrar RGB'ye dönüştürülerek pan-sharp yapılmış olur.

Wavelet Algoritması sesin fiziksel temelleri üzerine kuruludur. Pankromatikten aldığı yüksek frekansı, rengi değiştirmeden çoklu bandın düşük frekansına ekler. Burada renk dönüşümü iyidir. Pankromatik ve Multispectral (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.


### 3.2.1.5 UNB Sharpening Algoritması

Algoritma UNB'den Dr.Yun Zhang tarafından geliştirilmiştir. Bu algoritma hem DigitalGlobe firması hem de bu uygulamada kullanılan PCI yazılımında lisanslı olarak kabul edilmiştir. DigitalGlobe firmasının normal şartlarda kullandığı algortmadır. Bu algortmada renk dönüşümü mükemmeldir. Renkler orijinal çoklu banttakine çok yakın sonuçlar vermektedir. Keskinlik kabul edilebilir sınırlarda olup diğer tekniklere göre (örneğin PCA, IHS) oldukça üstündür. Algoritma çok robust ve çeşitli çalışma alanı içeriklerini oldukça iyi ele alabilecek şekildedir (Padwick 2005).

UNB Algoritması istatistik tabanlı çalışan bir algortmadır. Birleştirilen görüntü bantlarının gri değerleri arasındaki en iyi uyumu 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.

Örneğin, renk bilgisini veren renkli QuickBird görüntüsü ise 2.44m YÖA değerine sahiptir ve dolayısıyla nesnelere renkleri yardımıyla nesne ayrımı ön plana çıkmaktadır. Görüntünün yüksek uzaysal çözünürlüğü ve spektral çözebilirliğin bu etkileri, aşağıda verilen basit bir işlem ile irdelenebilir. Bu işlemde, üç spektral QuickBird kanallarının (2.44m YÖA) birinci ana bileşeni yerine, 0.6m YÖA değerine sahip QuickBird pankromatik bandı kullanılır. Daha sonra ana bileşenlerin yeni kombinasyonu, ters temel bileşenlerin transformasyonu

uygulanarak tekrar dönüştürülür (Zhang ve Wang, 2004). Bu işlemler sonucunda, Şekil 3.12c’de gösterilen 0.6m YÖA değerine sahip “pan-sharp” QuickBird görüntüsü elde edilmektedir. Aşağıdaki şekilde, pankromatik görüntüde tanınan çatı ve yol nesneleri, renkli görüntüden alınan renk bilgisi ile birleştirilmiş ve uzaysal çözebilirliği yüksek renkli bir görüntü elde edilmiştir (Cheng vd., 2003).



Şekil 3.12 QuickBird pan, renkli ve pan-sharp görüntüleri  
(Cheng vd., 2003)

Aşağıdaki UNB Algoritmasının diğer algoritmalar ile karşılaştırmalı gösterimleri verilmiştir (Şekil 3.13 ve Şekil 3.14).



a: GS Algoritması sonucu

b: PCA Algoritması sonucu

c: UNB Algoritması sonucu

Şekil 3.13 GS, PCA ve UNB Algoritmalarının karşılaştırılması



a: Wavelet Algoritması sonucu

b: UNB Algoritması sonucu

Şekil 3.14 Wavelet ve UNB Algoritmalarının karşılaştırılması



#### 4. GÖRÜNTÜ SINIFLANDIRMA YAKLAŞIMLARI

Günümüz görüntü işleme ve dolayısıyla uzaktan algılama teknolojilerinde, klasik sınıflandırma yaklaşımlarından olan piksel-tabanlı yöntemlerin yanında nesne-tabanlı yöntemler de kullanılmaya başlanmıştır. Yüksek çözünürlüklü görüntülerden elde edilen zengin bilgi içeriği, piksel-tabanlı sınıflandırma yaklaşımlarında tam olarak yansıtılamamaktadır. Bunun nedeni, bu sınıflandırma yaklaşımlarının temelini tekil piksellerin gri değerlerine dayanmakta ve böylelikle sınıflandırma için sadece spektral bilgi kullanılmış olmasıdır. Örneğin, yüksek çözünürlüklü IKONOS ve QuickBird uydu görüntüleri, bu tür sınıflandırma uygulamalarında tutarsız sınıflandırma sonuçları vermekte ve araştırılan nesnenin çıkarımında beklentileri karşılayamamaktadır. Bahsedilen piksel-tabanlı klasik yöntemlerin yapısından dolayı bu durum, yeni bir yaklaşım olan nesne-tabanlı sınıflandırma yöntemlerinin kullanımını gerektirir. Bu tür yaklaşımda kullanılan algoritmalar, sınıflandırmaların düzenlenmesi konusunda segmentleri daha uygun hale getirmek için, spektral bilginin yanında yapısal veya dokusal ek bilgilerle daha pozitif sınıflandırma sonuçları sunar.

Nesne-tabanlı 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 yöntemle, 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.

Bu bölümde, ilk olarak sınıflandırma kavramı ile geçişli-geçişsiz sınıflandırıcılar anlatılmış ve sonrasında, klasik piksel-tabanlı sınıflandırma yaklaşımı yöntemlerinden kısaca bahsedilmiştir. Ayrıca yüksek çözünürlüklü uydu görüntülerinden kentsel ayrıntıların çıkarımında son zamanlarda uygulanan nesne-tabanlı sınıflandırma yaklaşımı ayrıntılı bir şekilde anlatılmaya çalışılmıştır.

##### 4.1 Sınıflandırma Kavramı ve Sınıflandırıcılar

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, özellikle 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.

Uzaktan algılama uygulamalarında klasik sınıflandırıcılar, (örneğin maksimum benzerlik, minimum uzaklık veya paralelyüz) bu suretle nesnelere 1.0 veya 0.0 olarak üyeliği atarlar. Bahsedilen bir nesne, ya bir sınıfa dahildir veya değildir. Bu tip sınıflandırıcılar, nesnelere, ikili yaklaşımla sınıfa atadığının kabulünden beri geçişsiz sınıflandırıcılar olarak adlandırılırlar.

Bunun tersine, geçişli sınıflandırıcılar (temel olarak bulanık sistemler ve/veya Bayesian 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 karşıladıklarına 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 (Karakış, 2005).

Dikkate alınan sınıflandırma yöntemleri temelde kontrollü ve kontrolsüz olarak ayrılabilir. Kontrollü yöntemde istenilen sınıfların nasıl olacağı kullanıcıya sorulurken, kontrolsüz yöntem hemen hemen kullanıcıdan bağımsızdır. Benzer özellik gösteren nesnelere türlerine göre gruplara ayıran istatistiksel gruplama yöntemleri 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 yöntemleri 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 nesnelerin 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 yöntemleri, 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 sınıflandırmama 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 (Baatz vd., 2005).

#### **4.1.1 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 alınırlar. 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.

#### **4.1.1.1 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 4.1’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 4.1 Üyelik fonksiyonlarına örnek (Baatz vd., 2005)

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 4.2,  $x$  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 4.2 Birbirleri içine giren fonksiyonlarla bulanıklığın sağlanması (Baatz vd., 2005)

#### 4.1.1.2 Bulanıklık Kural Tablosu

Bulanıklık kural tablosu, farklı bulanıklık setlerini birleştiren bulanıklık kurallarının kombinasyonundan oluşur. En basit bulanıklık kuralı, tek bir bulanıklık setine dayalı olandır. 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 4.2’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 4.3). Bu değerler sınıf üyeliğinin derecesini gösterir.




Şekil 4.3 Özelliğin her bir sınıfa karşılık vermesi, ancak bir sınıfa baskın çıkması (Baatz vd., 2005).

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 böyle değildir (Benz vd., 2003).

En olasılıklı 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 4.4’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 4.4 Birbirine yakın değerler nedeniyle sınıf tayininin yapılamaması (Baatz vd., 2005)

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 alınır.

#### 4.1.1.3 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.

## 4.2 Klasik Piksel-Tabanlı Sınıflandırma Yaklaşımı

Klasik piksel-tabanlı sınıflandırma yaklaşımlarının bütün amacı, arazi örtü sınıfları ve özelliklerine göre bir görüntüdeki tüm pikselleri otomatik olarak bir araya getirmektir. Bu konuyla ilgili daha ayrıntılı bilgi Lillesand ve Kiefer, (1994) kaynağında bulunabilir. Aşağıda piksel-tabanlı sınıflandırma yaklaşımlarından olan Maksimum Benzerlik (Maximum Likelihood), Minimum Uzaklık (Minimum Distance) ve Paralelyüz (Parallelepiped) yöntemleri kısaca anlatılmıştır.

#### 4.2.1 Maksimum Benzerlik Sınıflandırma Yöntemi


Maximum benzerlik sınıflandırma yöntemi uzaktan algılamada görüntü sınıflandırması için en çok kullanılan ve bilinen kontrollü sınıflandırma yöntemidir. Bu yöntem sınıflar için eş olasılık eğrilerinin tanımlanmasına ve sınıflandırılacak piksellerin üyelik olasılığı en yüksek olan sınıfa atanması ilkesine dayanır (Şekil 4.5). Herhangi bir sınıfa ait piksel setini temsil eden noktalar kümesinin geometrik şekli bir elipsoitle tanımlanırsa, bu elipsoidin yönü ve rölatif boyutları model uzayını tanımlayan özellikler arasındaki kovaryanslara bağlı olacaktır. Maximum benzerlik yönteminin etkinliği, her spektral sınıf için ortalama vektör ile kovaryans matrisin doğru biçimde tahmin edilmesine bağlı olmaktadır. Bu koşul ise, sınıfların her biri için yeterli miktarda örnekleme verisinin (pikseller) bulunabilmesine bağlıdır. Örnekleme bölgesine ait yeterli miktarda veri bulunmadığı zaman (sınıfların olasılık dağılımlarını doğru bir şekilde tahmin edebilecek özellikte veri olmadığı zaman) arzulanan sınıflandırma doğruluklarına ulaşamaz. Böyle bir durumda kovaryans bilgilerini kullanmayan başka sınıflandırma yöntemlerine başvurmak gerekir (Oruç, 2003).



Şekil 4.5 Olasılık yoğunluk fonksiyonları (Oruç, 2003)

#### 4.2.2 Minimum Uzaklık Sınıflandırma Yöntemi

Örnekleme bölgelerine ait örnekleme verileri sınırlı olduğu zaman, kovaryans bilgilerini kullanmayan yalnızca spektral sınıfların ortalama vektörlerinin kullanılmasına dayanan sınıflandırma yöntemlerine başvurmak gerekir. Böyle bir durumda kısıtlı örnekten ortalama değerler kovaryanslara nazaran daha doğru tahmin edilebilir. Minimum uzaklık yöntemi böyle bir yaklaşım uygular. Örnekleme verilerinden sınıf ortalamaları belirlenir, sınıflandırmada bir piksel en yakın ortalamaya sahip sınıfa atanır (Şekil 4.6).

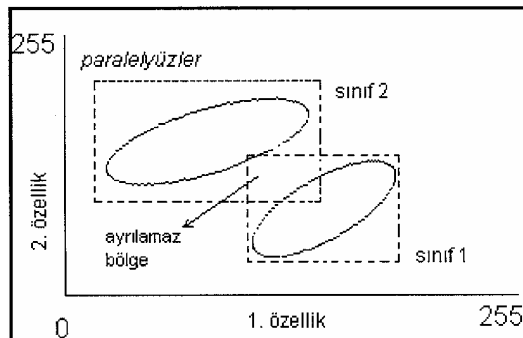


Şekil 4.6 Minimum uzaklık sınıflandırma yöntemi (Oruç, 2003)

Minimum uzaklık sınıflandırma yöntemi, maksimum benzerlik yönteminden daha hızlı olduğu için ilgi çekicidir. Ancak kovaryans bilgilerini kullanmadığından maximum benzerlik yöntemi kadar esnek değildir. Maximum benzerlik yöntemiyle sınıflandırmada sınıflar çok değişkenli normal sınıf dağılım modeli yardımıyla modellendirilmektedir. Minimum uzaklık yönteminde kovaryans verilerinin kullanılmaması nedeniyle sınıf modelleri spektral anlamda simetriktir. Bu nedenle bazı sınıflar iyi modellenmeyebilir. Ancak örnekleme verileri sınırlı olduğu zaman minimum uzaklık yöntemi, maximum benzerlik yönteminden daha doğru sonuçlar verir (Oruç, 2003).

#### 4.2.3 Paralelyüz Sınıflandırma Yöntemi

Bu yöntem kontrol (örnekleme) verilerinin spektral bileşenlerinin histogramlarının incelenmesine dayalı çok basit bir kontrollü sınıflandırma yöntemidir. Aynı zamanda bir sınıflandırma analistinden en az bilgiyi gerektiren yöntemdir. Tanımlanan her sınıf için, kullanılan her bandın minimum ve maksimum piksel değerleri kullanılmaktadır. Uygulanan karar kuralı basittir. Her bilinmeyen piksel, özellik değeri ile ilgili olduğu paralelyüz içine atanır (Şekil 4.7).



Şekil 4.7 İki boyutta paralelyüz sınıflandırma (Oruç, 2003)

Bu yöntemde iki sıradışı durum oluşabilir: Bir piksel değeri hiçbir paralelyüz içine dahil edilemeyebilir ve bir pikselin birden fazla örtüşen paralelyüz içinde olma olasılığı var olabilir. Her iki durumda da karar kuralını uygulamak zorlaşacaktır. Bu tür çelişkilerin giderilmesi için komplike bir kural da uygulanabilmektedir. Her paralelyüzün merkez noktası ile bilinmeyen piksel arasındaki Euklid uzaklığının hesaplanması ve böylelikle en iyi sınıflandırma için “minimum” kuralı uygulaması çözüm olarak ileri sürülmektedir.

Paralelyüz sınıflandırma yöntemi, uygulaması hızlı ve kolay olmasına rağmen; her bir örnekleme seti için özelliklerin yalnızca minimum ve maksimum değerleri kullanılması nedeniyle, gerçek spektral sınıfların iyi temsil edilememesine yol açmaktadır. Yöntemin diğer negatif yanı ise, sınıf üyeliklerinin öncül olasılıklarının dikkate alınmamasıdır (Oruç, 2003).

### **4.3 Nesne-Tabanlı Sınıflandırma Yaklaşımı**

Nesne-tabanlı sınıflandırma yaklaşımının temel işlem birimi, alışlagelmiş ve klasikte kullanılan piksel-tabanlı görüntü analizinin tersine tekil piksel değil, görüntü segmentleri veya nesnelere aittir. Burada sınıflandırma işlemi görüntü nesnelere üzerinden yapılır. Nesne-tabanlı yaklaşıma bir sebep, çoğu görüntü analizi uygulamasından beklenen sonucun, gerçek dünya nesnelere ait, gerçek sınıflandırma ve gerçek şekillerinde olmasıdır. Bu beklenti alışlagelmiş piksel tabanlı yaklaşımlarla sağlanamaz (Hofmann, 2001a, b, c).

Direkt olarak sunulan nesne yoluyla edinilen görüntü bilgisi, bu görüntü nesnelere ait birbirine bağlanmasıyla oluşur. Halbuki, tekil, komşu piksellerin topolojik ilişkisi üstü kapalı olarak sayısal veride verilir, böylece komşu nesnelere çıkarımı için, komşu piksellerin bir arada açık bir şekilde ele alınması gerekir. Sonuç olarak, topolojik ağ çok farklı çeşitte komşuluk bilgilerinin, etkin bir biçimde yayılımına izin veren büyük bir avantaj sağlar.

Her sınıflandırma işlemi kesin bir ölçüğe bağlıdır. Bu nedenle, görüntü nesnelere ait ortalama çözünürlüğünün istenilen ölçüğe uygunluğu çok önemlidir. Görüntü bilgisi, görüntü nesnelere ait ortalama büyüklüğüne bağlı olarak farklı ölçeklerde sunulabilir. Aynı görüntü daha küçük veya daha büyük objeler olarak segmentlere ayrılabilir ki bu görüntü nesnelere ait tüm bilgileri pratik olarak büyük ölçüde etkiler. Bu nedenle her ölçekte farklı bilgiler çıkarılabilir. Bu bilgileri farklı nesne tabakalarında eş zamanlı olarak farklı ölçekteki görüntü bilgileri gibi sunmak mümkündür. Bu yapıdaki nesne tabakaları birbirleriyle ilişkilendirilerek, birçok ek bilginin çıkarımına katkıda bulunulabilir (Marangoz ve diğere, 2004). Buna, örneğin hiyerarşik ağ düzeniyle ve nesnelere ait bu ağ yapısındaki sunumuyla varılabilir. Komşularının yanında böyle düzenli bir hiyerarşik yapıda nesnelere, alt

ve üst nesnelere de tanılır. Bu, belirli bir alanın, alt nesnelere hassas analizine olanak tanır ve böyle düzenli bir hiyerarşik yapı olmadan bu tip sonuçlara ulaşmak imkansızdır. Bundan başka, alt nesnelere yapısına bağlı olarak, üst nesnelere şekilleri değiştirilebilir.

Tekil pikseller veya tek pikselden oluşan nesnelere, görüntü nesnelere 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 nesnelere çıkarılabilmesidir. 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 ulaşılabilir. Baatz vd. (2005), kavramsal bakış açısıyla, mümkün olan özellikleri aşağıdaki şekilde gruplara ayırmışlardır:

- **Temel Özellikler:** Objelerin fiziksel özellikleri, gerçek dünyanın resmedilmesiyle ve görüntüleme durumuyla belirlenir (basit olarak sensör ve aydınlatma). Bu özellikler rengi, dokuyu ve nesnelere yapısını ifade eder.
- **Topolojik Özellikler:** Nesnelere veya bütün çerçevenin geometrik komşuluğunu ifade eden özelliktir. Örneğin solda, sağda olma veya belirli bir nesneye belirli bir mesafede olma veya görüntü içindeki belirli bir alanda olma.
- **Çevresel Özellikler:** Nesnelere semantik komşuluk ilişkilerini tanımlayan özelliklerdir. Örneğin bir park %100 şehir alanıyla çevrili olmalıdır.

Sınıflandırmanın temelinde, görüntü nesnelere işlenmesi özel yollardan yapılabilir. Bir nesne orman olarak sınıflandırıldığı andan itibaren, örneğin lokal olarak yapay zeka uygulanabilir ve prensipte o andan itibaren bu nesneye 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 nesnelere işlenmesi ve sınıflandırılması arasındaki döngüsel, karşılıklı etkileşimdir. Segmentasyona, ölçeğe ve görüntü nesnelere 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 ayrı uygulama içinde kullanılacak işlem yöntemlerinin doğru seçimi, uygulamaya güç katabilir ve doğru bir segmentasyon ve sınıflandırma yöntemi, kullanıcıya yaklaşımın tüm avantajlarını sağlar (Baatz vd., 2005).

### **4.3.1 Görüntü Yorumlamada Temel Bileşenler**

Burada, nesne-tabanlı sınıflandırmanın en önemli özelliği olan görüntü yorumlamada ölçek ve görüntü semantikleri konuları incelenmiştir.

#### **4.3.1.1 Görüntü İşlemede Yaklaşık Ölçek**

Ölçek, görüntüyü anlamamanın 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 alınır, 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 ölçekte 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 (Baatz vd., 2005). Bu bağ ve ilişkilerin, sadece görüntünün çözünürlüğünü değiştirerek analiz edilemeyeceğini gösterir. Bu husus birçok faydalı bilginin kaybolmasına da neden olabilir.

#### 4.3.1.2 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. Anlamli 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, anlamli 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 deęişen, 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 baęlı 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 işlemi) 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 kontekt bilgisi tipik olarak sadece belirsiz dil kuralları terimlerinde ifade edilir. Örneğin, eğer ağaçlar “neredeysse 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 (Baatz vd., 2005).

### 4.3.2 Segmentasyon

Segmentasyon görüntünün birbirinden farklı alt bölümlere ayrılmasıdır (Baatz ve Schäpe, 2000). 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 nesnelerin 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.

Tabi ki görüntü nesnesi üretimi için birçok çeşit yöntem 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 yöntemleri iki ana gruba ayrılır; bilgi çıkarım yöntemleri (yukarıdan-aşağıya) ve buna karşılık veri çıkarım yöntemleri (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, nesnelerin anlamlarını üstü kapalı olarak verir.

Aşağıdan-yukarıya yaklaşımında, segmentler bir dizi istatistik yöntem ve parametreyle tüm görüntüyü işlemeye bağlı olarak üretilir. Aslında, aşağıdan-yukarıya yöntemi bir çeşit veri çıkarımı veya sıkıştırma olarak görülebilir. Ama, gruplama yöntemlerindeki gibi, başlangıçta üretilen görüntü segmentleri hiçbir anlam ifade etmezler. Daha iyi bir tarifile görüntü nesne primitifleri olarak isimlendirilirler. Üretilen görüntü nesnelerinin ne çeşit gerçek dünya nesnelerini ifade edeceğini belirlemek kullanıcıya bağlıdır. İki yaklaşım arasındaki temel fark;

yukarıdan-aşağıya yöntemleri genellikle lokal sonuçlar verir, çünkü hemen model tanımlamasını karşılayan pikselleri işaretler, oysa aşağıdan-yukarıya yöntemleri 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 yöntem 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. Bunlar iki aşamalı tasarıdan oluşurlar:

- Model aşamasında karakteristik özellikler görüntü dokusu içerisinde ve sınırlar ise uzaysal frekanstan çıkarılır. Bunlar Markov Rassel Field (MRF) modelleri, birlikte meydana gelme matrisleri dalga katsayıları, dalga paketleri ve fraktal gösterimlerdir.
- Optimizasyon aşamasında özellikler uygun kalite ölçütüne kadar azaltılarak homojen segmentler halinde sınıflandırılırlar. Buna çoğu sıklıkta, birkaç çeşit gruplama kıymet fonksiyonlarıyla ulaşılır (Hoffmann vd., 2005).

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 nesnelere 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 yöntem, aslında dışbükey ve bağıl olarak yumuşatılmış nesnelere, hatta hafifçe dokunan nesnelere 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 yöntem istenilen sonuçlara ulaşmayabilir.

#### **4.4 Ecognition Yazılımı Altında Nesne Tabanlı Görüntü Analizi**

Ecognition yazılımı, 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 yöntem 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 nesnelere bu hiyerarşik yapısı içine entegre edilmiş olarak, her nesne

onun bitişik nesnesini, alt ve üst nesnelere tanır. Nesnelere düşeyde 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 nesnelere vektör bilgisi eklenebilir. Böyle yaparak, Ecognition altındaki görüntü nesnelere 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 metodlarıdır. 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 işlemlerle 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. Bunlara 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, nesnelerin şekilleri, sınıflandırmayla ve bilgi tabanlı segmentasyonla geliştirilebilir. Genellikle bu yeni özellikli ve semantik ilişkili, sırasıyla, yeni üretilen özelliklerine göre sınıflandırılan yeni nesnelere yol açar (Baatz vd., 2005).

#### 4.4.1 Görüntü Nesnelerinin Çoklu Segmentasyonu

Segmentasyonun kendisi bir amaç değildir. Görüntü analizinin amacı, arazi örtüsü / arazi kullanım sınıflandırması veya ilgilenilen nesnelerin çıkarımı olabilir. Bununla beraber, ilgilenilen nesneler, Şekil 4.8'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 nesneler, 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. En iyi segmentasyon sonucu, ileri işlemler için optimum bilgi sağlayandır.



Şekil 4.8 Heterojen nesnelere örnek çatılar ve yeşil alan (Baatz vd., 2005)

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 çok yüksek çözünürlüklü görüntüler gibi verilere uyumludur.

Nesne tabanlı görüntü analizinde, optimum ham materyale ulaşmak için, aşağıda belirtilen sebepler, çoklu segmentasyonun Ecognition için geliştirilmesiyle tanımlanmıştır:



- Bir segmentasyon aşaması, görüntü alanlarının optimum ayrımı ve sunumu için yüksek homojenlikte segmentler üretmelidir.
- Her görüntü analizi problemi, spesifik bir veriye bağlı, belirli bir uzaysal ölçekteki verilerle uğraşırken, görüntü nesnelерinin ortalama boyutları, ilgilenilen ölçeye uygun olmalıdır.
- 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.
- Segmentasyon aşaması evrensel olmalı ve çok sayıda farklı görüntü ve probleme uygulanabilmelidir.
- Segmentasyon sonuçları çoğaltılabilmelidir.
- 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 nesneleri ve görüntü nesnelерinin ortalama boyutları için, heterojenliğin tanımında verilen, olası kriterler:

- Görüntü nesnelерinin ortalama heterojenliđi minimum olmalıdır.
- Görüntü nesnelерinin ađırlıklı ortalama heterojenliđi minimum olmalıdır.

Çoklu segmentasyonun geliştirilmesi için, öncelik ikinci kritere verilmelidir. Bu kriter anlamı deđiştirilmeden řu şekilde formülize edilebilir:


- Piksellerin ortalama heterojenliđi minimum olmalıdır, hangi görüntü nesnesine aitse, onun heterojenliđi her piksele atanır.

İkinci formül, bir görüntünün her parçasının, segmentasyon sonuçlarının heterojenliđinin deđerlendirilmesine eřit katkıda bulunması gerektiđini vurgular.

Bu kavramsallařtırmada bir segmentasyon aşamasının sonucu, görüntü nesne primitiflerinin, verilen bir problemle ilgili olarak, gerçek dünyanın görüntü nesnelерine ilk yaklařımıř gibi ele alınmasını sađlar. Bununla birlikte bu yaklařım, çok sayıda probleme uygulanabilen ve deđiřik tiplerdeki dokulu görüntü verisi üzerinde bile çalıřabilen yüksek kaliteli evrensel bir çözüm olmalıdır.

#### 4.4.2 Segmentasyonun Uygulanması

Çoklu segmentasyon ařađıdan-yukarıya, bir piksellik nesnelерle bařlayan, alan birleřtirme tekniđidir (řekil 4.9). Çok sayıda alt adımda, küçük görüntü nesneleri, büyük olanlara birleřtirilir (Burnett ve Blaschke, 2003). Bu çift mantıklı gruplandırma ile altta yatan optimizasyon iřlemi, sonuç görüntü nesnelерinin ađırlıklı heterojenliđi  $nh'$  ı minimuma indirir. Burada  $n$  segmentin boyutu ve  $h$  heterojenliđin kendine özgü tanımıdır. Her adımda, bitiřik görüntü nesne çifti, tanımlanmıř heterojenliđin en küçük artışına göre birleřtirilir. En küçük büyüme deđerleri, ölçek parametresine göre belirlenen sınırı ařarsa, iřlem durur. Böyle yaparak, çoklu segmentasyon, lokal optimizasyon adımı olur.



řekil 4.9 Üç ayrı katmanda oluřturulan görüntü segmentasyonu sonrasındaki görüntü nesnelерinin hiyerarřik ađ yapısı (Karakıř vd., 2005)

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.

#### 4.4.2.1 Heterojenlik Kriterinin Belirlenmesi

Ecognition'da spektral veya renk heterojenliğinin tanımlanması için, her tabakanın ağırlığı  $w_c$  ile her tabakadaki spektral değerlerin ağırlıklı standart sapmasının çarpımının toplamı kullanılır:

$$h = \sum_c w_c \sigma_c \quad (4.1)$$

Birçok durumda, spektral heterojenliğin özel olarak minimize edilmesi, dallanmış segmentlere veya fraktal şekilli sınır çizgilerine sahip görüntü nesnelere yol açar (Şekil 4.10). 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 4.10 Düşük heterojenlik sonucu geometrik anlamda bozuk şekillerin oluşması  
(Baatz vd., 2005)

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

$$h = \frac{l}{\sqrt{n}} \quad (4.2)$$

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

$$h = \frac{l}{b} \quad (4.3)$$

Bu heterojenlik tanımının uygulanması, sonuç görüntü nesnelerinin şekillerinin yumuşaklığını optimize eder. Şekil 4.11, 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 4.11 Optimize edilmiş heterojenlikle daha düzgün şekilli yapıların oluşması (Baatz vd., 2005)

Heterojenlik için bu üç kriter karıştırılmış bir halde uygulanabilir. (4.2) ve (4.3) formülleri ek olarak genel bir şekil kriterine özetlenir. Özellikle radar gibi yoğun dokulu verilerde, şekil kriterinin düzgün seçilmesi, nesnelerin fraktal şekillenmesini iptal etmeye yardım 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.

$$f = w.h_{renk} + (1 - w).h_{şekil} \quad (4.4)$$

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.

$$h_{renk} = \sum_c w_c \cdot (n_{brlş} \cdot \sigma^{brlş} - (n_{nesne1} \cdot \sigma^{nesne1} + n_{nesne2} \cdot \sigma^{nesne2})) \quad (4.5)$$

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

$$h_{şekil} = w_{btm} \cdot h_{btm} + (1 - w_{btm}) \cdot h_{ymş} \quad (4.6)$$

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:

$$h_{ymş} = n_{brlş} \cdot \frac{l_{brlş}}{b_{brlş}} - (n_{nesne1} \cdot \frac{l_{nesne1}}{b_{nesne1}} + n_{nesne2} \cdot \frac{l_{nesne2}}{b_{nesne2}}) \quad (4.7)$$

$$h_{btm} = n_{brlş} \cdot \frac{l_{brlş}}{\sqrt{n_{brlş}}} - (n_{nesne1} \cdot \frac{l_{nesne1}}{\sqrt{n_{nesne1}}} + n_{nesne2} \cdot \frac{l_{nesne2}}{\sqrt{n_{nesne2}}}) \quad (4.8)$$


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 yol açar.

#### 4.4.3 Alt Nesnelerin Çizgi Analizi Amaçlı Segmentasyonu

Ecognition, görüntü nesnelere nesne tabanlı çizgisel analizi için değişik özellikler sunar. Bu amaç için, “normal” segmentasyon modu, çoklu segmentasyon işlemi 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 nesnelerin, aynı üst objenin parçası olmayan komşu piksellere olan en çok ilişkili sınır uzunluğunu belirler.


Şekil 4.12’deki gibi görüntü nesnelere analizi için, özel görüntü nesne düzeyi alt segmentlere ayrılabilir. Sonuçlar bütünlük arz eden alt nesnelere ki bu nesnelere 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 4.12 Alt segmentlere ayrılmış nesne örneği (Baatz vd., 2005)

#### 4.4.4 Görüntü Nesnelere Hiyerarşik Ağ Yapısı

Ecognition’da farklı uzaysal çözünürlükteki görüntü bilgilerinin eş zamanlı sunumunu sağlayan, görüntü nesnelere hiyerarşik ağ yapısını kurarken farklı segmentasyon teknikleri kullanılabilir. Görüntü nesnelere birbiriyle bağlanmıştır, böylece, her görüntü nesnesi kendi kontekstini (komşuluk), üst nesnesini, alt nesnesini “tanır” (Şekil 4.13). Böylece nesnelere arasındaki ilişkiyi tanımlamak mümkün olabilir. Örneğin “Orman a sınır komşuluğu” ve bu çeşit lokal kontekst bilgisini kullanmak gibi.



Şekil 4.13 Hiyerarşik ağ yapısı (Baatz vd., 2005)

Bu hiyerarşik ağ topolojik olarak sınırlıdır, örneğin bir üst nesnenin sınırı, alt nesnelere ait alanların sınırlarıyla uyumludur. Belirli bir görüntü nesnesiyle gösterilen bir alan, alt nesnelere ait alanların toplamıyla tanımlanır. Teknik olarak, Ecognition’da 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 kadar yapılabilir ve eğer bitişik görüntü nesnelere farklı üst nesnelere ait alt nesnelere ise birleştirilemezler. Ecognition’da, görüntü nesnelere uzaysal olarak istikrarlı şekilde tanımlanırlar.

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

- Farklı ölçeklerdeki yapılar eş zamanlı sunulabilir ve böylece birbirleriyle olan ilişkilerine göre sınıflandırılabilirler.
- 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 ait bir araya gelmesi ile analiz edilebilir. Bu teknik mantığıyla, değişik veri tipleri birbirleriyle olan ilişkileriyle analiz edilebilirler.
- Görüntü nesnelere ait şekilleri alt nesnelere yeniden gruplandırılmasına bağlı olarak düzeltilir.

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:

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

Görüntü nesnelere başka bir hiyerarşik ağ yapısı uygulaması, görüntü nesnelere, ayrı ayrı üst nesnelere göre sınıflandırmaktır (Baatz vd., 2005).

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:


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

#### 4.4.5 Ecognition'da 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 4.14a) veya hafifçe kısaltılmış poligonlar (Şekil 4.14b) 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 4.14c). Bu poligonlar şekil poligonu olarak ifade edilir.





Şekil 4.14 Ecognition altında poligonların oluşturulması (Baatz vd., 2005)

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 (Ecognition’da bu iki başlangıç noktası topolojik noktalardır, Şekil 4.14c’de sarı işaretli gösterilmiştir) algoritma, iki uç noktayı birleştiren doğru üzerinde düşeyde poligona olan en uzun mesafedeki noktayı bulur (Şekil 4.15a). Bulunan bu noktada poligon iki kısa doğruyla gösterilir (Şekil 4.15b). Bu işlem hesaplanan dik mesafe, verilen bir sınır değerinden küçük oluncaya kadar devam ettirilir (Şekil 4.15c). Diğer bir tabirle sınır değer, poligonun altta yatan rasterdan olan en büyük sapmayı tanımlar. Ecognition’da bu sınır değeri “Poligon Oluştur” iletişim kutusunda piksel birimi cinsinden tanımlanabilir.



Şekil 4.15 Douglas Peucker Algoritmasının poligonlara uygulanması (Baatz vd., 2005)

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.

#### 4.4.6 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. Bu yaklaşımda görüntü nesnelerinin analizi için, bulanık sınıflandırma aşağıda ifade edilen özelliklere sahiptir;

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

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 sınıflandırmadır.

Bir bulanıklık kuralı tek bir durum içerebilir veya bir nesnenin bir sınıfa tam olarak atanması için birçok durumun kombinasyonundan meydana gelebilir. Burada durumlar sınıf tanımlamalarının içine yerleştirilen eşitliklerle tanımlanır. Eşitlikler üyelik fonksiyonları, sınıflara benzerlik veya en yakın komşuluk olabilir. Bu şekilde nesnelerin 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 ilgili 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 direkt rol oynar. Örneğin sinüs eğrisine benzer yapıda bir eğri kullanmak daha yumuşak geçişli sonuçlar verirken, dikdörtgenel fonksiyonlar kullanmak daha sert ve geçişe izin vermeyen sonuçlar verir. Şekil 4.16'de nesne-tabanlı görüntü yazılımı olan Ecognition altında bu fonksiyonların nasıl gösterildiği verilmektedir.



Şekil 4.16 Ecognition altında kullanılan fonksiyon çeşitleri (Baatz vd., 2005)

Bundan sonra yapılması gereken sınıf atamalarının yapılabilmesi için, o sınıf içine dahil edilmesi gereken nesnelere için uygun öznitelikleri belirlemektir. Bu öznitelikler bazı üyelik fonksiyonlarıyla 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. Böylece uygun öznitelik ve uygun fonksiyon şeklinin seçilmesiyle sonuç sınıflandırmaya ulaşılmaya çalışılır (Baatz vd., 2005).

## 5. MEVCUT VERİLER, ÜRETİLEN VEKTÖR ÜRÜNLER ve MEVCUT REFERANS VEKTÖR HARİTALAR

Bu bölümde, Zonguldak test alanına ait mevcut ve üretilen verilerden bahsedilecektir. Bu veriler aşağıda sıralanmıştır:

- 1m ve altı YÖA değerine sahip olan yüksek çözünürlüklü uydu görüntüleri,
- Görüntülerin düzeltilmesi için kullanılan test alanına uygun şekilde dağılmış YKN verileri,
- Orto-görüntülerin üretilmesin için kullanılan ilgili alanın SYM verileri,
- İlgili alana ait üretilen ve referans veri olarak kullanılacak 1/5000 ölçekli vektör haritalar (2004 yılı sonu üretilen ortofoto ve vektör haritalar),
- Kullanılan uydu görüntülerinin ekran üzerinden elle vektörleştirme sonuçları.

### 5.1 Kullanılan Uydu Görüntüleri

Uygulamada kullanılan görüntü verileri, 1m YÖA değerine sahip olan yüksek çözünürlüklü pan-sharp IKONOS ve 0.6m YÖA değerine sahip olan yüksek çözünürlüklü pan-sharp QuickBird uydu görüntüleridir. Bu iki görüntünün özellikleri detaylı olarak incelenmiş ve aşağıda sunulmuştur. Görüntülerin geometrik düzeltilmesi ve zenginleştirilmesi açısından yapılan analizler çalışmanın uygulama bölümünde anlatılmıştır.

#### 5.1.1 IKONOS Uydusu ve Görüntü Verileri

IKONOS görüntü verilerinden, multispektral bantlar için 4m YÖA değerine sahip, pankromatik bant içinse 1m YÖA değerine sahip görüntüler elde edilmektedir [1]. Bu görüntülerin metadata (başlık) dosyalarındaki önemli özellikleri Çizelge 5.1’de verilmiştir.

Çizelge 5.1 IKONOS görüntülerinin özellikleri

ÖZELLİKLER	2002 YILI GÖRÜNTÜSÜ	2008 YILI GÖRÜNTÜSÜ
<b>Gün, Zaman</b>	02/10/2002 - 08:59	06/03/2008 – 08:44
<b>Nominal azimut (derece)</b>	10.5023	44.496
<b>Nominal yükseklik açısı (derece)</b>	63.2446	61.386
<b>Güneş azimutu (derece)</b>	166.2923	138.237
<b>Güneş yükseklik açısı (derece)</b>	41.5399	66.494
<b>Nadir açısı (derece)</b>	26.7554	28.614
<b>Görüntü boyutu (piksel: satır - sütun)</b>	11,004 x 11,000	13,384 x 12,340
<b>Referans yüksekliği (m)</b>	208.04	314.08

Ortalama 450m yüksekliğe sahip ve yaklaşık 11×11 km'lik bir alanı kaplayan IKONOS görüntülerinin üst kısımlarında Karadeniz sahili uzanmakta ve bu görüntünün diğer kısımlarında Zonguldak'ın merkezi yerleşimi bulunmaktadır (Şekil 5.1).



a: 2002 yılı IKONOS görüntüsü



b: 2008 yılı IKONOS görüntüsü

Şekil 5.1 Zonguldak bölgesine ait IKONOS görüntüleri

Tez çalışmasının uygulama bölümünde, görüntünün içeriğinden çıkarılabilecek tüm sınıfları içerecek bir bölge çalışma için kesilmiş ve bu bölge çalışmaya esas olmuştur. Şekil 5.2'de



gösterilen bu bölgenin en büyük karakteristiği, çok değişken topoğrafyaya sahip olması ve Zonguldak'taki yapılaşmanın en fazla olduğu bölge olmasıdır. Ayrıca bu bölgede, otomatik olarak çıkarılması istenen kültürel detayların yoğunlukta olması da çalışmanın amacı açısından önem taşımaktadır. 2002 ve 2008'de çekilen görüntülerin tez çalışmasında kullanılacak bölümleri Şekil 5.2'de gösterilmiştir.



a: 2002 yılı IKONOS görüntüsü



b: 2008 yılı IKONOS görüntüsü

Şekil 5.2 Test alanına ait pan-sharp IKONOS görüntüleri

### 5.1.2 QuickBird Uydusu ve Görüntü Verisi

Mayıs 2004'te çekilen ve yaklaşık 15×15 km'lik bir alanı kaplayan bu uydu görüntüsü, DigitalGlobe isimli özel bir A.B.D. şirketi tarafından çalıştırılan QuickBird uydusuna aittir. Bu görüntünün metadata (başlık) dosyalarındaki önemli özellikleri Çizelge 5.2'de verilmiştir.

Çizelge 5.2 Çalışma alanına ait QuickBird uydu görüntüsünün özellikleri

ÖZELLİKLER	GÖRÜNTÜ
Gün, Zaman	23/05/2004, 08:39:55
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
Görüntü boyutu (piksel: satır - sütun)	24,572 x 25,500
Referans yüksekliği (m)	265.66

QuickBird verisinden, multispektral bantlar için 2.4m YÖA değerine sahip, pankromatik bant içinse 0.6m YÖA değerine sahip görüntüler elde edilmektedir [2]. Aynı IKONOS görüntüsünde olduğu gibi Zonguldak Bölgesini kaplayan bu görüntü, Şekil 5.3'de verilmiştir.



Şekil 5.3 Zonguldak bölgesine ait QuickBird görüntüsü

Önceki görüntüler gibi QuickBird uydu görüntüsü de, test alanını kaplayacak şekilde kesilerek, aynı test alanında çalışma imkanı sağlanmıştır (Şekil 5.4).




Şekil 5.4 Test alanına ait pan-sharp QuickBird görüntüsü



## 5.2 Test Alanına Ait Mevcut ve Üretilen Diğer Vektör Ürünleri

Uygulama kapsamında, test alanının mevcut 1/5000 ölçekli sayısal topoğrafik haritası referans vektör harita olarak kullanılacağından dolayı, vektör harita üzerindeki kentsel ayrıntılar olan yol ve bina yapıları dışındaki tüm detay tabakaları kapatılmış ve ilgili katmanlar ortaya çıkartılmıştır (Şekil 5.5) (Marangoz, vd., 2006 ve 2007).




Şekil 5.5 1/5000 ölçekli referans vektör haritadaki bina ve yol yapıları

Bunun yanında, diğer detay çıkarım yöntemlerinden olan görüntünün ekran üzerinden elle vektörleştirilmesi sonucunda, bina ve yol yapıları için elde edilen vektör bilgilerinin görüntüler üstüne bindirilmiş gösterimleri Şekil 5.6, 5.8 ve 5.10'de verilmiş, ayrıca NetCAD v5.0 yazılımında görüntü tabakası kapatılarak, Şekil 5.7, 5.9 ve 5.11' de yalnızca vektör ürünleri ayrı ayrı gösterilmiştir.



Şekil 5.6 2002 yılı IKONOS görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları






Şekil 5.7 2002 yılı IKONOS görüntüsünden elle vektörleştirme sonucu elde edilen ürün




Şekil 5.8 2008 IKONOS görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları



Şekil 5.9 2008 yılı IKONOS görüntüsünden elle vektörleştirme sonucu elde edilen ürün



Şekil 5.10 2004 yılı QuickBird görüntüsü üzerine bindirilmiş elle vektörleştirme sonuçları (Marangoz vd., 2007)



Şekil 5.11 2004 yılı QuickBird görüntüsünden elle vektörleştirme sonucu elde edilen ürün (Marangoz vd., 2007)

Şekil 5.7, 5.9 ve 5.11’de gösterilen vektör ürünler, NetCAD yazılımında ilgili görüntülerin açılması ve ekran üzerinden elle vektörleştirilmesiyle elde edilmiştir. Bu işlemdeki en önemli husus, vektörleştirmeyi yapan operatörün tecrübeli bir operatör olup olmadığıdır. Çünkü bu vektörleştirme işlemindeki geçen süre, uygulamanın genel tamamlanma zamanını büyük ölçüde etkileyecektir. Örneğin bu çalışmadaki gibi tecrübeli bir operatör, ilgili alandaki vektörleştirmeyi her bir görüntüyü birer günde tamamlamıştır. Fakat tecrübesiz bir operatör bu işlemi üçer günde tamamlayabilmektedir.

## 6. UYGULAMA

Bu bölümde, çalışma kapsamında kullanılan yüksek çözünürlüklü görüntülerin geometrik düzeltilmesi, zenginleştirilmesi, elde edilen bu sonuç görüntüler üzerinden kentsel ayrıntılar olan yol ve binaların piksel- tabanlı ve nesne-tabanlı sınıflandırma teknikleriyle otomatik olarak belirlenmesi amaçlanmıştır. Ayrıca, elde edilen sınıflandırma sonuçları vektör ürün haline getirildikten sonra bir CBS ortamına aktarılıp, test alanına ait diğer mevcut ve üretilmiş ürünlerle bütünleştirilmesine yönelik analiz ve sorgulamalar yapılmıştır.

Bu amaçla, test alanının mevcut 1/5000 ölçekli sayısal topoğrafik haritası referans vektör harita olarak kullanılmış, diğer bir detay çıkarım yöntemlerinden olan görüntülerin ekran üzerinden elle vektörleştirilmesi ile üretilen vektör ürünleri de karşılaştırma amacıyla uygulama bölümünde analiz edilmiştir.

Böylelikle, ele alınan yüksek çözünürlüklü uydu görüntüleri üzerinden kentsel ayrıntıların hangi yöntemle ne kadar çıkarılabildiğine ilişkin kullanılan yazılımlar ve işlem adımları detaylı bir şekilde anlatılmaya çalışılmıştır.

### 6.1 Test Alanı

Zonguldak test alanı; Türkiye'nin Kuzeybatısında yer alan, Kuzeyinde Karadeniz ve Güneyinde ormanlık alanlar arasında dar bir sahil şeridine kurulmuş bir endüstri şehridir. Bölge; bir 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 800m yüksekliğe varan sık ormanlarla kaplı dağlarla çevrilidir. Uygulamada görüntülerin tümüyle çalışılmamış, görüntünün içeriğinden çıkarılabilecek tüm sınıfları içerecek bir bölge çalışma için kesilmiş ve bu bölge çalışmaya esas olmuştur.

Şekil 6.1'de gösterilen bu test alanının en büyük karakteristiği, çok değişken topoğrafyaya sahip olması ve Zonguldak'taki yapılaşmanın en fazla olduğu bölge olmasıdır. Ayrıca bu alanda, otomatik olarak çıkarılması istenen kentsel detaylar olan yol ve bina yapılarının yoğun olması da çalışmanın amacı açısından önem taşımaktadır. Şekil 6.1'deki görüntüye detaylı olarak bakıldığında, bina detaylarının çatı yapıları farklı olduğu ve bazı yol detaylarının da bina gölgesi altında kaldığı görülmektedir.





Şekil 6.1 Test alanı (Pan-sharp QuickBird görüntüsü)

## 6.2 Kullanılan Yazılımlar

Uygulamada analiz edilen 2002 ve 2008 yılına ait IKONOS görüntüleri ile 2004 yılına ait QuickBird görüntüsünün geometrik düzeltilmesi ve zenginleştirilmesi için PCI Geomatica yazılımı kullanılmıştır. Elde edilen düzeltilmiş ve zenginleştirilmiş olan görüntüler daha sonra değişik Computer Aided Design (CAD) yazılımlarında, piksel-tabanlı sınıflandırma yaklaşımını kullanan PCI yazılımında ve nesne-tabanlı sınıflandırma yaklaşımını kullanan Ecognition yazılımında değerlendirilmiştir. En son olarak, referans vektör haritalar ve elde edilen detay çıkarımlarının karşılaştırmalı analizleri MapInfo Professional v7.0 yazılımı kullanılarak yapılmıştır.

İşlemlerde öncelikle görüntülerin kullanıma hazır hale getirilmesi, sonrasında bu görüntülerden istenen kentsel ayrıntıların çıkarılması aşamaları yer alır. Böylelikle görüntü, sırasıyla aşağıda anlatılan işlem adımlarından geçmektedir:

- PCI Geomatica OrthoEngine V9.1.4 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.


- İkinci aşamada yine aynı yazılımın, Dr. Yun Zhang tarafından geliştirilmiş algoritması olan “Pan-sharp” modülü kullanılmıştır. Bu yaklaşım, görüntülerin yüksek uzaysal çözünürlüğü ile sensörlerin spektral karakteristiklerinden yararlanmayı sağlar. Bu şekilde yüksek çözünürlüklü renkli uydu görüntüsü üzerinden daha ayrıntılı detay çıkarımı mümkün hale getirilmektedir.
- Son aşama ise, görüntü üzerinden elle vektörleştirme, otomatik piksel-tabanlı ve nesne-tabanlı sınıflandırma yaklaşımlarıyla istenen detayların çıkartılarak karşılaştırmalı analizlerin yapılmasıdır. Ekran üzerinden elle vektörleştirme yöntemi için farklı CAD yazılımları denenmiştir. Her yazılımın kendisine göre uygulama kolaylıkları mevcuttur. Ancak hangisinin kullanıldığı önem arz etmemektedir. Sonuçta elde edilen vektörler yapı itibariyle birbirinin aynısıdır.
- Piksel-tabanlı sınıflandırma yaklaşımında PCI Geomatica Focus modülü, tez çalışmasına konu olan nesne-tabanlı sınıflandırma yaklaşımında ise Ecognition v4.0.6 yazılımı kullanılmıştır.
- Referans vektör haritalar, görüntüden elle vektörleştirme sonuçları ve nesne-tabanlı otomatik detay çıkarım ürünlerinin karşılaştırmalı analizleri, bir bilgi sistemi yazılımı olan MapInfo Professional v7.0 yazılımı kullanılarak yapılmıştır.

### 6.3 Görüntülerin Geometrik Olarak Düzeltilmesi

Çalışmada kullanılan görüntüler, uygulamaya başlanmadan önce düzenli bir şekilde yayılmış uygun YKN (yer kontrol noktası) seçimi için analiz edilmiştir. Bu belirleme sonucunda, tüm görüntülerde farklı sayıda YKN GPS ölçmeleri ile yaklaşık 3cm doğrulukla ölçülmüştür.

Bu noktaların görüntü üzerinde çok iyi görülebilir olmasından dolayı, noktalar, bina köşeleri, kavşaklar vb. olarak seçilmiştir. Görüntülerin yüksek çözünürlüğünden dolayı, birçok kentsel detaylar tanınmış ve YKN olarak kullanılabilmiştir. YKN'nın görüntü koordinatlarının ölçülmesi, PCI Geomatica-Orto Engine yazılımının YKN Ölçme Arayüzü (GCP Collection Tool) ile gerçekleştirilmiştir (Büyüksalih, 2003).

Görüntüler için kullanılan farklı YKN verileri ile hem pankromatik, hem de renkli bantları için yarım pikselin altında doğruluklar elde edilmiştir. Şekil 6.2'de QuickBird görüntüsü için görüntü üzerine dağılmış olan noktaların görünümü örnek olarak verilmiştir.




Şekil 6.2 Test alanı üzerinde YKN'lerin dağılımı

Bundan sonra yapılan işlem, görüntülerin orto hale getirilmesidir. Bunun için görüntüler için birkaç farklı SYM kullanılmıştır. Kullanılan SYM'ler, 1/25000 ve 1/5000 ölçekli ülke haritalarından üretilmiş SYM'lerdir.

#### 6.4 Görüntülerin Zenginleştirilmesi

Yukarıdaki işlemler sonucunda görüntüler her hangi bir uygulamaya altlık ihtiyacını karşılayabilecek düzeye gelmiştir. Ancak görüntülerin zenginleştirilerek daha iyi sonuçlar vermesi için daha önceki bölümlerde de belirtildiği gibi “pan-sharp” algoritması kullanılması, uygulama sonuçlarının başarılı olması açısından yararlıdır. PCI Geomatica V9.1.4 yazılımındaki pan-sharp algoritması ile görüntüler, renkli görüntüden renk bilgisini ve pankromatik görüntüden de yüksek bilgi içeriğini alarak, renkli ve yüksek çözünürlüklü görüntüler olarak üretilmektedir (Şekil 6.3).



Şekil 6.3 Test alanının pan-sharp QuickBird görüntüsünün elde edilmesi

Bu aşamada, zenginleştirilen görüntülerin tüm düzeltmeleri yapılmış haldedir. Bundan sonra, görüntü üzerinden elle vektörleştirme ve nesne-tabanlı sınıflandırma yaklaşımları kullanılarak, istenen kentsel ayrıntıların çıkarılması işlemleri yapılabilecektir.

### 6.5 Görüntülerin Ekran Üzerinden Elle Vektörleştirilmesi

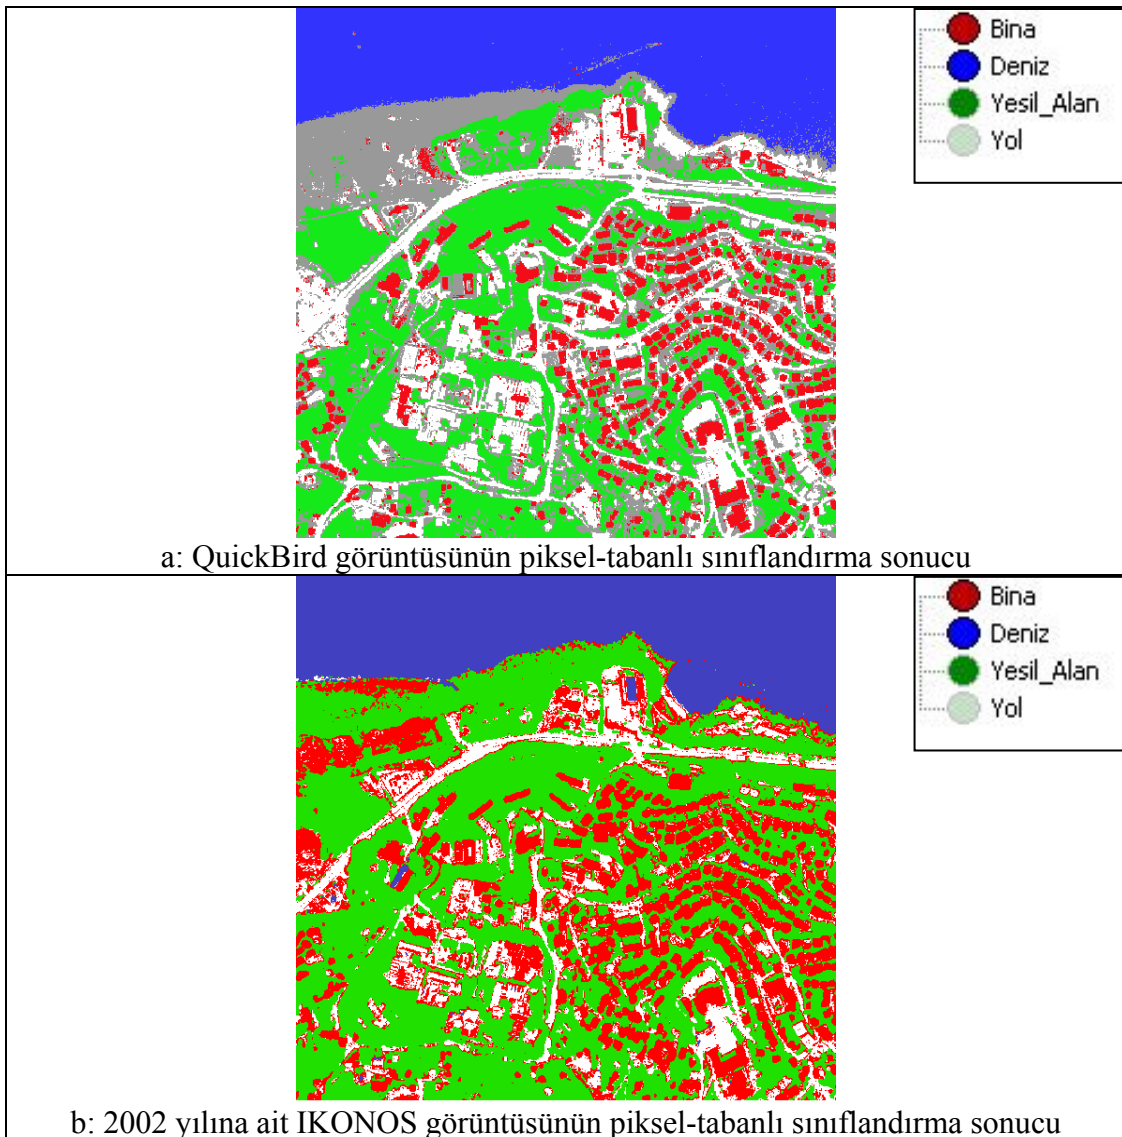
Görüntüler bir CAD yazılımı üzerinde açılmış ve ekran üzerinden elle sayısallaştırma uygulaması ile istenen bina ve yol detayları vektör hale getirilmiştir. Burada her bir detay grubu için farklı katmanlar oluşturulmuştur. Sonuç vektör ürünlerin birbirinden farklı olmadığı için hangi programda vektörleştirildiği bu noktada önemini yitirmektedir. Görüntüler üzerinden elde edilen bu vektörel ürünler önceki bölümdeki Şekil 5.7, 5.9 ve 5.11'de verilmiştir.

## 6.6 Görüntülerin Farklı Sınıflandırma Yaklaşımlarıyla Değerlendirilmesi


Görüntüler bu aşamada piksel-tabanlı ve nesne-tabanlı sınıflandırma yaklaşımlarıyla değerlendirilmiş, sınıflandırma sonuç ürünlerinin doğruluk analizleri yapılmış ve görüntülerdeki bina ve yol yapılarının sınıflandırılmış sonuçları gösterilmiştir.

### 6.6.1 Piksel-Tabanlı Sınıflandırma Sonucu Elde Edilen Ürünler

Çalışmanın bu aşamasında, uygulamalarda genelde en çok kullanılan ve gerçeğe en yakın sonuçlar veren Maksimum Benzerlik yöntemi kullanılmıştır. Bu yöntem, dördüncü bölümde de bahsedildiği gibi, görüntüdeki belirlenen sınıflar için eş olasılık eğrilerinin tanımlanmasına ve sınıflandırılacak piksellerin üyelik olasılığı en yüksek olan sınıfa atanması ilkesine dayanmaktadır. PCI Geomatica yazılımı kullanılarak, görüntülerden elde edilen kontrollü piksel-tabanlı sınıflandırma sonuçları Şekil 6.4 a, 6.4b ve 6.4c’ gösterilmiştir.







Şekil 6.4 Kullanılan görüntülerin piksel-tabanlı sınıflandırma sonuçları

### 6.6.1.1 Sonuç Ürünlerin Doğruluk Analizleri

Uzaktan algılamada sınıflandırma doğruluğu, seçilen referans bilgiler ve sınıflandırılmış veri arasındaki uyuşmanın belirlenmesi anlamına gelmektedir. Bu amaçla, piksel-tabanlı sınıflandırma sonucunda doğruluk değerlendirmesi için çalışma alanının görüntüleri üzerinde rastgele 50'şer piksel seçilmiş ve her bir pikselin yer gerçeği verileri ile uyuşumu analiz edilmiştir. Bu değerlendirme sonucunda Maksimum Benzerlik yöntemini kullanarak yapılan piksel-tabanlı sınıflandırma sonuçları Çizelge 6.1'de verilmiştir.

Çizelge 6.1 Piksel-tabanlı sınıflandırmalar için genel doğruluk ve Kappa değerleri

Doğruluk Değerlendirmesi	QuickBird	2002 yılına ait IKONOS	2008 yılına ait IKONOS
<b>Genel Doğruluk (%)</b>	72.65	69.21	70.12
<b>Kappa</b>	0.610	0.566	0.582

Burada genel doğruluklarının sonuçlarına en büyük etken, görüntüden seçilen sınıflara ait piksellerin fazla sayıda seçilmesi ve bunların yer gerçeği verileri ile uyuşumunun çok iyi değerlendirilmesi gerekmektedir.


### 6.6.2 Nesne-Tabanlı Sınıflandırma Sonucu Elde Edilen Ürünler

Nesne-tabanlı sınıflandırma yaklaşımı, dördüncü bölümde de bahsedildiği üzere; görüntüdeki yapıyı, dokuları ve spektral bilgileri birlikte dikkate alan bir yöntemdir. 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 ayarlanmaktadır. Bu yöntemle, sadece tekil pikseller sınıflandırılmakla kalmaz, ayrıca bir önceki segmentasyon basamağı sırasında homojen görüntü nesnelere de ortaya çıkar. Bu segmentasyon değişik çözünürlüklerde yapılabılırken, nesne kategorilerinin katmanlarını ayırt etmeye de izin verir.

Çalışmanın bu aşamasında Ecognition v4.0.6 yazılımı kullanılarak, görüntülerdeki bina ve yol yapılarının nesne-tabanlı sınıflandırmaları yapılmıştır. 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 gelmektedir.

Bu bağlamda yazılım altında her görüntü için yeni birer 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 eklenebilmektedir. Bu altlıklar vektör veya raster formatta olabilir. Şekil 6.5’de QuickBird görüntüsü için Ecognition yazılımında proje tanımlanma penceresi gösterilmektedir.



Şekil 6.5 Ecognition altında projenin tanımlanması ve görüntünün açılması

Bundan sonraki aşama sınıflandırmaya esas olacak görüntü segmentlerinin oluşturulmasıdır. Bunun için her bir görüntü için uygun segmentasyon sonuçlarının oluşturulması için yazılıma girilen segmentasyon parametreleri belirlenmiştir.


Uygun segmentasyon sonuçları elde edildikten sonra, görüntüden elde edilmesi istenen ayrıntılar için detay sınıfları oluşturulmaktadır. Bu bağlamda, tüm görüntülerde ilgili sınıflar oluşturulmuş ve bu sınıfların içine dahil olacak segmentler için uygun üyelik fonksiyonları belirlenmiştir. Bunun ardından sınıflandırma işlemleri başlatılmış ve her bir görüntü için nesne-tabanlı sınıflandırma sonuçları elde edilmiştir. Bahsi geçen görüntülere ait segmentasyon parametre değerleri, üyelik fonksiyonları, sınıflandırma sonuçları ve bunlara ilişkin doğruluk analizleri de aynı şekilde aşağıdaki ilgili başlıklarda verilmiştir.

### 6.6.2.1 QuickBird Uydu Görüntüsünden Nesne-Tabanlı Detay Çıkarımları


Sınıflandırmaya esas olan görüntünün uygun segmentasyon parametreleri belirlenerek Çizelge 6.2’de verilmiş ve bu segmentasyon sonucunda oluşan segmentasyon görüntüleri Şekil 6.6’de gösterilmiştir.

Çizelge 6.2 QuickBird görüntüsü için segmentasyon parametreleri


Katman	1	2	3	4	5	6
Ölçek par.	10	20	30	35	60	30
Renk	0.5	0.7	0.3	0.5	0.5	Spektral Farklılık
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



c




d



e

Şekil 6.6 QuickBird görüntüsü için beş değişik ölçek parametresi kullanılarak yapılan görüntü segmentasyonu (Ölçek parametresi :  $a = 10$ ,  $b = 20$ ,  $c = 30$ ,  $d = 35$  ve  $e = 60$ )

Segmentasyon aşaması sonrasında, oluşturulan sınıflar içerisinde birçok üyelik fonksiyonu tanımlanmış ve bunların fonksiyon aralıkları yazılıma girilmiştir. Şekil 6.7’de örnek olarak “bina” sınıfı için girilmiş iki özellik ve fonksiyon tanımlaması gösterilmektedir.



a: Üçüncü banda ait yansıma değerlerini kullanan dikdörtgensel fonksiyon

b: Dikdörtgensel şekil uyuşumunu kullanan dikdörtgensel fonksiyon)


Şekil 6.7 Sınıf atamaları için kullanılan özellikler ve bunlara ait fonksiyonlar

Şekil 6.7’den 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 dikdörtgensel bir fonksiyon kullanılmıştır. Bunun anlamı bu şartı sağlayan nesnelerin %100 bu sınıfa dahil olacaktır. Bunun dışında diğer nesnelerle komşuluk ilişkileri ve daha birçok kriter kullanılmıştır. Ayrıca beşinci katman sütununa



karşılık gelen segmentasyon katmanı ile deniz gibi büyük yapılar tek bir segment yapısında elle sınıflandırılmış ve diğer alt katmanlara hiyerarşik olarak yansıtılmıştır. Bu anlamda “sınıf bağımlı” seçeneği seçilerek sınıflandırma yapılmıştır. Bunun anlamı daha büyük ölçek parametresiyle oluşturulan katmanlardan veya o sınıf içinde daha öncesinde veya o sınıflandırma anında ilk aşamada sınıflandırmaya cevap vermiş olan nesnelere ilgili durum analizlerinin, sınıflandırma işlemine katılmasıdır.

Yapılan tüm işlemlerin sonucunda, beşinci segmentasyon katmanı esas alınarak QuickBird görüntüsü sınıflandırılmış ve test alanındaki bina, yol yapıları ile sadece gösterim için deniz, yeşil alan ve gibi detaylar otomatik olarak çıkartılmıştır (Şekil 6.8a). Çalışmaya esas olan bina ve yol yapılarının da ayrı ayrı sınıflandırma sonuçları Şekil 6.8b ve Şekil 6.8c’de verilmiştir.



Şekil 6.8 QuickBird uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları

### 6.6.2.1.1 Sonuç Ürünlerin Doğruluk Analizleri

Ecognition yazılımında QuickBird görüntüsü için doğruluk değerlendirmesini yapmak üzere, 100 adet bina için ve 50 adet yol yapıları için örnek nesnelere seçilmiştir. Sonrasında bu sınıflar için istatistik türü, “Örnek nesnelere göre oluşturulan hata matrisi” türü seçilerek hata matrisleri oluşturulmuş ve Çizelge 6.3’de verilmiştir.

Çizelge 6.3 QuickBird görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi

Sınıf	Bina	Yol	Toplam
Bina	100	0	100
Yol	9	41	50
Sınıflandırılmamış	14	16	30
Toplam	123	57	
<b>Doğruluk</b>			
Üretici	0.81	0.72	
Kullanıcı	1.00	0.82	
<b>Genel Doğruluk</b>	<b>0.78</b>		
<b>Kappa</b>	<b>0.59</b>		

Çizelge 6.3’e bakıldığında, toplam doğruluğun yaklaşık %78 olduğu görülmektedir. Üretici doğruluklarında, bina yapılarının %81, yol yapılarının %72 ve kullanıcı doğruluklarında bina yapılarının %100, yol yapılarının %82 gibi değerler ön plana çıkmaktadır. Bu istatistiksel verilerden, QuickBird görüntüsündeki bina yapılarının ilgili sınıfa dahil edilmesinde başarılı olduğu ve bina sınıflandırmasının daha tatmin sonuçlar verdiği söylenebilir. Bunun yanında yol yapılarının ise ilgili sınıfa dahil edilmesinde daha az başarılı olduğunu ve bazı yanlış sınıflandırmaların olduğu yorumu yapılabilir.

Bu görüntünün nesne-tabanlı sonuçlarının daha ayrıntılı değerlendirmeleri, çalışmanın altıncı bölümündeki “CBS Ortamında Karşılaştırmalı Analizler” başlığı altında verilmiştir.

### 6.6.2.2 IKONOS Uydu Görüntülerinden Nesne-Tabanlı Detay Çıkarımları

QuickBird görüntüsündeki uygulamaya benzer olarak, 2002 ve 2008 yıllarına ait IKONOS görüntüleri için sınıflandırmaya esas olan uygun segmentasyon parametreleri belirlenerek sırasıyla Çizelge 6.4 ve 6.5’de verilmiştir.


Çizelge 6.4 2002 yılına ait IKONOS görüntüsü için segmentasyon parametreleri

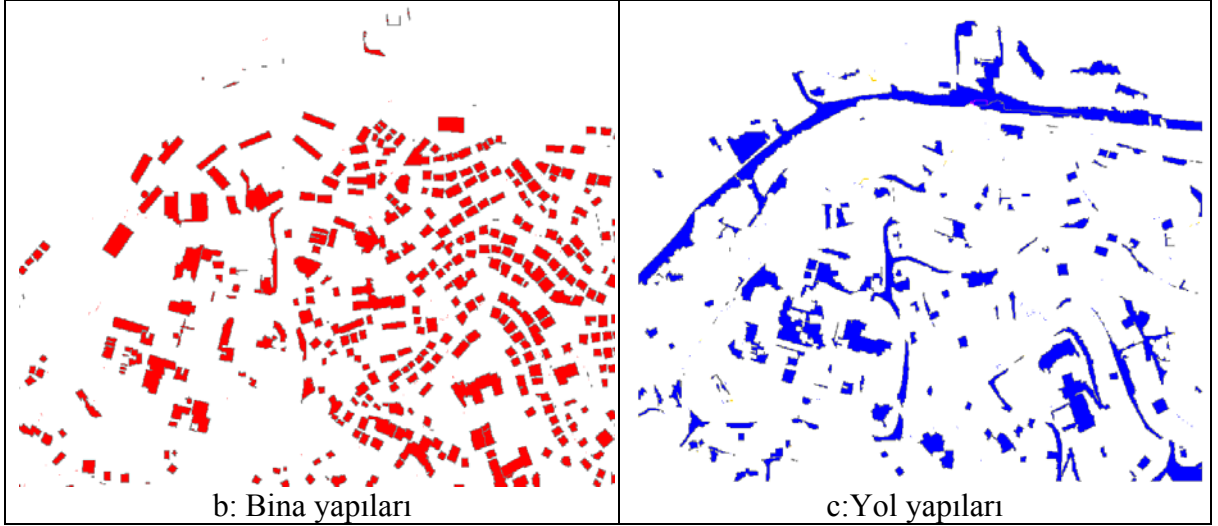
Katman	1	2	3	4	5
Ölçek par.	10	20	30	50	30
Renk	0.5	0.3	0.1	0.5	Spektral Farklılık
Biçim	0.5	0.7	0.9	0.5	
Yumuşaklık	0.5	0.5	0.5	0.5	
Bütünlük	0.5	0.5	0.5	0.5	
Seg. modu	Normal	Normal	Normal	Normal	

Çizelge 6.5 2008 yılına ait IKONOS görüntüsü için segmentasyon parametreleri


Katman	1	2	3	4	5	6
Ölçek par.	10	20	30	35	60	30
Renk	0.5	0.3	0.1	0.1	0.5	Spektral Farklılık
Biçim	0.5	0.7	0.9	0.9	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	

Segmentasyon aşaması sonrasında, oluşturulan sınıflar içerisinde görüntülere uygun olarak üyelik fonksiyonları tanımlanmış ve bunların fonksiyon aralıkları yazılıma girilmiştir. Yapılan tüm işlemlerin sonucunda, her iki görüntü de beşinci segmentasyon katmanları esas alınarak sınıflandırılmış ve görüntülerdeki ilgili detaylar otomatik olarak çıkartılmıştır (Şekil 6.9 ve 6.10).






Şekil 6.9 2002 yılına ait IKONOS uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları



a: Test alanındaki detaylarının nesne-tabanlı sınıflandırma sonucu



Şekil 6.10 2008 yılına ait IKONOS uydu görüntüsünden nesne-tabanlı sınıflandırma sonuçları



### 6.6.2.2.1 Sonuç Ürünlerin Doğruluk Analizleri

Bu aşamada, IKONOS görüntülerinden nesne-tabanlı sınıflandırma sonuçları için doğruluk değerlendirmesini yapmak üzere, QuickBird uygulamasına benzer şekilde, 100 adet bina için ve 50 adet yol yapıları için her iki görüntüde örnek nesnelere seçilmiştir. Sonrasında bu sınıflar için istatistik türü, “Örnek nesnelere göre oluşturulan hata matrisi” türü seçilerek hata matrisleri oluşturulmuş ve Çizelge 6.6 ve 6.7’de verilmiştir.

Çizelge 6.6 2002 yılına ait IKONOS görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi

Sınıf	Bina	Yol	Toplam
Bina	86	14	100
Yol	19	31	50
Sınıflandırılmamış	13	17	30
Toplam	118	62	
<b>Doğruluk</b>			
Üretici	0.74	0.66	
Kullanıcı	0.94	0.75	
<b>Genel Doğruluk</b>			
		<b>0.73</b>	
<b>Kappa</b>			
		<b>0.52</b>	

Çizelge 6.7 2008 yılına ait IKONOS görüntüsünden nesne-tabanlı sonuçların doğruluk değerlendirmesi

Sınıf	Bina	Yol	Toplam
Bina	94	6	100
Yol	15	35	50
Sınıflandırılmamış	15	15	30
Toplam	124	56	
<b>Doğruluk</b>			
Üretici	0.78	0.69	
Kullanıcı	0.96	0.79	
<b>Genel Doğruluk</b>			
		<b>0.75</b>	
<b>Kappa</b>			
		<b>0.55</b>	

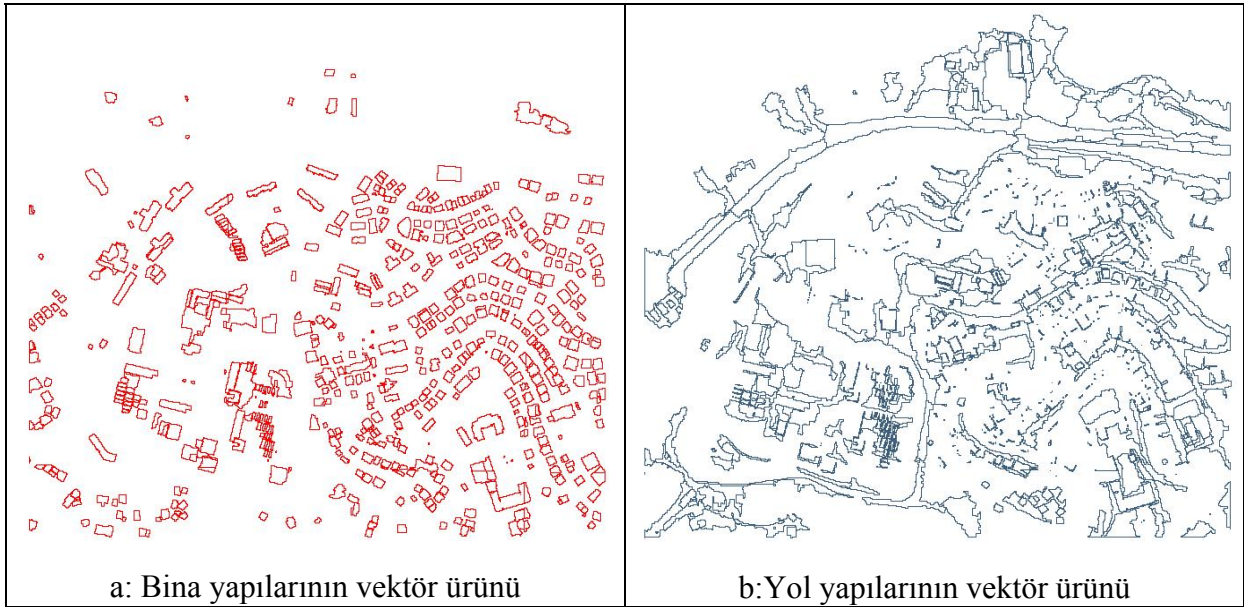
Tüm nesne-tabanlı değerlendirme sonuçlarına bakıldığında, IKONOS görüntülerinin nesne-tabanlı sınıflandırma sonuçlarının, QuickBird görüntüsü sınıflandırma sonuçlarına göre detay çıkarımında başarısız olduğu görülmüştür (Çizelge 6.5, 6.6 ve 6.7) Ayrıca, elde edilen istatistiksel verilerden, IKONOS görüntülerindeki bina yapılarının nesne-tabanlı sınıflandırma sonuçlarının başarılı olduğu ve bina sınıflandırmasının daha tatmin sonuçlar verdiği görülmektedir. Fakat aynı görüntüdeki yol yapılarının çıkarılmasının daha az başarılı olduğu

ve daha fazla yanlış sınıflandırmaların olduğu yorumu yapılabilir. Bu görüntülerin nesne-tabanlı sonuçlarının daha ayrıntılı değerlendirmeleri, çalışmanın altıncı bölümündeki “CBS Ortamında Karşılaştırmalı Analizler” başlığı altında verilmiştir.


### 6.6.3 Nesne-Tabanlı Sınıflandırma Sonuçlarının Vektör Ürün Haline Çevrilmesi

Piksel-tabanlı sınıflandırma sonuç ve doğruluk değerlendirmeleri analiz edildiğinde, nesne-tabanlı sınıflandırma sonuçlarının çok daha başarılı olduğu görülmüştür. Bu yüzden sadece çalışma konusuna esas olan nesne-tabanlı sınıflandırma sonuçları dikkate alınarak, bu sonuçlar üzerinden karşılaştırma, analiz ve sorgulamalar yapılmıştır.


Nesne-tabanlı sınıflandırma sonuçları, vektör ürün haline kolaylıkla çevrilebildiği için CBS uygulamalarına altlık oluşturma açısından oldukça fazla kolaylıklar sağlamaktadır. Tüm görüntülere ait yol ve bina yapılarının sınıflandırma sonuçları, çalışmanın sonraki bölümlerindeki karşılaştırma, sorgulama ve analiz aşamalarında kullanılmak amacıyla vektör ürüne çevrilmiştir (Şekil 6.11, 6.12 ve 6.13). Bu işlem sınıflandırma sonuçlarının Ecognition yazılımında “\*.shp” uzantılı dosya olarak kaydedilip, MapInfo yazılımında “\*.tab” dosyası açılmak üzere saklanmıştır.



Şekil 6.11 QuickBird görüntüsünün nesne- tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler



Şekil 6.12 2002 yılına ait IKONOS görüntüsünün nesne- tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler



Şekil 6.13 2008 yılına ait IKONOS görüntüsünün nesne- tabanlı sınıflandırma sonuçlarından elde edilen vektör ürünler

### 6.7 CBS Ortamında Karşılaştırmalı Analizler


Referans vektör haritalar ürünleri ile görüntülerden elle vektörleştirme yaklaşımları ve nesne- tabanlı otomatik detay çıkarımlarının karşılaştırma, sorgulama ve analizleri, bir bilgi sistemi yazılımı olan MapInfo Professional v7.0 yazılımı kullanılarak yapılmıştır. Bu yazılım, raster ve vektör yapısına sahip verilerin sınıf ve katman bilgilerini koruyarak, bu bilgileri kendi içerisinde de birer katman olarak belirler. Böylece her iki ayrı yapıdan gelen veriler, aynı format altında farklı katmanlarda gösterilerek görsel karşılaştırmaları ve sayısal analizleri yapılabilmektedir. Bunun yanında da bazı değerlendirmeler de NetCAD v5.0 yazılımı kullanılarak sağlanmıştır. Görüntüler referans vektörle karşılaştırıldığından dolayı, referans vektördeki bina ve yol yapılarının uzunluk ve alan bilgileri %100 oranında alınmıştır.

### 6.7.1 QuickBird Uydu Görüntüsü için Analiz Sonuçları


Bu bölümde, referans vektör harita ile QuickBird görüntüsünden üretilen elle vektörleştirme ürünleri ve nesne-tabanlı sınıflandırma sonuçları karşılaştırılarak analiz edilmiş ve gerekli sorgulamalar yapılarak yorumlanmıştır.

#### 6.7.1.1 Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının Karşılaştırılması

Bu aşamada ilk olarak, QuickBird görüntüsünün ekran üzerinden elle vektörleştirilmesinden üretilen vektör haritaları ile referans vektör olarak 1/5000'lik vektör harita ilgili yazılımda karşılaştırılmış, bina ve yol yapılarına ait analiz ve sorgulamalar yapılarak sonuçlar Şekil 6.14 ve 6.15'de görsel olarak verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.14 Bina yapılarının QuickBird görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler



Şekil 6.15 Yol yapılarının QuickBird görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler

Sayısal olarak değerlendirme yapmak için, yazılım ortamında referans vektör haritadaki ve QuickBird görüntüsü üzerinden elle vektörleştirme sonucunda elde edilen vektör haritadaki mevcut bina sayısı saydırılmış ve bu binaların toplam alanları hesaplanmıştır (Çizelge 6.8). Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 88 adet bina yapısının elle vektörleştirme yaklaşımı ile çıkarılmadığı ve elle vektörleştirme sonucunda 18 adet bina yapısının da referans vektörde mevcut olmadığı görülmüştür.

Yol yapılarının analizleri için de, referans vektör haritadaki ve elle vektörleştirme sonuçlarındaki yol yapılarının orta eksenlerinin toplam yol uzunlukları ilgili yazılımda hesaplanarak Çizelge 6.8'de gösterilmiştir.




Çizelge 6.8 Referans vektör haritadaki ve QuickBird görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları


Veri	Vektör Harita	QuickBird Görüntüsü
<b>Detay</b>		
<b>Bina (adet)</b>	596 (%100)	422 (%71)
<b>Bina (Alan - m<sup>2</sup>)</b>	143100.45 (%100)	114198.67 (%79)
<b>Yol (Uzunluk - m)</b>	14570.31 (%100)	13285.57 (%91)

### 6.7.1.2 Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması

Nesne-tabanlı bina yapılarının sınıflandırma sonuçlarından elde edilen vektör haritalar ile referans vektör olarak 1/5000'lik vektör harita yazılımda üst üste çakıştırılarak, bina ve yol yapılarına ait nesne-tabanlı sonuçlardaki doğru sınıflandırılmış, hatalı sınıflandırılmış ve sınıflandırılmamış alanlar ortaya çıkartılmış ve görsel olarak Şekil 6.16 ve 6.17'de verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.16 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler



Şekil 6.17 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler

Nesne-tabanlı bina ve yol çıkarımlarının sonuç ürünleri alan kapatan bir yapı şeklinde olduğundan dolayı, bu ürünleri referans vektör harita ile kapladıkları alan cinsinden karşılaştırmak gerekmektedir. Bu yapılarının referans vektör harita ile karşılaştırması amacıyla öncelikle, referans vektör haritadaki bina ve yol yapıları bir CAD yazılımı kullanılarak alan kapatan bir yapı haline getirilmiştir. Sonrasında, nesne tabanlı sonuçlardaki ve vektör haritadaki alanları aynı CBS yazılımı ortamında sorgulamaları yapılarak hesaplanmıştır. Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 112 adet (221658.45 m<sup>2</sup>) bina yapısının nesne tabanlı sınıflandırma yaklaşımı ile çıkarılamadığı ve nesne-tabanlı sınıflandırma 19 adet (6106.00 m<sup>2</sup>) bina yapısının da referans vektörde mevcut olmadığı görülmüştür (Çizelge 6.9).

Çizelge 6.9 Referans vektör haritadaki ve QuickBird görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları

Veri / Detay	Vektör Harita	QuickBird Görüntüsü
<b>Bina (adet)</b>	596 (%100)	520 (%87)
<b>Bina (Alan - m<sup>2</sup>)</b>	143100.45 (%100)	130123.91 (%91)
<b>Yol (Alan - m<sup>2</sup>)</b>	165037.52 (%100)	188729.34 (%114)




## 6.7.2 2002 Yılına ait IKONOS Uydu Görüntüsü için Analiz Sonuçları


Bu bölümde, referans vektör harita ile 2002 yılına ait IKONOS görüntüsünden üretilen elle vektörleştirme ürünleri ve nesne-tabanlı sınıflandırma sonuçları karşılaştırılarak analiz edilmiş ve gerekli sorgulamalar yapılarak yorumlanmıştır.

### 6.7.2.1 Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının Karşılaştırılması

Bu aşamada ilk olarak, 2002 yılına ait IKONOS görüntüsünün ekran üzerinden elle vektörleştirilmesinden üretilen vektör haritaları ile referans vektör harita ilgili yazılımda karşılaştırılmış, bina ve yol yapılarına ait analiz ve sorgulamalar yapılarak sonuçlar görsel olarak Şekil 6.18 ve 6.19'de verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.18 Bina yapılarının 2002 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler



Şekil 6.19 Yol yapılarının 2002 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler

2002 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirme sonucunda elde edilen vektör haritadaki mevcut bina sayısı saydırılmış ve bu binaların toplam alanları hesaplanmıştır (Çizelge 6.10). Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 181 adet (26678 m<sup>2</sup>) bina yapısının elle vektörleştirme yaklaşımı ile çıkarılmadığı ve elle vektörleştirme sonucunda 15 adet (3502.88 m<sup>2</sup>) bina yapısının da referans vektörde mevcut olmadığı görülmüştür.


Yol yapılarının analizleri için de, referans vektör haritadaki ve elle vektörleştirme sonuçlarındaki yol yapılarının orta eksenlerinin toplam yol uzunlukları ilgili yazılımda hesaplanarak Çizelge 6.10'da gösterilmiştir.

Çizelge 6.10 Referans vektör haritadaki ve 2002 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları

Detay \ Veri	Vektör Harita	2002 yılına ait IKONOS Görüntüsü
Bina (adet)	596 (%100)	404 (%68)
Bina (Alan - m <sup>2</sup> )	143100.45 (%100)	96814.44 (%68)
Yol (Uzunluk - m)	14570.31 (%100)	8063.66 (%55)


### 6.7.2.2 Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması

Nesne-tabanlı bina yapılarının sınıflandırma sonuçlarından elde edilen vektör haritalar ile referans vektör harita yazılımda üst üste çakıştırılarak, bina ve yol yapılarına ait nesne-tabanlı sonuçlardaki doğru sınıflandırılmış, hatalı sınıflandırılmış ve sınıflandırılmamış alanlar ortaya çıkartılmış ve görsel olarak Şekil 6.20 ve 6.21’de verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.20 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler





Şekil 6.21 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler

Bina ve yol yapılarının nesne-tabanlı çıkarımları ile referans vektördeki sonuç ürünlerindeki alanları sorgulamalar yapılarak hesaplanmıştır (Çizelge 6.11). Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 169 adet (37498.90 m<sup>2</sup>) bina yapısının nesne tabanlı sınıflandırma yaklaşımı ile çıkarılmadığı ve nesne-tabanlı sınıflandırma sonucunda 17 adet (7106.00 m<sup>2</sup>) bina yapısının da referans vektörde mevcut olmadığı görülmüştür.

Çizelge 6.11 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları


Veri / Detay	Vektör Harita	2002 yılına ait IKONOS Görüntüsü
Bina (adet)	596 (%100)	530 (%89)
Bina (Alan - m <sup>2</sup> )	143100.45 (%100)	123534.14 (%86)
Yol (Alan - m <sup>2</sup> )	165037.52 (%100)	220481.00 (%133)

### 6.7.3 2008 yılına ait IKONOS Uydu Görüntüsü İçin Analiz Sonuçları


Bu bölümde de, referans vektör harita ile 2008 yılına ait IKONOS görüntüsünden üretilen elle vektörleştirme ürünleri ve nesne-tabanlı sınıflandırma sonuçları karşılaştırılarak analiz edilmiş ve gerekli sorgulamalar yapılarak yorumlanmıştır.

#### 6.7.3.1 Referans Vektör Harita ile Görüntü Üzerinden Elle Vektörleştirme Sonuçlarının Karşılaştırılması

Bu aşamada ilk olarak, 2008 yılına ait IKONOS görüntüsünün ekran üzerinden elle vektörleştirilmesinden üretilen vektör haritaları ile referans vektör harita ilgili yazılımda karşılaştırılmış, bina ve yol yapılarına ait analiz ve sorgulamalar yapılarak sonuçlar görsel olarak Şekil 6.22 ve 6.23’de verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.22 Bina yapılarının 2008 IKONOS Görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler



Şekil 6.23 Yol yapılarının 2008 yılına ait IKONOS görüntüsünden elle vektörleştirilmesi sonuçları için CBS tabanlı analizler

2008 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirme sonucunda elde edilen vektör haritadaki mevcut bina sayısı saydırılmış ve bu binaların toplam alanları hesaplanmıştır (Çizelge 6.12). Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 143 adet (20949.60 m<sup>2</sup>) bina yapısının elle vektörleştirme yaklaşımı ile çıkarılmadığı ve elle vektörleştirme sonucunda 24 adet (13258.96 m<sup>2</sup>) bina yapısının da referans vektörde mevcut olmadığı görülmüştür.

Yol yapılarının analizleri için de, referans vektör haritadaki ve elle vektörleştirme sonuçlarındaki yol yapılarının orta eksenlerinin toplam yol uzunlukları ilgili yazılımda hesaplanarak Çizelge 6.12’de gösterilmiştir.




Çizelge 6.12 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsü üzerinden elle vektörleştirilen bina ve yol yapılarının analiz sonuçları

Veri	Vektör Harita	2008 yılına ait IKONOS Görüntüsü
<b>Detay</b>		
<b>Bina (adet)</b>	596 (%100)	431 (%72)
<b>Bina (Alan - m<sup>2</sup>)</b>	143100.45 (%100)	112504.76 (%79)
<b>Yol (Uzunluk - m)</b>	14570.31 (%100)	10096.23 (%69)


### 6.7.3.2 Referans Vektör Harita ile Nesne-Tabanlı Sonuçların Karşılaştırılması

Nesne-tabanlı bina yapılarının sınıflandırma sonuçlarından elde edilen vektör haritalar ile referans vektör harita yazılımda üst üste çakıştırılarak, bina ve yol yapılarına ait nesne-tabanlı sonuçlardaki doğru sınıflandırılmış, hatalı sınıflandırılmış ve sınıflandırılmamış alanlar ortaya çıkartılmış ve görsel olarak Şekil 6.24 ve 6.25’de verilmiş ve sayısal bilgileri hesaplanmıştır.



Şekil 6.24 Bina yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler





Şekil 6.25 Yol yapılarının nesne-tabanlı sınıflandırma sonuçları için CBS tabanlı analizler

Bina ve yol yapılarının nesne-tabanlı çıkarımları ile referans vektördeki sonuç ürünlerindeki alanları sorgulamalar yapılarak hesaplanmıştır (Çizelge 6.13). Ayrıca yapılan analizler sonucunda, referans vektörde mevcut olan 158 adet (29292.83 m<sup>2</sup>) bina yapısının nesne tabanlı sınıflandırma yaklaşımı ile çıkarılmadığı ve nesne-tabanlı sınıflandırma 20 adet (5704.31 m<sup>2</sup>) bina yapısının da referans vektörde mevcut olmadığı görülmüştür.


Çizelge 6.13 Referans vektör haritadaki ve 2008 yılına ait IKONOS görüntüsünün nesne-tabanlı sınıflandırılmasından elde edilen bina ve yol yapılarının analiz sonuçları

Detay \ Veri	Vektör Harita	2008 yılına ait IKONOS Görüntüsü
Bina (adet)	596 (%100)	451 (%76)
Bina (Alan - m <sup>2</sup> )	143100.45 (%100)	138748.31 (%97)
Yol (Alan - m <sup>2</sup> )	165037.52 (%100)	243216.13 (%147)

#### 6.7.4 CBS Ortamındaki Karşılaştırmalı Analiz Sonuçlarının İrdelenmesi

Çalışmaya esas olan test alanındaki 2004 yılına ait pan-sharp QuickBird, 2002 ve 2008 yıllarına ait pan-sharp IKONOS uydu görüntülerinin elle vektörleştirme ile elde edilen vektör haritaları ve nesne-tabanlı sınıflandırma yaklaşımı sonucunda elde edilen verileri CBS yazılımı altında toplanmış, ilgili alanın 2005 yılında üretilmiş 1/5000 ölçekli referans vektör harita verisi ile karşılaştırılmıştır.

Karşılaştırma sonuçlarına geometrik doğruluk açısından bakıldığında; çalışmanın 6. bölümündeki “Görüntülerin Geometrik Olarak Düzeltilmesi” başlığı altında, tüm görüntüler için doğruluk değerlerinin yarım pikselin altında elde edildiğinden ve ayrıca bu aşamadan sonra orto-görüntü elde edilmesi için görüntüler için farklı SYM verisi kullanıldığından bahsedilmiştir. Bu bağlamda bina yapıları için, görüntülerin elle vektörleştirilmesi ve nesne-tabanlı sınıflandırma sonucu elde edilen vektörlerin, referans vektör ile CBS yazılımı altında birer tabaka olarak üst üste bindirilmesi sonucunda oluşan geometrik kayıklıklar Şekil 6.26’da birer örnek olarak gösterilmiştir.



Şekil 6.26 Görüntülerden farklı yaklaşımlarla elde edilen sonuçların referans harita ile geometrik olarak karşılaştırılması – 2002 IKONOS örneğinde bina yapıları

Tüm görüntüler üzerinde analiz yapıldığında, bina köşeleri arasındaki kayıklık değerlerinin 0-1.5m arasında değiştiği gözlenmiştir. Bu analiz aynı şekilde yol yapıları için de yapılmış ve yaklaşık aynı değerler bulunmuştur. Tez çalışmasında, nesne-tabanlı sınıflandırma sonuçlarının geometrik olarak karşılaştırılmasından ziyade, bu tür bir yaklaşımın görüntüdeki nesnelerin çıkarım başarısı incelendiği için bu miktarın kabul edilebilir olduğu söylenebilir. Bu tür geometrik kayıklıkların oluşmasındaki en önemlisi faktör, orto-görüntü oluşturulması amacıyla SYM verisi kullanılmasıdır. Görüntülere en uygun olan SYM verisi 1/25000 ölçekli

ülke haritalarından üretildiği için geometrik kayıklıkların bahsedilen değerlerde olması normal karşılanabilir. Bu kayıklık değerlerinin en fazla olduğu yerler, test alanının arazi yüksekliğinin arttığı yerlerdir. Arazi değişimlerinin bu tür farklılık gösterdiği yerlerde görüntü verisi SYM tam olarak örtüşmemektedir ve böylelikle üretilen sonuç vektörlerde geometrik kayıklık meydana gelmiştir.

Elde edilen vektör ürünlerin geometrik olarak karşılaştırılmasından sonra, referans vektör haritadaki ve görüntülerdeki kentsel ayrıntılar alan ve uzunluk bilgileri açısından karşılaştırılmış ve sonucunda elde edilen bilgiler Çizelge 6.14’de verilmiştir.

Çizelge 6.14 Test alanındaki yol ve bina yapılarının, referans vektör haritadaki ve görüntülerden değişik yöntemlerle elde edilen vektör ürünlerindeki alan ve uzunluk bilgileri

Veri \ Detay		Bina Yapısı (adet)	Bina Yapısı (alan – m <sup>2</sup> )	Yol Yapısı (uzunluk - m)	Yol Yapısı (alan m <sup>2</sup> )
<b>1/5000 Ölçekli Referans Vektör Harita</b>		596 (%100)	143100.45 (%100)	14570.31 (%100)	165037.52 (%100)
<b>2004 yılına ait pan-sharp QuickBird</b>	<b>Elle Vektör</b>	422 (%71)	114198.67 (%79)	13285.57 (%91)	-
	<b>Nesne-Tabanlı</b>	520 (%87)	130123.91 (%91)	-	188729.34 (%114)
<b>2002 yılına ait pan-sharp IKONOS</b>	<b>Elle Vektör</b>	404 (%68)	96814.44 (%68)	8063.66 (%55)	-
	<b>Nesne-Tabanlı</b>	530 (%89)	123534.14 (%86)	-	220481.00 (%133)
<b>2008 yılına ait pan-sharp IKONOS</b>	<b>Elle Vektör</b>	431 (%72)	112504.76 (%79)	10096.23 (%69)	-
	<b>Nesne-Tabanlı</b>	451 (%76)	138748.31 (%97)	-	243216.13 (%147)

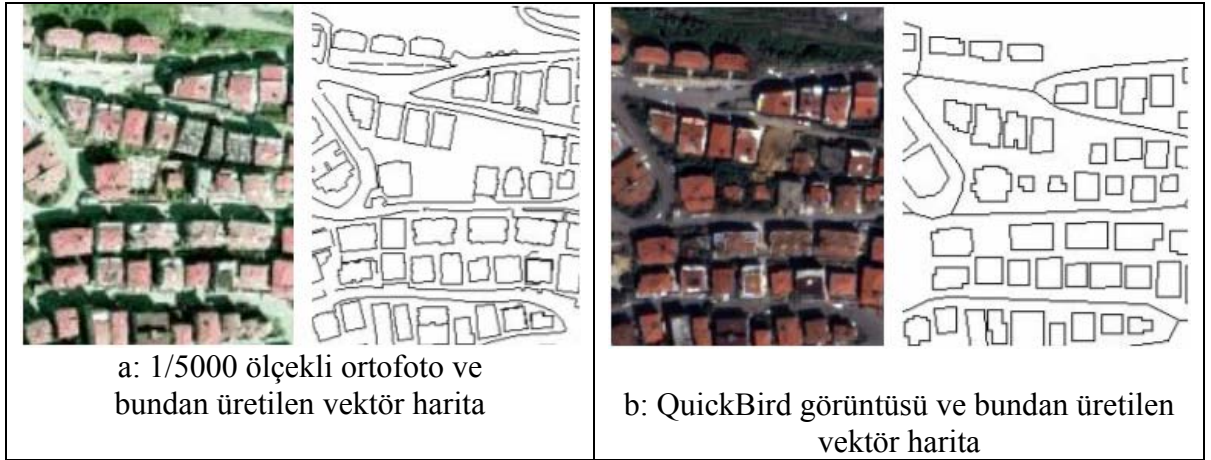
2005 yılında üretilen 1/5000 ölçekli vektör haritanın referans olarak alındığı bu analizlerde dikkat edilmesi gereken en önemli husus, kullanılan görüntülerinin ilgili test alanını görüntüleme tarihidir. Bu husus dikkate alınmadığında, elle vektörleştirme yaklaşımı ile;

- Adet olarak bina yapılarının çıkarılmasında en uygun verinin 2008 yılına ait IKONOS görüntüsünün (%72) ve 2004 yılına ait QuickBird görüntüsünün (%71) olduğu, 2002 yılına ait IKONOS görüntüsünün (%68) de diğer görüntülere oranla başarısız olduğu görülmüştür.
- Uzunluk olarak yol yapılarının çıkarmasında en başarılı vektör verisi, 2004 yılına ait QuickBird görüntüsünün (%91), sonrasında 2008 yılına ait IKONOS görüntüsünün (%69) ve 2002 yılına ait IKONOS görüntüsünün (%55) olduğu görülmüştür.

Nesne-tabanlı yaklaşımla ise,

- Adet olarak bina yapılarının çıkarılmasında en başarılı vektör verisi 2002 yılına ait IKONOS görüntüsü (%89) olduğu görülmüştür. Bu çıkarım başarısına yakın sonuç veren 2004 yılına ait pan-sharp QuickBird görüntüsü (%87) ve 2008 yılına ait IKONOS görüntüsü (%76) de başarılı olmuşlardır.
- Alan olarak yol yapılarının çıkarılmasında sırasıyla en başarılı vektör verisi 2004 yılına ait QuickBird görüntüsü (%114), 2008 yılına ait IKONOS görüntüsü (%133) ve 2002 yılına ait IKONOS görüntüsü olduğu görülmüştür.


Referans vektörün üretim ve uydu görüntülerinin alım tarihleri göz önüne alındığında, 2004 yılına ait QuickBird görüntüsü en uygun karşılaştırma örneği kabul edilmiştir. Bu iki verinin Çizelge 6.14'deki karşılaştırma analizlerinin sonuçlarına örnek olması açısından referans vektör harita ve görüntüden elle vektörleştirme ile üretilen vektör haritaya detaylı olarak bakıldığında; görüntüden üretilen vektör haritadaki bina ve yol yapılarının 1/5000 ölçekli haritadaki mevcut bina yapılarına benzer şekilde çıkarıldığı görülmüştür (Şekil 6.27).



Şekil 6.27 Referans vektör harita ve QuickBird görüntüsünden üretilen vektör haritanın karşılaştırılması

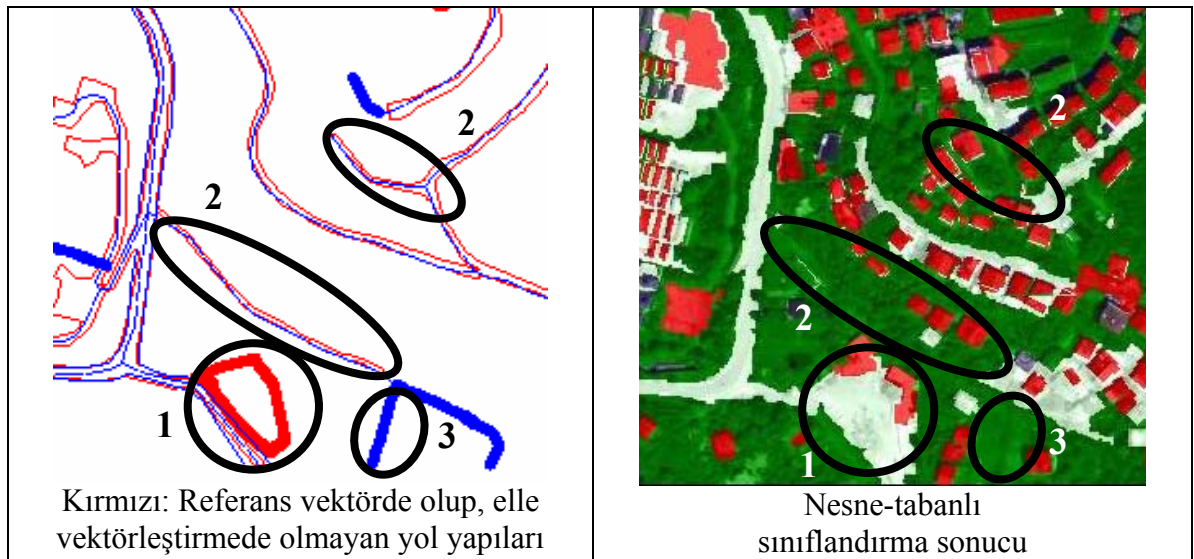
Diğer yandan, QuickBird görüntüsünden elle vektörleştirme ve nesne-tabanlı yaklaşım sonuçlarına detaylı bir şekilde bakıldığında, referans vektör haritada mevcut olup elle vektörleştirilemeyen bina yapıları nesne-tabanlı yaklaşım ile belirlenebilmiştir (Şekil 6.28'de 1 no'lu alan). Bunun yanında elle vektörleştirilemeyen bazı bina yapılarının, nesne-tabanlı yaklaşımla da belirlenemediği belirlenmiştir (Şekil 6.28'de 2 no'lu alan). Ayrıca, referans vektörde mevcut olan ve elle vektörleştirilen bazı bina yapılarının nesne-tabanlı yaklaşımla çıkarılmadığı gözlenmiştir (Şekil 6.28'de 3 no'lu alan).





Şekil 6.28 QuickBird görüntüsünden bina yapılarının elle vektörleştirme ve nesne-tabanlı sınıflandırma sonuçları

Aynı şekilde yol yapıları için Şekil 6.29'a bakıldığında, referans vektör haritada mevcut olup elle vektörleştirilemeyen bazı yol yapılarının nesne-tabanlı yaklaşım ile belirlenebildiği görülmüştür (Şekil 6.29'da 1 no'lu alan). Bunun yanında referans vektörde mevcut olan ve elle vektörleştirilen bazı yol yapılarının nesne-tabanlı yaklaşımla çıkarılmadığı gözlenmiştir (Şekil 6.29'da 2 no'lu alanlar). Ayrıca referans vektörde mevcut olmayan ve elle vektörleştirilen bazı yol yapılarının da nesne-tabanlı yaklaşımla çıkarılmadığı görülmüştür (Şekil 6.29'da 3 no'lu alan).



Şekil 6.29 QuickBird görüntüsünden yol yapılarının elle vektörleştirme ve nesne-tabanlı sınıflandırma sonuçları

Şekil 6.28 ve 6.29'daki analizlere örnek olarak diğer görüntülerden elde edilen sonuçlar da verilebilir. Görüntülerden bina ve yol yapılarının çıkarılması için yapılan bu karşılaştırmalarda, bazı ayrıntı çıkarım yöntem ve yaklaşımlarının başarısından söz edilmektedir. Daha önceden de bahsedildiği gibi, görüntülerden elde edilebilecek bilgi içeriğini etkileyen bir çok etken mevcuttur. Bu etkilerden en önemlisi görüntünün sahip olduğu etkin YÖA değeri olup, görüntünün alım zamanındaki atmosferik durum, görüntünün güneş yükseklik ve azimut açıları, görüntüleme sisteminin bakış açısı ve görüntüdeki ayrıntıların durumu ile aralarındaki kontrast da görüntüden çıkarılacak bilgi içeriğini etkilemektedir (Bakınız Bölüm 2).



Çizelge 6.15'de, uygulamada kullanılan görüntülerin sahip olduğu YÖA değerleri, güneş yükseklik ve azimut açıları değerleri verilmiştir. Ayrıca görüntülerin bu özelliklerinin gösterilmesi amacıyla Şekil 6.30'da, görüntülerdeki aynı alana ait gösterimler örnek olarak verilmiştir.

Çizelge 6.15 Kullanılan görüntülerin sahip olduğu bazı özellikler

<b>Görüntü</b> <b>Özellikler</b>	<b>2004 Yılına ait</b> <b>Pan-sharp</b> <b>QuickBird</b>	<b>2002 Yılına ait</b> <b>Pan-sharp</b> <b>IKONOS</b>	<b>2008 Yılına ait</b> <b>Pan-sharp</b> <b>IKONOS</b>
Etkin YÖA Değeri (m)	0.6	1.0	1.0
Güneş Yükseklik Açısı (derece)	64.70	63.24	66.5
Güneş Azimut Açısı (derece)	139.10	166.3	138.2
Bakış Açısı (derece)	3.90	26.8	28.6

Burada, Şekil 6.30'da gösterilen bina ve yol ayrıntılarının çıkarılmasında görüntülerin sahip olduğu bazı özelliklerden kaynaklanan bazı sorunlardan bahsedilecektir.



	<p>b: 2002 Pan-sharp IKONOS</p> <p>Güneş Yükseklik Açısı: <math>63.2^{\circ}</math>  Güneş Azimut Açısı: <math>166.3^{\circ}</math>  Bakış Açısı: <math>26.8^{\circ}</math></p>
	<p>c: 2008 Pan-sharp IKONOS</p> <p>Güneş Yükseklik Açısı: <math>66.5^{\circ}</math>  Güneş Azimut Açısı: <math>138.2^{\circ}</math>  Bakış Açısı: <math>28.6^{\circ}</math></p>

Şekil 6.30 Farklı güneş yükseklik ve azimut açlarına sahip görüntülerin aynı alandaki gösterimi

Tüm görüntülerde bina yapılarının sadece belirli değerlerde yansıma vermediği için ve bazı çatılarının aynı renkte olmadığından dolayı, görüntülerden bu yapıların bazılarının çıkarımı yapılamamaktadır. Fakat yine de binaların çatılarında güneşten yansımaları mevcut olduğu için bunların tanınmasında ve çıkarılmasında sorun yaşanmamıştır. Genelde aynı güneş yükseklik açlarına sahip bu görüntülere bakıldığında, güneş azimut açısı ( $166.3^{\circ}$ ) yüksek olan 2002 yılına ait IKONOS görüntüsünde bina gölgesinde kalan yol yapılarının çıkarılmadığı belirlenmiştir. 2004 yılına ait QuickBird ve 2008 yılına ait IKONOS görüntülerinde ise yol yapılarının rahatça tanınabildiği gözlenmiştir. Bunun yanında, görüntülerin görüntüleme sisteminin bakış açısı değeri de 2004 yılına ait QuickBird görüntüsünden belirgin şekilde görülmüştür. Görüntüleme sistemlerinin bakış açısı daha yüksek olan 2002 ve 2008 yıllarına ait IKONOS görüntülerinde bina yapılarının arasında kalan yol yapılarının tanınmadığı çok rahatlıkla gözlenmiştir.



Görüntülerin bahsedilen bu özellikleri, görüntülerdeki bilgi içeriği düzeyinin incelenmesine olanak tanımış ve bunun sonucunda, gerçeğe yakın sonuçlar veren 2004 yılı pan-sharp QuickBird görüntüsünün olduğu belirlenmiştir. Görüntünün 0.6m YÖA değerine, 65°'lik güneş yükseklik açısına, 139°'lik güneş azimut açısına ve 3.90'lik bakış açısına sahip olduğundan dolayı bu görüntüde, gölgede kalan ara yol yapıları ve küçük bina yapıları bile kolaylıkla tanınmış, bulunmuş ve çıkarılabilmektedir.

Bunun yanında, yüksek çözünürlüklü renkli görüntülerin elde edilmesini sağlayan pan-sharp uygulamasıyla, bina ve yol yapılarının birbirlerinden ve diğer ayrıntılardan ayrılarak tanınması sağlanmıştır. Görüntülerin bu analizleri ve referans vektör ile CBS tabanlı karşılaştırmaları sonucunda, görüntülerdeki ayrıntıların elle vektörleştirme ve nesne-tabanlı yaklaşım ile nesnelerin bulunma ve grup olarak tanınma değerlendirmeleri Çizelge 6.16'da verilmiştir.

Çizelge 6.16 Bina ve yol yapılarının, görüntülerden değişik yöntemlerle bulunma ve tanınma değerlendirmeleri

Detay	Görüntü	Bulunma						Tanınma					
		Elle Vektörleştirme			Nesne-Tabanlı			Elle Vektörleştirme			Nesne-Tabanlı		
		3	2	1	3	2	1	3	2	1	3	2	1
Bina Yapısı	2004 yılı QuickBird	√			√			√			√		
	2002 yılı IKONOS	√			√				√			√	
	2008 yılı IKONOS	√			√			√				√	
Yol Yapısı	2004 yılı QuickBird	√			√			√			√		
	2002 yılı IKONOS	√			√			√					√
	2008 yılı IKONOS	√			√			√				√	

## 7. SONUÇ ve ÖNERİLER

Uzaktan algılamanın topografik amaçlı geçmişi, otuz yıldan daha önceye dayanmaktadır. Düşük çözünürlüklü uydu görüntüleri 1/50000 ve 1/100000 ölçekli topografik haritaların yapımına imkan vermiş ve özellikle gelişmemiş ve bu düzeyde harita örtüsü az olan ülkelerde de temel nitelikli orta ölçekli haritaların üretimine önemli katkı yapmıştır. Ancak, kartografik amaçlı uydu sistemlerindeki gelişmeler bu düzeyde kalmamış ve günümüzün yüksek çözünürlüklü yüksek teknoloji uydu görüntüleri QuickBird, IKONOS, ve Orbview ile metre ve alt-metre düzeyinde piksel boyutuna ulaşılmıştır.

Bu noktada, her ülkenin orta ve büyük ölçekli haritalarını yapımı ve güncelleme ihtiyacı olduğunu belirtmekte yarar vardır. Zira, konuma bağlı güncel ve doğru bilgi, yönetim ve savunma gibi amaçlarda önemli bir altlıktır. Gelişmiş ülkeler, haritalarını yapmak güncellemek için çeşitli kurumlara sahiptirler ve bu kurumlar etkin bir biçimde çalışmaktadırlar. Ancak geliştirmekte olan ülkelerde güncelleme çalışmaları son derece yavaş ilerlemekte olup, uzaktan algılama teknolojisi bu soruna etkin bir çözüm olma yolunda hızla ilerlemektedir. Uzaktan algılamanın konumsal bilgi edinmede kazanmaya başladığı önem doğrultusunda, YÖA değeri 0.5m ve altında uydu görüntüleri kullanılmaya başlanacaktır. Bütün bunlar, yapılan çalışmaların da doğruladığı gibi, 1/10000 ölçekli bir haritanın bilgi içeriğini çıkaracak bir ayrıntı zenginliğini kullanıcılara sunmaktadır (Tübitak Raporu, 2006).

Bunların yanında, harita yapım ve güncelleme çalışmalarında kullanılacak görüntülerin kullanıma hazır hale getirilmesi ve uygulama aşamasında görüntü içerisinden bilgi çıkarılması için gerekli olacak yazılım ve donanım ihtiyaçları da göz önünde bulundurulmalıdır. Bu aşamada, uygulanacak metot bile söz sahibi olacaktır. Bu görüntülerdeki detayları ekran üzerinden elle vektörleştirmek veya bunları bazı algoritmalar kullanarak yarı otomatik veya tam otomatik çıkarmak, yazılım ve bu yazılımlar arasında bazı teknik ve mali farklar oluşturmaktadır. Şöyle ki, görüntülerin elle vektörleştirilmesi, günümüz yaygın CAD tabanlı yazılımlar (NetCAD, AutoCAD vb. yazılımlar) ile kullanıcılar tarafından rahatça uygulanabilmekte olup, yüksek maliyetli bir uygulama değildir. Fakat, görüntülerin yarı ve tam otomatik olarak çıkarılması, bu işleme uygun yazılımlar (PCI, Ecognition vb. yazılımlar) kullanılarak yapılabilmektedir. Burada, yazılımların yüksek maliyetleri de göz önünde bulundurulmalıdır. Teknik açıdan farklılıkları ise; görüntülerin elle vektörleştirilmesi tekniğinde işlemin uzun sürede gerçekleştirilmesi, operatör hatalarının fazla olabileceği, bunun yanında diğer otomatik çıkarım tekniğinde, işlemin çok kısa sürede sonlandırılması ve operatör hatalarının en aza indirilmesi olarak sayılabilir.

Günümüzde, yüksek çözünürlüklü uydu görüntüleri kullanarak 1/10000 ölçekli haritalardan büyük ölçekli haritaların yapımı ve güncellenmesinin olabirirliliği araştırma konusudur. Örneğin, mevcut QuickBird uydusu verileriyle özellikle engebesiz alanlarda, yaklaşık 1/6000 ile 1/10000 ölçekleri arasında haritaların üretilebildiği Jacobsen ve Büyüksalih (2008)'in çalışmalarında belirtilmiştir. Yüksek çözünürlüklü bir uzaktan algılama görüntüsünden büyük ölçekli harita yapımı ve güncelleme çalışmalarında kullanılabilirliğini araştırmak için öncelikle, bu görüntülerdeki kentsel ayrıntıları tanıma ve çıkarma yaklaşımlarının değerlendirilmesi gerekmektedir.

Bu amaçla bu tez çalışmasında, ilk olarak, Zonguldak Bölgesini kaplayan 2004 yılına ait QuickBird görüntüsünün, 2002 ve 2004 yıllarına ait IKONOS görüntülerinin geometrik düzeltmeleri ve zenginleştirme işlemleri yapılmış ve görüntüler bir sonraki uygulama aşaması için kullanıma hazır hale getirilmiştir. Sonraki adımda, görüntüdeki kentsel ayrıntılar olan bina ve yol yapıları ekran üzerinden elle vektörleştirme yöntemi ile vektörleştirilmiştir. Ayrıca bu yapılar, diğer detay çıkarma yaklaşımları olan klasik piksel-tabanlı sınıflandırma ve günümüzde çok sıkça kullanılan nesne-tabanlı sınıflandırma yöntemleri ile otomatik olarak çıkartılmıştır. Elde edilen nesne-tabanlı sonuçlar vektör ürünler haline getirilmiş ve bir bilgi sistemi ortamına aktarılması sağlanmıştır. Otomatik olarak üretilen bu vektör ürünler, test alanının mevcut 1/5000 ölçekli referans vektör haritası ile coğrafi tabanlı yazılımda bütünleştirilip karşılaştırılarak, görüntünün ekran üzerinden elle vektörleştirilmesi yöntemiyle elde edilen vektör ürünlerine karşı başarısı analiz edilmiştir.

Böylelikle uzaktan algılama görüntüleri kullanarak, değişik yaklaşımlarla görüntü üzerindeki kentsel ayrıntıların tanınması ve çıkarılması sağlanmıştır. Tezin amacına uygun olarak, bu görüntülerden büyük ölçekli harita yapımı ve güncellenmesi konusu araştırılarak, sonuç ve yorumlar yapılmış ve gerekli öneriler getirilmiştir.

- Uydu görüntüleri genellikle; ham, geometrik olarak düzeltilmiş ve orto düzeltmeli görüntü olarak satılmaktadır. Bu başlamda, uygulama yapılacak alanda mevcut veya üretilmiş YKN ve SYM verileri var ise, uydu görüntülerinin ham olarak alınması kullanıcının yararınadır. Böylelikle görüntü ve arazinin verilerinin birlikte değerlendirilmesi, uygulamayı yapacak olan kullanıcının denetiminde yapılmış olacaktır.
- Kullanılan görüntü verisinin içerdiği fazla bilgi içeriğine karşılık, bu bilgilerin eksiksiz çıkarılması için ham görüntüde mutlaka ön düzeltme ve zenginleştirme işlemlerine ihtiyaç duyulmaktadır. Görüntülerin geometrik düzeltme aşamasında

kullanılan YKN'lerin uygun şekilde ve sayıda seçilerek analiz edilmesinin ve kullanılacak SYM verilerinin kaliteli olmasının, sonuç harita ürünlerini doğrudan etkileyeceği göz önünde bulundurulmalıdır. Görüntü zenginleştirme işlemleri ise, görüntülere uygulanan görsel ve işlevsel amaçlı iyileştirme işlemleridir. Bu işlemlerle görüntünün görsel niteliği iyileştirilir ve sonucunda, görüntü işleme yazılımlarında daha iyi analiz sonuçları elde edilir.

- Zengin bilgi içeriği sayesinde pan-sharp QuickBird ve IKONOS görüntüleri, harita güncellemesi için uygun bir görüntü verisi olmasına rağmen, 1/5000 ölçekli bir haritanın sağladığı konum doğruluğuna sahipken, 1/5000 ölçekli haritadaki bilgi içeriğine erişmemektedir. Bu bağlamda daha iyi sonuçlar elde etmek için ilgili alana ait tek görüntü ile değil, stereo görüntüleriyle çalışılması gerekmektedir.
- Yüksek çözünürlüklü uydu görüntülerinden kentsel ayrıntıların çıkarımı uygulamalarında görüntünün ekran üzerinden elle vektörleştirme işlemi oldukça fazla zaman almaktadır. Kullanılan görüntülerden bu yaklaşımla üretilen vektör haritalar, bina yapılarında %68-72, yol yapılarında ise %55-91 oranlarında 1/5000 ölçekli referans vektör haritayı karşılamaktadır. Bu yaklaşım için en başarılı verinin, düşük güneş azimut açısına ve düşük görüntüleme sisteminin bakış açısına sahip olan 2004 yılına ait QuickBird görüntüsünün (bina yapılarında %71, yol yapılarında %91) olduğu, en başarısız verinin ise, yüksek güneş azimut açısına ve yüksek görüntüleme sisteminin bakış açısına sahip olan 2002 yılına ait IKONOS görüntüsünün (bina yapılarında %68, yol yapılarında %55) olduğu gözlenmiştir.
- Detay çıkarım yöntemlerinden biri olan nesne-tabanlı otomatik sınıflandırma yaklaşımı ise çıkarım işleminin en kısa sürede ve otomatik gerçekleştirilmesine olanak tanımıştır. Bu yaklaşımla üretilen vektör haritanın başarısı, bina yapılarında alan olarak 1/5000 ölçekli referans vektör haritadaki aynı yapıları %79-97 oranında karşılamaktadır. Bu değerın elle vektörleştirme sonuçlarına yakın olması, nesne-tabanlı yaklaşımların kullanılabilirliğini arttırmakta, doktora tezinin amacını karşılamaktadır. Nesne-tabanlı otomatik yol çıkarımları için ise, alan olarak yapılan analiz ve karşılaştırmalar sonucunda, referans vektör haritayı yaklaşık %115-147 oranında karşıladığı görülmüştür. Referans vektördeki yapıların %100 oranında alınması ile ortaya çıkan bu karşılaştırma sonuçlarının en önemli sebebi, görüntüdeki bina gölgelerindeki ve bazı binaların çatılarındaki yansımalarının yol yapılarındaki

yansımalara benzer olması ve böylelikle bu tip yapıların da yol sınıfı olarak sınıflandırılmasıdır.

Genel olarak yanlış sınıflandırmaların sebebi, kullanılan görüntüdeki ayrıntıların durumu (plansız yapılaşma, dar yollar vb.) ve aralarındaki kontrast değerleri, mevcut gölge sorunu ve test alanının değişken olan topoğrafyası olarak gösterilebilir. Ayrıca, nesne-tabanlı yaklaşım uygulamasında çalışılan ve “Alan Büyütmesi - Region Growing” algoritması kullanan Ecognition yazılımında alansal objelerin çıkarımında daha fazla başarı elde edildiği bilinmektedir. Bu bağlamda, yol yapıları gibi çizgisel detayların otomatik olarak çıkarımında sorunlar yaşanmıştır.

- Görüntüdeki bazı yol detaylarının, beton çatılı bina yapıları ile aynı spektral yansımayı vermesinden dolayı nesne-tabanlı segmentasyon ve sınıflandırma aşaması olumsuz yönde etkilenmiş, böylece sonuç ürün referans vektörü tam anlamıyla karşılayamamıştır.
- Elle vektörleştirmede operatör bilgisi kullanılabilirken, aynı durum nesne-tabanlı yaklaşımda geçerli olmamaktadır. Örneğin devam eden bir yolun ağaç altında kalması veya tünelle devam etmesi durumunda elle vektörleştirme yapan bir operatör, bilgisi dahilinde bu yol yapısını devam ettirebilirken, nesne-tabanlı yaklaşımın operatör bağımsız olması bu duruma izin vermemektedir. Buna karşın, nesne-tabanlı detay çıkarım yaklaşımda uygulanan bulanık üyelik fonksiyonları, bu sorunun bir miktar giderilmesinde yardımcı olmakta ve spektral analizin dışında da imkanlar sağlamaktadır.
- Referans vektör haritanın üretildiği 2005 yılından sonraki değişimleri izlemek ve bu haritanın güncellenmesi için analiz edilen 2008 yılına ait IKONOS görüntüsünün elle vektörleştirme ve nesne-tabanlı yaklaşım sonuçlarına göre, geçen üç sene içerisinde bina ve yol yapılarında değişiklikler saptanmıştır. Örneğin, referans vektörde bulunmayıp, görüntüden elle vektörleştirme sonucunda 24 adet bina yapısı ve yine referans vektörde bulunmayıp, görüntüden nesne-tabanlı yaklaşım ile 20 adet bina yapısı tanınmış ve çıkarılmıştır. Bu bina yapıları, eskiden mevcut olup restore edilmiş veya yeni inşa edilmiş olabilir. Elde edilen bu çıkarım sonuçlarından, elle vektörleştirme yöntemi ve özellikle yürütme işlemi uzun sürmeyen nesne-tabanlı yaklaşım ile güncelleme çalışmalarının yapılabileceği söylenebilir.

Uygulama sonunda, bina ve ağaç gölgesinde kalmayan, açık alanlardaki ana yolların ve düzgün yerleşim gösteren şehirleşme bölgelerindeki tali yolların nesne-tabanlı yaklaşım ile başarılı bir şekilde çıkarılabileceği görülmüştür. Ayrıca bazı yol yapılarının spektral yansıma değerlerinin çıplak arazilerinkilerle aynı olması ve özellikle kullandığı algoritması nedeniyle bu yaklaşımın, yol yapılarının çıkarımında başarısız olduğu belirlenmiştir. Genel anlamda başarılı sınıflandırma sonuçları için, uygulama yapılacak bölgenin 1m'den daha az YÖA değerine sahip uydu görüntüsüne ihtiyaç duyulmaktadır. Bu bağlamda gelişen teknolojiyle birlikte, WorldView ve GeoEye gibi uydu sistemlerinin görüntülerinin kullanılması önerilmektedir.

Çalışmada yaklaşık 1x1 km'lik bir alanda uygulama yapıldığından, elle vektörleştirme ve nesne-tabanlı yöntem sonuçlarını elde etmede zorluk yaşanmamıştır. Fakat daha geniş alanlarda çalışıldığında; elle vektörleştirme işleminde daha fazla operatör ihtiyacı ve vektörleştirme zamanı ortaya çıkacaktır. Diğer yandan nesne-tabanlı sınıflandırma işleminde ise, yüksek boyutlu veri kullanılacağından dolayı sadece ilgili yazılımın yürütülme süresi artacaktır. Böylelikle nesne-tabanlı yaklaşımın kullanımı, kullanıcı için daha avantajlı olacaktır.

Görüntüden başarılı şekilde çıkarılan yapıların nesne-tabanlı sonuçları, vektör yapıya çevrilebildiği için CBS uygulamalarına altlık oluşturma açısından oldukça fazla kolaylıklar sağlamaktadır. Sonuç ürünlerin bir CBS yazılımı altında toplanmasıyla, test alanına ait diğer grafik ve öznitelik bilgileriyle birlikte analiz ve sorgulamaları yapılabilmektedir. Bu bağlamda, ilgi alanı için mevcut raster ve vektör verilerle birlikte CBS tabanlı analiz ve karşılaştırmalarının yapılması, güncel durumun ortaya koyması açısından önem taşımaktadır. Böylece kentsel oluşum sürecinde analizler yapılarak ileriye yönelik projeler için bir sayısal altlık oluşturulması sağlanmaktadır.

Sayısal harita yapımı ve güncellenmesi süresinde, CBS veri tabanlarından homojen yapıda olmayan verilerin derlenmesi sırasında veri kalitesini sağlayacak güncellik, doğruluk, bütünlük ve organizasyon gibi teknik özelliklerin dikkate alınması gerekmektedir. Belirli bir amaç için toplanan verinin, bütünüyle farklı bir amaç için kullanılması gerekliliğinde verinin yeniden sıralanması ve diğer kaynaklarla birleştirilmesi söz konusu olabilir. Verilerin sürekli olarak artmasının veri heterojenliğine yol açtığı da unutulmaması gereken bir unsurdur.

**KAYNAKLAR**

- Abdel-Aziz, Y. I. ve 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, 420-475.
- Akdeniz, H., (2004), "The Opportunities That Digital Orthophotos Can Supply in Urban Planning", ISRPS 2004 Annual Conference, 19 - 23 July 2004, Istanbul, Turkey.
- Alkış, Z., (1998), "Planlamada Uzaktan Algılama ve Coğrafi Bilgi Sistemlerinin Yararları", Metropolitan Alanlar Planlama Sorunları 1. Sempozyumu, YTÜ Yayınları, İstanbul, 200-204.
- Antunes, A.F., Lingnau C. ve Da Silva J. C., (2003), "Object Oriented Analysis and Semantic Network For High Resolution Image Classification", Anais XI SBSR, 05-10 April 2003, Belo Horizonte, Brazil, 273-279.
- Baatz, M., ve Schäpe, A., (2000), "Multiresolution Segmentation – An Optimisation Approach for High Quality Multi-Scale Image Segmentation", AGIT Symposium, Salzburg.
- Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., Lingenfelder, I., Mimler, M., Sohlbach, M., Weber, M., ve Willhauck, G., (2004), eCognition Professional: User Guide 5, Definiens-Imaging, Munich.
- Bayram, B., Batuk, F.B., Alkış Z. ve İpekçi A., (2002), "Monitoring Urban Growth: Büyükçekmece", 3<sup>rd</sup> International Symposium Remote Sensing of Urban Areas, 11-13 June 2002, İstanbul, Turkey, 811-818.
- Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I. ve Heynen, M., (2004), "Multi-Resolution, Object-Oriented Fuzzy Analysis of Remote Sensing Data for GIS-Ready Information", ISPRS Journal of Photogrammetry & Remote Sensing, 58:239-258.
- Blaschke, T., Lang, S. ve Hay, G. J., (2008), Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications, Springer-Verlag Berlin Heidelberg, ISBN: 978-3-540-77057-2.
- Blaschke, T., (2003), "Continuity, complexity and change: A hierarchical Geoinformation-based approach to exploring patterns of change in a cultural landscape", Multifunctional Landscapes Vol III: Continuity and Change. Advances in Ecological Sciences 16, WIT press, Southampton, Boston, 33-54.
- Burnett, C. ve Blaschke, T. (2003), "A Multi-Scale Segmentation / Object Relationship Modelling Methodology for Landscape Analysis". Ecological Modelling 168(3): 233-249.
- Büyüksalih, G., Oruç, M. ve Koçak, M. G., (2003), "Geometric Accuracy Testing of IKONOS Geo-Product Mono Imagery using Different Sensor Orientation Models", Turkish Journal of Engineering Environmental Science, 27: 347-360.
- Büyüksalih, B., Marangoz A. M. ve Jacobsen, K., (2005), "Potential of KOMPSAT-1 for Mapping Purposes", EARSeL Workshop on 3D Remote Sensing, Porto, Portugal.
- Cheng, P., Toutin, T., Zhang, Y. ve Wood, M., (2003) "QuickBird – Geometric Correction, Path and Block Processing and Data Fusion", Earth Observation Magazine's (EOM) May 2003.
- Çelik, M., Saygın, Ö., Süer, A., Kınacı, O., Günay, E., Çaçtaş, E. ve Dal, F. (2004), "Şehir Planlamada Coğrafi Bilgi Sistemleri ve Uzaktan Algılama Çalışmaları", 3. CBS Bilişim



Günleri, 6-9 Ekim 2004, Fatih Üniversitesi, İstanbul.

Çelik, R., (2006), Yüksek Çözünürlüklü Uydu Görüntülerinden Detayların Otomatik ve Manuel Çıkarımı ve CBS Ortamında Analizi, Yüksek Lisans Tezi, ZKÜ Fen Bilimleri Enstitüsü.

Çelikoyan, T. M. ve Altan, O., (2005), “İstanbul kentinde arazi kullanımının hava fotoğrafları ve uydu görüntüleri yardımıyla tarihsel dönemlerde incelenmesi ve analizi”, İTÜ Dergisi/d Mühendislik, 4/3: 67-75.

Damm, A., Hostert P. ve Schiefer S., (2005), “Investigating Urban Railway Corridors with Geometric High Resolution Satellite Data”. ‘Human Settlements and Impact Analysis’ - 3<sup>rd</sup> International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005) - ISPRS WG VII/1, 14 - 16 March 2005, Tempe, AZ , USA.

Fraser, C. S., (2002), “Prospects For Mapping from High-resolution Satellite Imagery”, 23<sup>rd</sup> Asian Conference on Remote Sensing, No. 173, 25-29 November 2002, Kathmoandu, Nepal.

Frauman, E. ve Wolff E., (2005), “Segmentation of Very High Spatial Resolution Satellite Images in Urban Areas for Segments-Based Classification”, ‘Human Settlements and Impact Analysis’ - 3<sup>rd</sup> International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005) - ISPRS WG VII/1, 14 - 16 March 2005, Tempe, AZ , USA.

Herrera, B., (2003), Classification And Modeling Of Trees Outside Forest In Central American Landscapes By Combining Remotely Sensed Data and GIS. PhD thesis, Department of Remote Sensing and Landscape Information Systems. University of Freiburg, Germany.

Hofmann, P., (2001a), “Detecting Urban Features From IKONOS Data Using an Object-Oriented Approach, First Annual Conference of the Remote Sensing & Photogrammetry Society 12-14 September 2001, 28-33.

Hofmann, P, (2001b), “Detecting Buildings and Roads from IKONOS Data Using Additional Elevation Information”, GIS Geo-Information-System, 2001:6.

Hofmann, P, (2001c), “Detecting Informal Settlements from IKONOS Image Data Using Methods Of Object Oriented Image Analysis - An Example From Cape Town”, Remote Sensing of Urban Areas”, edited by Jürgens, Carsten (Regensburg).

Jacobsen, K., (2002), “Mapping with IKONOS Images”, EARSeL, Prag 2002 “Geoinformation for European-wide Integration” Millpress ISBN 90-77017-71-2, 149 – 156.

Jacobsen, K., (2003), “Geometric Potential of IKONOS and QuickBird Images”, The Photogrammetric Week, Germany.

Jacobsen, K., (2005), “High Resolution Imaging Satellite Systems”, 3D-Remote Sensing Workshop, Porto.

Jacobsen, K. ve Büyüksalih, G., (2006), “Mapping From Space - A Cooperation of Zonguldak Karaelmas University and University of Hannover”, Fifth International Symposium "Turkish-German Joint Geodetic Days", 28-31 March 2006, Berlin, Germany.

Jacobsen, K. ve Büyüksalih, G., (2008), “Topographic Mapping from Space”, 4<sup>th</sup> Workshop of EARSeL on Remote Sensing for Developing Countries/GISDECO 8, 05-10 June 2008,

İstanbul, Turkey.

Karakış, S., Marangoz, A. M. ve Büyüksalih, G., (2005), “QuickBird Pan-Sharpended Görüntüsü Üzerinden Otomatik Detay Çıkarımı ve Coğrafi Bilgi Sistemlerine Uygunluğunun Analizi”, 10.Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara

Karakış, S., (2005), Yüksek Çözünürlüklü Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Tekniğiyle Otomatik Olarak Belirlenmesi ve Coğrafi Bilgi Sistemi (CBS) Ortamında Bütünleştirilmesine Yönelik Araştırma, Yüksek Lisans Tezi, ZKÜ Fen Bilimleri Enstitüsü.

Karakış, S., Topan, H., Büyüksalih, G., Marangoz, A. M. ve Jacobsen, K., (2005), “Semantic Analysis of Space Imagery for Mapping Purposes”, 2<sup>nd</sup> RAST Congress, İstanbul.

Liedtke, J., (2002), “QuickBird-2 System Description and Product Overview”, JACIE Workshop, 25-27 March 2002, Washington DC.

Lillesand, M.T. ve Kiefer, W. R., (1994), Remote Sensing and Image Interpretation, Third Edition, John Wiley & Sons, Inc., New York, 750 pp.

Marangoz, A. M., Oruç, M. ve Büyüksalih, G., (2004), “Object-oriented Image Analysis and Semantic Network for Extracting The Roads and Buildings from IKONOS Pan-sharpened Images”, ISRPS 2004 Annual Conference, 19 - 23 July 2004, Istanbul, Turkey.

Marangoz, A. M., Karakış, S., Oruç, M. ve Büyüksalih, G., (2005), “Nesne-Tabanlı Görüntü Analizi ve IKONOS Pan-Sharpended Görüntüsünü Kullanarak Yol ve Binaların Çıkarımı”, 10.Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.

Marangoz, A. M., Alkış, Z., Büyüksalih, G. ve Akçın, H., (2006), “Verification of Information Contents and Cost Considerations Using Very High Resolution Space Imagery For Object Extraction”, Fifth International Symposium "Turkish-German Joint Geodetic Days", 28-31 March 2006, Berlin, Germany.

Marangoz, A. M., Oruç, M., Karakış, S. ve Sahin, H., (2006), “Comparison of Pixel-Based and Object-Oriented Classification Using IKONOS Imagery for Automatic Building Extraction – Safranbolu Testfield”, Fifth International Symposium "Turkish-German Joint Geodetic Days", 28-31 March 2006, Berlin, Germany.

Marangoz, A. M., Alkış, Z. ve Karakış, S., (2007) “Evaluation of Information Content and Feature Extraction Capability of Very High Resolution QuickBird Pan-Sharpended Image”, Conference on Information Extraction from SAR and Optical Data, with Emphasis on Developing Countries, 16-18 Mayıs 2007, İTÜ, İstanbul.

Marangoz, A. M., Alkış, Z. ve Büyüksalih, G., (2007) “Nesne-Tabanlı Otomatik Detay Çıkarımlarından Elde Edilen Vektör Ürünün CBS Ortamına Aktarılması ve Mevcut Diğer Verilerle Bütünleştirilmesi”, 11. Türkiye Harita Bilimsel ve Teknik Kurultayı, 02-06 Nisan 2007, ODTÜ, Ankara.

Navulur, K., (2007), Multispectral Image Analysis Using the Object-Oriented Paradigm, CRC Press, Taylor & Francis Group, 6000 Broken Sound Parkway NW, Suite 300, Boca Raton, FL 33487-2742.

Nobrega, R.A.A., O'hara, C.G. ve Quintanilha, J.A., (2006), “Detecting Roads in Informal Settlements Surrounding Sao Paulo City by Using Object-Based Classification”, 1<sup>st</sup> International Conference on Object-based Image Analysis (OBIA 2006), 4-5 June 2006, Salzburg, Austria.

Oruç, M., (2003), Zonguldak Bölgesindeki Doğal Olmayan Çevresel Değişimlerin Uydu Görüntü Verileri ile Analizi, Yüksek Lisans Tezi, ZKÜ Fen Bilimleri Enstitüsü.

Oruç, M., Marangoz, A. M. ve Büyüksalih, G., (2004), "Comparison of Pixel-based and Object-oriented Classification Approaches Using LANDSAT-7 ETM Spectral Bands", ISRPS 2004 Annual Conference, 19 - 23 July 2004, Istanbul, Turkey.

Özfidan, F., Topan, H., Şahin H. ve Karakış, S., (2005), "Yüksek Çözünürlüklü Uydu Görüntülerinin Bilgi İçeriklerinin Karşılaştırılması", IGSM&GHG 2005, İstanbul.

Padwick, (2005), "Pan Sharpening of High Resolution Satellite Imagery", DigitalGlobeWEB, <http://digitalglobe.com>.

Repaka, S. R., Truax, D. D., Kolstad, E. ve O'Hara, C. G., (2004), "Comparing Spectral and Object Based Approaches for Classification and Transportation Feature Extraction From High Resolution Multispectral Imagery", ASPRS 2004 Annual Conference, 23-28 May 2004, Denver, USA.

Stanag 3769: "Minimum resolved object sizes and scales for imagery interpretation", AIR STD 80/15, Edition 2, HQ USAF/XOXX(ISO) Washington D.C. 20330-5058, 1970, <http://astimage.daps.dla.mil/docimages/0000/26/72/108527.PD6>

Şahin, H., Büyüksalih G., Akçın, H., Topan, H., Karakış, S. ve Marangoz A. M., (2004), "Information Content Analysis of KVR-1000 Ortho-Image Based on the Available, Topographic Maps in the GIS Environment", EARSeL Workshop, Remote Sensing for Developing Countries, 26-29 September 2004, Cairo, Egypt.

Şahin, H., Topan, H., Karakış, S. ve Marangoz A. M., (2004), "Comparison of Object Oriented Image Analysis and Manual Digitizing for Feature Extraction", ISRPS 2004 Annual Conference, 19 - 23 July 2004, Istanbul, Turkey.

Şahin, H., Karakış, S., Topan, H., ve Marangoz, A. M., (2005), "KVR-1000 Uydu Görüntüsü Üzerinden Elle Sayısallaştırma ve Nesneye Yönelik Görüntü Analizi Yöntemlerinin Karşılaştırılması", 10. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.

Topan, H., (2004), Yörünge Düzeltmeli IRS-1C/1D Pankromatik Mono Görüntüsünün Geometrik Doğruluk ve Bilgi İçeriği Açısından İncelenmesi, Yüksek Lisans Tezi, ZKÜ Fen Bilimleri Enstitüsü.

Topan, H., Büyüksalih, G. ve Jacobsen, K., (2005), "Information Contents of High Resolution Satellite Images", EARSeL Workshop on 3D Remote Sensing, Porto.

Topan, H., Maktav, D. ve Büyüksalih, G., (2006), "Uydu Görüntülerinin Bilgi İçeriğinin Topoğrafik Harita Yapımı Açısından İncelenmesi", 1. Uzaktan Algılama ve CBS Çalıştayı ve Paneli, 25-27 Kasım 2006, İTÜ, İstanbul.

Topan, H., Maktav, D. ve Büyüksalih G., (2007), "Mapping Potential of Orbview-3 Panchromatic Image in Mountainous Urban Areas: Results of Zonguldak Test-Field", Urban Remote Sensing Joint Event 2007 (4th IEEE GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas & 6<sup>th</sup> International Symposium of Remote Sensing of Urban Areas), 11-13 April 2007, Paris, France.

Topan, H., Maktav, D., Jacobsen, K. ve Büyüksalih G., (2009), "Information Contents of Optical Satellite Images for Topographic Mapping", International Journal of Remote Sensing, 30, (7):1819-1827.

Topan, H., Oruç, M. ve Jacobsen K., (2009), “Potential of Manual and Automatic Feature Extraction from High Resolution Space Images in Mountainous Urban Areas”, ISPRS Hannover Workshop 2009 - High-Resolution Earth Imaging for Geospatial Information, 2-5 June 2009, Hannover, Almanya.

Toutin, T., (2003), “Error Tracking in Ikonos Geometric Processing using a 3D Parametric Model”, Photogrammetric Engineering&Remote Sensing, 69:43-51.

Tübitak Raporu (2006), “Batı Karadeniz Bölgesinin Uzay Görüntülerinin Harita Yapım Amaçlı Geometrik ve Semantik Analizi ve Veritabanı Oluşturulması”, Çevre, Atmosfer, Yer ve Deniz Bilimleri Araştırma Grubu, Tübitak Projesi No: 104Y050, Haziran 2006, Zonguldak

Van Der Sande, C., De Jong S.M. ve De Rooc A.P.J., (2004), “A Segmentation and Classification Approach of IKONOS-2 Imagery for Land Cover Mapping to Assist Flood Risk and Flood Damage Assessment”, ISPRS Journal of Photogrammetry & Remote Sensing, 58: 217-229.

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.

Weng, Q., (2008), Remote Sensing of Impervious Surfaces, CRC Press, Taylor & Francis Group, 6000 Broken Sound Parkway NW, Suite 300, Boca Raton, FL 33487-2742.

Wong, T. H., Mansor, S. B., Mispan, M. R., Ahmad, N. ve Sulaiman W. N. A., (2003), “Feature Extraction Based on Object Oriented Analysis”. ATC 2003 Conference, 20-21 May 2003, Malaysia.

Yan, G., (2003): “Pixel Based and Object-Oriented Image Analysis for Coal Fire Research”, Master Thesis, ITC, Netherlands.

Zhang, Y. ve Wang, R., (2004), “Multi-Resolution and Multi-Spectral Image Fusion for Urban Object Extraction”, ISPRS 2004 Annual Conference, 19 - 23 July 2004, Istanbul, Turkey.

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.

Zoej, M. J. V. (1999) “Mathematical Modelling and Geometric Accuracy Testing of IRS-1c Stereo-Images”, ISPRS Joint Workshop on Sensors and Mapping from Space 1999, Hannover, Germany.

## İNTERNET KAYNAKLARI

[1][http://www.nik.com.tr/2008/tr/sistem/uydu\\_goruntuleri/ikonos.html](http://www.nik.com.tr/2008/tr/sistem/uydu_goruntuleri/ikonos.html)

[2][http://www.nik.com.tr/2008/tr/sistem/uydu\\_goruntuleri/quickbird.html](http://www.nik.com.tr/2008/tr/sistem/uydu_goruntuleri/quickbird.html)

[3][http://www.digitalglobe.com/digitalglobe2/file.php/646/QuickBird\\_Imagery\\_Products-Product\\_Guide.pdf](http://www.digitalglobe.com/digitalglobe2/file.php/646/QuickBird_Imagery_Products-Product_Guide.pdf)

[4][http://www.digitalglobe.com/digitalglobe2/file.php/645/QuickBird\\_Imagery\\_Products-FAQ.pdf](http://www.digitalglobe.com/digitalglobe2/file.php/645/QuickBird_Imagery_Products-FAQ.pdf)

[5]<http://www.sieurasia.com/showpage.aspx?id=25>

**ÖZGEÇMİŞ**

Doğum tarihi 22.11.1976

Doğum yeri Zonguldak

Lise 1990–1994 TED Zonguldak Koleji

Lisans 1994–1999 Zonguldak Karaelmas Üniversitesi,  
Mühendislik Fakültesi  
Jeodezi ve Fotogrametri Mühendisliği Bölümü

Yüksek Lisans 1999–2002 Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü,  
Jeodezi ve Fotogrametri Müh. Anabilim Dalı, CBS ve  
Uzaktan Algılama Anabilim Dalı

Doktora 2003–2009 Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü,  
Jeodezi ve Fotogrametri Müh. Anabilim Dalı, CBS ve  
Uzaktan Algılama Anabilim Dalı

**Çalıştığı kurumlar**

1999–2008 Zonguldak Karaelmas Üniversitesi,  
Mühendislik Fakültesi, Uzman

2008-devam ediyor Zonguldak Karaelmas Üniversitesi,  
Mühendislik Fakültesi, Öğretim Görevlisi