

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**UYDU GÖRÜNTÜLERİNİN PİKSEL VE NESNE TABANLI
SINIFLANDIRMA SONUÇLARININ KARŞILAŞTIRILMASI
(DOĞU TRAKYA BÖLGESİ ÖRNEĞİ)**

**YÜKSEK LİSANS TEZİ
Serdar BAYBURT**

Anabilim Dalı : Jeodezi ve Fotogrametri Mühendisliği

Programı : Geomatik Mühendisliği

HAZİRAN 2009

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**UYDU GÖRÜNTÜLERİNİN PİKSEL VE NESNE TABANLI
SINIFLANDIRMA SONUÇLARININ KARŞILAŞTIRILMASI
(DOĞU TRAKYA BÖLGESİ ÖRNEĞİ)**

**YÜKSEK LİSANS TEZİ
Serdar BAYBURT
(501061629)**

Tezin Enstitüye Verildiği Tarih : 04 Mayıs 2009

Tezin Savunulduğu Tarih : 02 Haziran 2009

**Tez Danışmanı : Prof. Dr. Derya MAKTAV (İTÜ)
Diğer Jüri Üyeleri : Prof. Dr. Filiz SUNAR (İTÜ)
Doç. Dr. Gürcan BÜYÜKSALİH
(BİMTAŞ)**

HAZİRAN 2009

Sevgili hayat yoldaşım Emine Gönüler'e,

ÖNSÖZ

Arazi kullanımı ve arazi örtüsü haritaları bir kentin planlanması ve yönetimi gibi birçok alanda temel oluşturmaktadır. Bu haritaların üretimi, gelişen teknolojiye paralel olarak farklı verileri ve farklı yöntemleri beraberinde sürüklemiştir. Bu çalışmada, yaygın olarak kullanılan piksel tabanlı sınıflandırma ve yeni bir yaklaşım olan nesne tabanlı sınıflandırma yöntemleri farklı uydu görüntüleri kullanılarak incelenmiştir. Elde edilen sonuçlara dayanarak hangi yöntemin hangi uydu görüntüsünde arazi kullanımı haritası üretme noktasında ne kadar başarılı olduğu belirlenmiştir.

Bu çalışmanın yürütücülüğünü yapan, çalışmam boyunca yardımlarını ve bilgisini benden esirgemeyen çok değerli danışman hocam Prof. Dr. Derya MAKTAV'a teşekkürü bir borç bilirim.

Tecrübe ve vizyonu ile beni yönlendiren, uzaktan algılama konusunda yetişmemde büyük emek sahibi sayın hocam Doç. Dr. Gürcan BÜYÜKSALİH'e sonsuz şükranlarımı sunarım.

Tezim süresince yardımlarını esirgemeyen dostum, yol arkadaşım Yük. Müh. İsmail BÜYÜKSALİH'e ve işyeri arkadaşlarıma teşekkür ederim.

Her alanda desteklerini hiç eksik etmeyen babam Abdullah BAYBURT, annem Hamdiye BAYBURT ve kız kardeşim Öznur BAYBURT'a teşekkürlerimi sunarım.

Mayıs 2009

Serdar BAYBURT

(Mühendis)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
ÇİZELGE LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ VE ÇALIŞMANIN AMACI.....	1
2. UYDU GÖRÜNTÜLEME SİSTEMLERİNİN TARİHSEL SÜRECİ.....	3
3. UYDU GÖRÜNTÜLERİNİN ÇÖZÜNÜRLÜK PARAMETRELERİ	7
3.1 Radyometrik ve Geometrik Çözünürlük	7
3.1.1 Radyometrik çözünürlük	7
3.1.2 Geometrik çözünürlük	8
4. LANDSAT, IKONOS VE SPOT UYDU SİSTEMLERİ	9
4.1 Landsat	9
4.1.1 Landsat- 1, -2, -3.....	10
4.1.2 Landsat -4 ve -5	11
4.1.3 Landsat- 6	12
4.1.4 Landsat- 7	12
4.2 İkonos	12
4.3 SPOT	14
5. GÖRÜNTÜ SINIFLANDIRMA TEKNİĞİ.....	17
5.1 Piksel Tabanlı Sınıflandırma	17
5.1.1 Kontrollü sınıflandırma	17
5.1.1.1 Ortalamalar sınıflandırıcısına en kısa yakınlık	19
5.1.1.2 Paralel kenar sınıflandırıcısı.....	19
5.1.1.3 Gauss en yüksek olabilirlik sınıflandırıcısı	19
5.1.2 Kontrolsüz sınıflandırma	20
5.1.3 Melez (Hibrit) sınıflandırma.....	21
5.1.4 Spektral karışım analizi	21
5.1.5 Fuzzy (Bulanık) sınıflandırma.....	22
5.2 Sınıflandırma Doğruluğunun Değerlendirilmesi.....	23
5.2.1 Sınıflandırma hata matrisi	23
5.3 Nesne tabanlı sınıflandırma.....	24
5.3.1 Segmentasyon aşaması	24
5.4 Uygulamada Kullanılan Yöntemler	26
5.4.1 Piksel tabanlı en yüksek olabilirlik sınıflandırması (Maximum Likelihood Classification, (MLC))	26
5.4.2 Nesne tabanlı sınıflandırma	27

5.4.3 Homojen nesnelerin segmentasyonunda en uygun ölçeği seçmek için yeni bir yöntem	28
5.4.4 Nesne bazında en yakın komşuluk (Nearest Neighbour,NN) sınıflandırması	28
5.4.5 Çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması	29
6. UYGULAMA.....	31
6.1 Çalışma Alanı ve Veri Hazırlama.....	31
6.1.1 Çalışma alanı	31
6.1.2 Veri hazırlama	33
6.2 Uygulama Sonuçları	33
6.2.1 Spektral ayırt edilebilirlik	33
6.2.2 SPOT 5 görüntüsünün sınıflandırılması	37
6.2.2.1 SPOT 5 görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması.....	37
SPOT 5 görüntüsünün üyelik fonksiyonları ve fuzzy algoritmalarıyla nesne tabanlı sınıflandırma doğruluk analizi.....	51
6.2.2.2 SPOT 5 görüntüsünün piksel tabanlı sınıflandırılması	52
SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi	54
6.2.2.3 SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması	55
6.2.3 Landsat görüntüsünün sınıflandırılması	57
6.2.3.1 Landsat görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması.....	58
Landsat görüntüsünün üyelik fonksiyonları ve fuzzy algoritmalarıyla nesne tabanlı sınıflandırma doğruluk analizi.....	66
6.2.3.2 Landsat görüntüsünün piksel tabanlı en yüksek olabilirlik yöntemiyle sınıflandırılması	68
Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi	72
6.2.3.3 Landsat görüntüsünün piksel ve nesne tabanlı sonuçlarının karşılaştırılması	75
6.2.4 Ikonos görüntüsünün sınıflandırılması	77
6.2.4.1 Ikonos görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması.....	77
Ikonos görüntüsünün nesne tabanlı sınıflandırma doğruluk analizi.....	83
6.2.4.2 Ikonos görüntüsünün piksel tabanlı sınıflandırılması	85
6.2.4.3 Ikonos görüntüsü için piksel ve nesne tabanlı sonuçlarının karşılaştırılması	88
7. SONUÇLAR VE ÖNERİLER.....	91
KAYNAKLAR.....	93
EKLER.....	95
ÖZGEÇMİŞ.....	97

KISALTMALAR

ST	: Sütun Toplamı
ED	: Öklit Uzaklığı
MLC	: Maximum Likelihood Classifier
PCA	: Principal Component Analysis
NN	: Nearest Neighbour
BD	: Bhattacharya Distance
NASA	: National Aeronautics and Space Administration
ERTS	: Earth Resources Technology Satellite
SPOT	: Le Systeme Pour l' Observation de la Terre
MSS	: Multispectral Scanner
ETM	: Enhanced Thematic Mapper
TM	: Thematic Mapper
IFOV	: Instantaneous Field-of-View
HRV	: High Resolution Visible
RMSE	: Root Mean Squared Error
PAN	: Pankromatik
UTM	: Universal Transverse Mercator
WGS	: World Geodetic System
GSD	: Ground Sampling Distance
MOMS	: Modular Obtoelectronic Multispectral Scanner

ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Landsat misyonlarında kullanılan algılayıcılar	9
Çizelge 4.3 : Ikonos yörüngesinin özellikleri	13
Çizelge 4.4 : Ikonos görüntüsünün özellikleri	13
Çizelge 4.5 : Ikonos GEO ürün seçenekleri tablosu	14
Çizelge 4.6 : SPOT görüntüsünün özellikleri	16
Çizelge 6.1 : Piksel bazındaki öklit uzaklığı (ölçek parametresi = 1).	34
Çizelge 6.2 : Farklı ölçeklerdeki ED değerleri. a) ölçek parametresi = 5, b) ölçek parametresi = 10, c) ölçek parametresi = 20, d) ölçek parametresi = 30, e) ölçek parametresi = 40	34
Çizelge 6.3 : SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi	51
Çizelge 6.4 : SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları	51
Çizelge 6.5 : SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi. .	55
Çizelge 6.6 : SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.	55
Çizelge 6.7 : Landsat görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi	66
Çizelge 6.8 : Landsat görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları	67
Çizelge 6.9 : Landsat görüntüsünün piksel tabanlı sınıflandırma sonucunda oluşan hata matrisi.	74
Çizelge 6.10 : Landsat görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.	75
Çizelge 6.11 : Ikonos görüntüsünün nesne tabanlı sınıflandırılmasında uygulanan fonksiyon ve kurallar.....	81
Çizelge 6.12 : Ikonos görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi	83
Çizelge 6.13 : Ikonos görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları	83
Çizelge 6.14 : Ikonos görüntüsü için piksel tabanlı sınıflandırma sonuçları.	87
Çizelge 6.15 : Ikonos görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.	90

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1	: Yere izdüşülmüş pikseller arasındaki uzaklık (GSD).....	8
Şekil 3.2	: Landsat Uydularının temel konfigürasyonu.....	10
Şekil 6.1	: Çalışma alanı 1.....	32
Şekil 6.2	: Çalışma Alanı 2.....	32
Şekil 6.3	: Tarım-A, tarım-B ve tarım-C'ye ait ED değerlerinin altı farklı ölçek parametresinde karşılaştırılması.....	36
Şekil 6.4	: SPOT 5 görüntüsü (123 ve 213 bant kombinasyonu).....	37
Şekil 6.5	: Bina ve yolların karmaşık yapısı ve eklenecek olan vektörel veriler..	38
Şekil 6.6	: 1m Ikonos görüntüsü ve vektörel verilerin gücellenmesi.....	38
Şekil 6.7	: Vektörel veriler ile segmentasyon.....	39
Şekil 6.8	: Bina ve yol verilerinin sınıflandırmaya entegre edilmesi.....	39
Şekil 6.9	: Vektörel veriler için seviye tanımlanması.....	40
Şekil 6.10	: Seviye1'deki sınıflandırma sonucu.....	40
Şekil 6.11	: SPOT 5 görüntüsünün ikinci segmentasyon sonucu.....	41
Şekil 6.12	: Seviyenin oluşturulması ve fonksiyonu.....	41
Şekil 6.13	: Seviyeler arası sınıflandırma sonuçlarının aktarılması.....	42
Şekil 6.14	: Veri ve arka zeminin ayırımı.....	43
Şekil 6.15	: NDVI fonksiyonun tanımlanması.....	43
Şekil 6.16	: Yeşil alanların NDVI fonksiyonu ile birlikte sınıflandırılması ve minimum ve maksimum eşik değerleri.....	44
Şekil 6.17	: SPOT 5 görüntüsünün üçüncü ve son segmentasyon sonucu.....	45
Şekil 6.18	: Çalışma alanının 3 boyutlu görünümü ve tarım yapılan alanlar.....	46
Şekil 6.19	: Dijital yükseklik modelini sınıflandırmaya aktararak yeşil alt alanların çıkarımı.....	47
Şekil 6.20	: Dijital yükseklik modeli entegre edilmiş sınıflandırma sonuçları.....	48
Şekil 6.21	: Boş alanların çıkarımı ve ilgili fonksiyonu.....	48
Şekil 6.22	: Tarım-B ve C sınıflarının ayırımında kullanılan fonksiyon ve seviye1'deki sınıflar.....	49
Şekil 6.23	: SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucu.....	50
Şekil 6.24	: SPOT 5 görüntüsünde nesne tabanlı sınıflandırılmış alanlar ve grafiksel gösterimi.....	50
Şekil 6.25	: Toplanan örneklem alanların dağılımı.....	52
Şekil 6.26	: Tarım-B örneklem alanı ve yer gerçeği verisi ile doğrulama.....	52
Şekil 6.27	: SPOT 5 görüntüsü sınıflandırma sonucu.....	53
Şekil 6.28	: SPOT 5 görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.....	53
Şekil 6.29	: SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi için atılan rastgele 118 nokta ve dağılımı.....	54
Şekil 6.30	: SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizinde yer gerçeği ile karşılaştırılması.....	54

Şekil 6.31	: SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.....	56
Şekil 6.32	: SPOT görüntüsünün nesne ve piksel tabanlı sınıflandırma sonucunun irdelenmesi.....	57
Şekil 6.33	: Landsat görüntüsünün doğal bantlı (3,2,1) ve temel bileşenler analizi yapılmış hali.....	57
Şekil 6.34	: Landsat görüntüsünün segmentasyon sonucu.....	58
Şekil 6.35	: Landsat görüntüsü veri-arkaplan ayırımı.....	59
Şekil 6.36	: Landsat görüntüsü su ve su_değil sınıflarının ayırımı.....	60
Şekil 6.37	: Islak alan sınıfının ayırımında kullanılan fonksiyon.....	60
Şekil 6.38	: Toprak alan sınıfının tanımlanması.....	61
Şekil 6.39	: Landsat görüntüsünden “toprak alan” sınıfının çıkarılması ve fonksiyonu.....	61
Şekil 6.40	: Landsat görüntüsü “çayır_çimen” sınıfının çıkarımı ve fonksiyonu.....	62
Şekil 6.41	: Landsat görüntüsünde çalılık sınıfının çıkarımı ve fonksiyonu.....	63
Şekil 6.42	: Landsat görüntüsünde en yakın komşuluk sınıflandırması için özellik uzayının tanımlanması.....	64
Şekil 6.43	: Sınıflandırmaya giren sınıfların son şekli.....	64
Şekil 6.44	: Landsat görüntüsünün nesne tabanlı sınıflandırılıp CBS ortamında haritalanması.....	65
Şekil 6.45	: Landsat görüntüsünden nesne tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.....	65
Şekil 6.46	: Doğruluk analizi için üretilen 112 nokta ve dağılımı.....	66
Şekil 6.47	: Landsat görüntüsünün piksel tabanlı sınıflandırılırken farklı band kombinasyonları ve yüksek çözünürlüklü görüntülerle irdelenmesi.....	69
Şekil 6.48	: Yerleşim sınıfına ait örneklem alanının toplanması.....	70
Şekil 6.49	: Tarım-A sınıfına ait örneklem alanının toplanması.....	70
Şekil 6.50	: Toplanan örneklem alanları ve dağılımı.....	71
Şekil 6.51	: Landsat görüntüsünün nesne tabanlı sınıflandırılıp CBS ortamında haritalanması.....	71
Şekil 6.52	: Landsat görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.....	72
Şekil 6.53	: Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi için atılan rastgele 118 nokta ve dağılımı.....	72
Şekil 6.54	: Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi yapılırken yer gerçeği ile karşılaştırma.....	73
Şekil 6.55	: SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.....	75
Şekil 6.56	: Landsat görüntüsündeki yerleşim sınıfının nesne ve piksel tabanlı sınıflandırma sonuçları.....	76
Şekil 6.57	: Sınıflandırılacak olan Ikonos görüntüsünün farklı ölçek ve bant kombinasyonları.....	77
Şekil 6.58	: Sınıflandırmaya dahil edilen vektörel veriler.....	78
Şekil 6.59	: Ikonos görüntüsünün ikinci segmentasyonu.....	78
Şekil 6.60	: Ikonos görüntüsünde yeşil alan ve alt türlerinin ayırımında kullanılan fonksiyonlar.....	79
Şekil 6.61	: Ikonos görüntüsünün üçüncü ve son segmentasyonu.....	80
Şekil 6.62	: Tarım-A sınıfı için oluşturulan fonksiyon.....	80

Şekil 6.63	: İkonos görüntüsünün nesne tabanlı sınıflandırma sonucu.....	82
Şekil 6.64	: İkonos görüntüsünden nesne tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.....	82
Şekil 6.65	: İkonos görüntüsünde toplanan örneklem alanlar ve dağılımı.....	85
Şekil 6.66	: İkonos görüntüsünün piksel tabanlı sınıflandırma sonucu.....	86
Şekil 6.67	: İkonos görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.....	86
Şekil 6.68	: Sınıflandırılan İkonos görüntüsünün yer gerçeği bilgisi ile karşılaştırılması.....	87
Şekil 6.69	: İkonos görüntüsünün piksel tabanlı sınıflandırılmasında karışan sınıflar.....	88
Şekil 6.70	: Piksel ve nesne tabanlı sınıflandırma sonucunda tuz-biber etkisi.....	89
Şekil 6.71	: Şekil 6.69’da gösterilen alandaki karışıklığın nesne tabanlı sınıflandırma sonucu.....	89
Şekil 6.72	: İkonos görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.....	90
Şekil A.1	: İkonos görüntüsünde sınıflar arası öklit uzaklıklarının grafiksel gösterimi a) Scale5, b) Scale10, c) Scale20, d) Scale30, e) Scale40..	96

UYDU GÖRÜNTÜLERİNİN PİKSEL VE NESNE TABANLI SINIFLANDIRMA SONUÇLARININ KARŞILAŞTIRILMASI (DOĞU TRAKYA BÖLGESİ ÖRNEĞİ)

ÖZET

Son yıllarda gerek uydu teknolojilerindeki, gerekse bilgisayar yazılım ve donanımlarındaki gelişmeler uzaktan algılama teknolojilerine ve bu teknolojilerin kullanılmasıyla üretilebilecek verilere yeni bir boyut kazandırmıştır.

Günümüzde internet aracılığıyla da erişilebilen uydu görüntüleri hemen herkes tarafından kullanılabilir. Uzaktan algılama ile kentsel planlama, haritacılık, yer altı ve yer üstü kaynakların incelenmesi, su havzalarının yönetimi, kaçak yapı takibi gibi pek çok mühendislik çalışmaları hızlı ve ekonomik bir biçimde gerçekleştirilmektedir.

Arazi örtüsü ve arazi kullanımı bilgileri şehir planlama ve yönetimi için temel oluşturmaktadır. Klasik arazi kullanımı haritalamaları uydu görüntülerinin görsel yorumlanmasıyla olup pahalı, zaman kaybettirici ve kişisel olmaktadır. Bu nedenle, uzmanlar yıllardır otomatik veya yarı otomatik yaklaşımları araştırmaktadır. Yüksek çözünürlüklü uydu görüntüleri (örn. Ikonos, SPOT 5) özellikle kentsel alanlardaki uygulamalarda büyük kolaylıklar sağlamaktadır.

Bu çalışmada çeşitli uydu görüntülerinin farklı yöntemlerle sınıflandırılmasıyla oluşturulan arazi örtüsü ve arazi kullanımı haritalarının sonuçları incelenmiştir. Yaygın olarak kullanılan piksel tabanlı sınıflandırma yöntemlerinden en yüksek olabilirlik sınıflandırıcısı, yüksek ve orta çözünürlüklü uydu görüntülerine uygulanmıştır. Yüksek çözünürlüklü uydu görüntülerinden olan Ikonos ve SPOT 5’de piksel boyutunun küçülmesiyle sınıflararası spektral ayırt edilebilirlik düşmüş ve bu da sınıflandırma sonuçlarına yansıyan birtakım sorunların oluşmasına neden olmuştur. Buna karşın orta çözünürlüklü Landsat görüntüsünde ise aynı yöntem %7’lik bir farkla daha başarılı sonuç vermiştir. Sadece piksellerin istatistiksel analizine dayalı piksel tabanlı sınıflandırma yöntemine alternatif olan nesne tabanlı sınıflandırma, görüntüde sadece pikseller yerine anlamlı nesnelerin görüntülenebilmesine imkan sağlamaktadır. Bu nesnelere ait ölçek, renk, sıklık ve komşuluk gibi birtakım özelliklerin ve üyelik fonksiyonlarının da kullanılmasıyla yapılan nesne tabanlı sınıflandırma, piksel tabanlı olana göre Ikonos görüntüsü için %62’ye karşın %79’la, SPOT 5 görüntüsü için ise %67.5’e karşın %86’lık bir doğrulukla daha iyi sonuç vermiştir.

Nesne tabanlı sınıflandırmanın anahtar adımı olan segmentasyonda en uygun ölçek parametresini seçebilmek için piksel tabanlı sınıflandırmada sınıf ayırt edilebilirlik indeksi olarak bilinen öklit uzaklığı (Euclidian Distance: ED) yardımıyla yeni bir yöntem geliştirilmiştir. Piksel ve daha büyük ölçek seviyelerindeki ED değerleri arasındaki bu karşılaştırma, segmente edilen nesneleri en iyi sınıflandırma doğruluğuna ulaştıran bir potansiyel olan en uygun ölçeğin belirlenmesine yardımcı olmuştur.

Sınıflandırma doğruluğunu arttırmak ve sınıflar arası karışıklığı minimuma indirmek için yol ve binalara ait vektörel veriler sınıflandırmaya entegre edilmiştir. Aynı amaçla, dijital yükseklik modeli bulanık mantık fonksiyonlarıyla ilişkilendirilerek bazı türlerin ayırımına gidilmiştir. Birtakım matematiksel fonksiyonlar geliştirilip boş alan ve yeşil alan alt türleri çıkarılarak sınıflandırmaya yeni bir boyut kazandırılmıştır. Landsat TM (30m), SPOT 5 (2.5m pan-sharpaned) ve Ikonos (4m multispektral) görüntüleri için ilgili çalışma alanlarında piksel ve nesne tabanlı olmak üzere toplam altı adet sınıflandırma ve doğruluk analizi yapılarak sonuçlar irdelenmiş ve arazi örtüsü haritalanması konusunda bazı önerilerde bulunulmuştur.

COMPARISON OF THE PIXEL-BASED AND OBJECT-BASED CLASSIFICATION RESULTS OF SATELLITE IMAGERIES (CASE OF EASTERN THRACE)

SUMMARY

The development in satellite technology, computer hardware and software has marked a new epoch for remote sensing technology and the data which can be produced by using these technologies.

Nowadays, almost everyone has been using the satellite imageries which can also be reached via the Internet. Engineering studies like urban planning, mapping, underground and ground resource monitoring, watershed management, illegal constructing, etc. can be established via remote sensing in an economic and fast way.

Land-cover and land-use data are essential for urban planning and management. Traditional land-use mapping by visual image-interpretation is expensive, time consuming and often subjective. Researchers have been searching for automatic or semi-automatic approaches for many years. High spatial resolution images such as Ikonos and SPOT 5 offers great opportunities, especially for application in urban areas.

In this study, results of the land-cover and land-use maps obtained by classifying the several satellite images have examined in different methods. Maximum likelihood classifier which is one of the most popular pixel-based classification method have applied to the middle and high spatial resolution images. Smaller pixel size and poor spectral seperability affect the classification results badly for the high resolution Ikonos and SPOT 5 images. In contrast to this the required success have achieved for the middle spatial resolution Landsat images with 81% accuracy. Having been an alternative approach to the pixel based classification method which only based on the analysis of single pixels, object based classification has allowed the meaningful objects in the image instead of single pixels. Object-based classification uses scale, color, shape, compactness and context information and membership functions of these objects. In accordance with the pixel-based one object-based classification has resulted with the 17% extra accuracy for the Ikonos images and 19% extra accuracy for the SPOT 5 images.

Specifically for object segmentation, which is the key step in object-based classification, a new method has been developed to choose the optimal scale parameter with the aid of Euclidean distance (ED), a well known index of class seperability in traditional pixel-based classification. A comparison of ED values at the pixel level and the series of larger scales assisted us to determine an optimal scale at which the segmented objects have the potential to achieve the best classification accuracy.

The vector data of the houses and roads have integrated to the classification for minimizing the mixed classes and getting the high accuracy. Some classes have been

extracted by the digital elevation model which has been related with the membership functions. A different epoch has been gained by obtaining the sub-classes of green areas and barren ground by creation of new arithmetic features. In total six classifications and accuracy assessments have completed in study areas by using pixel and object based classification included with the Landsat TM (30m), SPOT 5 (2,5m pan-sharpaned) and Ikonos (4m multispektral) images. Some suggestions have been proposed by analysing the results.

1. GİRİŞ VE ÇALIŞMANIN AMACI

Arazi örtüsü ve arazi kullanımı bilgileri şehir planlama ve yönetimi için temel oluşturmaktadır. Arazi örtüsü (land cover) ve arazi kullanımı (land use) kavramları sıklıkla karıştırılmaktadır. Arazi kullanımı, arazinin insanlar tarafından daha çok ekonomik bakımından fonksiyonel rolü gözetilerek kullanımı şeklinde tanımlanır, gözlemlerle bile her zaman tespit edilemeyebilir. Buna karşın arazi örtüsü (land cover) ise görsel bir şekilde tespit edilebilmekte ve bina, yol, park alanları, orman, ve nehirler şeklinde ifade edilmektedir (Campbell, 1996-2002).

Piksel tabanlı görüntü sınıflandırma algoritmaları görüntüde semantik bilgiye yer vermez ve bu nedenle tipik arazi örtüsündeki doğal heterojenliğin çıkarımı açısından pek uygun değildir. Sonuçlanan tematik haritalar tuz-biber etkisi ile genel anlamda kalitesini düşürmektedir. Ya çok genel bir arazi örtüsü bilgisi şeklinde sonuçlanmaktadır ya da sınırlı doğrulukla ilave detaylı haritalar oluşmaktadır (Franklin et al. 2003). Nesne tabanlı görüntü analizinin gelişmesi, aslında piksellerin yanında anlamlı nesneler ve karşılıklı ilişkilerle görüntünün yorumlanması için bazı bilgilerin kullanım gerekliliğinden kaynaklanmaktadır. Detaylı bir nesne tabanlı görüntü analizinde ilk olarak, seçilen bir çözünürlükteki homojen görüntü nesneleri çıkarılır ve sonrasında sınıflandırılır. Spektral bilgiye ilaveten nesnelerden elde edilen ve görüntünün sınıflandırılmasında kullanılan biçim, doku, alan, içerik, diğer nesnelerle topolojik ilişkiler ve diğer nesne tabakalarındaki bilgiler gibi çoklu bilginin kullanımına izin vermektedir (Shackelford and Davis 2003).

Bilinen çoğu sınıflandırma yaklaşımları mevcut piksellerin istatistiksel analizine bağlıdır. Bu yaklaşımlar daha düşük çözünürlükteki görüntüler için uygun olmaktadır. Yüksek çözünürlüklü görüntülerin elde edilebilmesiyle birlikte sınıflandırma doğruluğunun da aynı şekilde gelişeceği umulmaktadır. Fakat sınıflandırılan arazi örtüsü tipleri genellikle daha düşük ölçeklere uygun olmaktadır. Daha iyi bir mekansal çözünürlükle birlikte çıkarılabilen alt sınıfların sayısı da aynı şekilde artmaktadır. Sınıflar içindeki spektral varyansın artması spektral olarak karışmış arazi örtü tiplerinin ayrımını daha zor yapabilir (Shaban and Dikshit 2001).

Son arařtırmalar, yksek znrlkl grntlerin piksel tabanlı sınıflandırma yntemleriyle sınıflandırılmasının uygun olmadığını gstermektedir (Schiewe et al. 2001). Alternatif bir zm ise, mekansal komřuluk zelliklerinin sınıflandırma iřlemine dahil edilmesiyle mmkn olmaktadır. Nesne tabanlı sınıflandırma ile bu tr mekansal bilgiler sınıflandırma iřlemine dahil edilmektedir. Bu yaklařım ayrıca coğrafiya veya ekolojik evre gibi disiplinlerle de aynı perspektiftedir. Sonu olarak bu yaklařım, piksellerin yalın halde kullanılması yerine anlamlı nesnelerin grntlenebilmesini gerektiren alıřmalarda daha uygun olmaktadır (Blaschke ve Strobl 2001).

1970’li yılların bařlarından itibaren bir ok bilgisayar destekli sınıflandırma yntemleri geliřtirilmiřtir (Curran, 1985; Schowengerdt, 1997; Richards ve Jia, 1999; Mather, 1999; Tso ve Mather, 2001; Campbell, 2002). Mevcut oğ yaklařım, uzaktan algılama grntsndeki spektral bilgi arazinin fiziksel zelliğinin elektromanyetik yansıtımından oluřtuğ iin, piksel tabanlı olup yalnızca ok bantlı spektral verinin kullanılmasıyla arazi rtsnn haritalanmasını oluřturmaktadır. Mevcut oğ sınıflandırıcı, algılayıcıların kısıtlı mekansal znrlğnn sebep olduğ karıřmıř piksellerden dolayı yksek doğruluk elde edememiřtir. Bu nedenle bu alıřmada bazı yksek ve orta znrlkl grntler test edilerek hangilerinin hangi yntemle arazi rts haritası retimi aısından bařarılı olduğ ortaya konulmuřtur.

2. UYDU GÖRÜNTÜLEME SİSTEMLERİNİN TARİHSEL SÜRECİ

Teknolojiye paralel olarak gelişim gösteren uzaktan algılama, pek çok bilim dalı tarafından oldukça yoğun bir şekilde kullanılmaktadır. Özellikle 1972 yılında NASA (National Aeronautics and Space Administration) tarafından ilk adı ERTS (Earth Resources Technology Satellite) olan Landsat serisi uyduların devreye sokulması ile somut ilerlemeler kaydeden bu teknoloji; çevre, orman, tarım, jeoloji, oşinografi, meteoroloji ve diğer benzer disiplinlerde büyük bir ilgi görmüştür.

Bununla birlikte, uzaktan algılamanın haritacılık ya da daha geniş kapsamda yüksek doğruluklu konumsal bilgi edinme açısından etkin kullanımı, 1980'li yıllarda ivme kazanmıştır. Yörüngedeki Landsat uydusunun kaba yer piksel boyutu ancak küçük ölçekli haritaların konum doğruluğu ve bilgisini sağlamakta ve ilgili uydu ürünleri özellikle yorumlama amaçlı çalışmalarda yoğun biçimde kullanılmaktaydı.

Topoğrafik amaçlı uygulamalara yönelik olarak Fransızların 1986 yılında yörüngeye yerleştirdikleri SPOT uydusu özellikle pankromatik bantta verdiği 10 m'lik yer çözünürlüğü ile konumsal bilgi edinme de büyük gelişmelere neden olmuştur (Önder, 2002). Ayrıca, bugün uydu görüntülerinin değerlendirilmesinde kullanılan Kratky, Gagan, Toutin, Jacobsen, Okamoto ve diğerlerine ait parametrik matematiksel modeller, SPOT uydusu tarafından çekilen görüntülerinin incelenmesi yoluyla geliştirilmiştir.

SPOT uyduları sağladıkları yan-bakış yeteneğiyle (Şekil 2.2) farklı yörünge geçişlerinden aynı alanının görüntülenmesi, haliyle ilgi alanının üç boyutlu incelenmesini sağlayacak stereo-görüntülerinin çekimine olanak vermişlerdir. Burada ki ana olumsuz unsur, stereo-çiftlerin çekimi arasında geçen zaman dilimidir. Bu süreç günlerden mevsimlere kadar uzanabilmekte, özellikle stereo-değerlendirmenin görüntü eşleştirme aşamasında görüntüler arasındaki radyometrik farklılıktan dolayı eşleşme sorunlarına ve üretilen modeller üzerinde boşluklara sebep olmaktadır. Bu sorun, yukarıdaki MOMS uydularının sağladığı

aynı yörünge üzerinde kısa aralıklı (stereo-çiftlerin çekim aralığı 120sn'dir) çekim yöntemiyle aşılmıştır.

1988 yılından itibaren kullanılmaya başlanan Hint IRS serisi uydulardan özellikle IRS-1C/1D, geniş bir alanı görüntüleyebilmesi ve 5.8m yer piksel çözünürlüğüne sahip olması nedeniyle, haritacılık açısından çeşitli araştırmalara konu olmuş ve görüntüleme geometrisini inceleyen modeller geliştirilmiştir (Jacobsen, 1998). Bu uyduların en önemli sorunu, stereo-görüntü alımı sırasında dönmeden dolayı uydunun harcadığı yakıtın çok yüksek düzeyde olması nedeniyle, stereo-görüntülemenin oldukça sınırlı olmasıdır.

Rusların KVR-1000 sistemi 1.56m piksel boyutuyla, Batı dünyasında önemli kararların alınması sebep olmuştur. Özellikle 10 m'den daha yüksek çözünürlüğe sahip uydu sistemi yerleştirilmesine onay vermeyen ABD (Amerika Birleşik Devletleri), Clinton Hükümetinin 1997 yılında aldığı bir kararla yüksek-çözünürlüklü uyduları üretecek olan şirketlerin kurulmasına onay vermiştir. SpaceImaging, DigitalGlobe ve son olarak GeoEye gibi şirketler bu kararın ürünleridir.

Günümüzde bu süreç, 1 metrenin altında doğrulukta konum bilgisi sağlayan ve büyük ölçekli harita içeriğinin elde edilmesine olanak veren uydu sistemleriyle daha büyük bir ivme kazanmıştır. SpaceImaging'in 24 Eylül 1999 tarihinde yörüngeye yerleştirilen Ikonos-2 uydusu, 1m çözünürlüklü pankromatik ve 4m çözünürlüklü çok bantlı görüntü kaydı yapabilmektedir. Daha da yüksek çözünürlük düzeyi, DigitalGlobe'un QuickBird uydusunun 60cm pankromatik ve 2.8m çok bantlı görüntüleriyle sağlanabilmiştir. Orbimage'in OrbView-3 uydusundaki pankromatik görüntüleme sistemi ise 1m yer piksel çözünürlüğüne sahip görüntüler elde edebilmektedir. SpaceImaging ve Orbimage'in birleşmesinden oluşan GeoEye ve DigitalGlobe firmaları, GSD'si 50 cm'nin altında olan görüntüler üretmiştir. Günümüzdeki yaygın tartışma, bu tür uydu ürünleriyle 1:5,000 ölçekli haritaların üretilip üretilmeyeceğidir. Geometrik doğruluk sağlanması açısından bu mümkündür. Ancak, bilgi içeriğinin çıkarılması ayrı bir konudur ve yapılan araştırmalar, özellikle QuickBird uydu görüntüsünün, en iyi durumda, 1:6,000 ölçekli haritaların içeriğini verebildiğini göstermiştir (Büyüksalih, 2004).

Yüksek çözünürlüklü uydu görüntüleri, özellikle, günümüz web-tabanlı servisleri GoogleEarth (www.googleearth.com) ve VirtualEarth (local.live.com) teknolojilerinin veri tabanlarında diğer tür orta-düzey çözünürlüklü uydu görüntüleriyle yoğun biçimde kullanılmaktadır.

3. UYDU GÖRÜNTÜLERİNİN ÇÖZÜNÜRLÜK PARAMETRELERİ

Konuma bağlı bilgi elde etmede uzaktan algılama görüntülerinin kullanımı giderek artmaktadır. Bunun pek çok nedeni vardır. Bunların başlıcaları, teknolojiye paralel olarak geometrik, radyometrik, spektral ve zamansal çözünürlüğün artması, bunun yanında görüntülerin kontrol noktalarına ihtiyaç duyulmadan da yer koordinat bilgisi ile birlikte elde edilebilmesidir. Bununla beraber, atmosferik koşullar, güneş yükseklik açısı ve nesneler arasındaki geometrik ayırım ve radyometrik zıtlık, ayrıca etkin piksel boyutu, konuma bağlı bilgi elde edilmesini ve görüntülerin içerdiği bilginin verimli bir şekilde çıkartılmasını etkilemektedir (Topan vd., 2004). Şu da unutulmamalıdır ki sivil kullanımdaki ticari görüntüleme sistemlerinin artışı, görüntülerin fiyatlarını da uygun düzeye çekmektedir.

Bu bölümde, uzaktan algılama görüntülerinin değerlendirilmesi açısından ana etkenlerden özellikle radyometrik ve geometrik çözünürlük kavramları üzerinde durulmuştur.

3.1 Radyometrik ve Geometrik Çözünürlük

Uzaktan algılama görüntülerinin kalitesini belirleyen önemli özelliklerden ikisi radyometrik ve geometrik çözünürlüktür. Bunlar, çeşitli nedenlerle bazı bozunumlara uğramakta ve bazı düzeltmelere tabi tutulmaktadır. Aşağıda, radyometrik ve geometrik çözünürlük kavramları hakkında bazı açıklayıcı bilgiler verilmiştir.


3.1.1 Radyometrik çözünürlük

Radyometrik çözünürlük, ilgi alanındaki en ufak enerji değişimlerini ayırt edebilme veya kaydetme yeteneğidir. Uzaktan algılamada elde edilen görüntüler, yeryüzünden yansıyan ve yayılan elektromanyetik enerjinin kayıdır. Özde analog formdaki bu enerji, analog'tan dijitale (A/D) dönüştürücüler sayesinde, $2b$ ile ifade edilen ve sistemden sisteme değişen bir aralığa bölünerek sayısallaştırılırlar. Burada b , bit işlem sayısı anlamına gelmektedir. Örneğin, SPOT 5 uydusu farklı gri

değeri veren görüntüler çekmektedir. Yüksek çözünürlüklü Ikonos-2 uydusu ise farklı gri değeri üreterek görüntüleri kaydetmektedir. Ancak, 11-bitlik Ikonos görüntülerinin gerçekte 2048 gri değerinden daha azını içerdikleri bilinmektedir (Baltsavias vd., 2001).

3.1.2 Geometrik çözünürlük

En basit şekliyle geometrik çözünürlük, bir görüntüleme sistemi tarafından ayrık olarak kaydedilebilen iki nesne arasındaki en küçük uzaklık olarak tanımlanabilir ve bunu ortaya koyan en uygun ölçüt, görüntünün GSD değeridir. Ancak, bu büyüklük, algılayıcı piksel boyutundan farklı olarak, yeryüzüne projekte edilmiş piksellerin merkezleri arasındaki uzaklığı ifade etmektedir (Şekil 3.1). Geometrik çözünürlükle radyometrik çözünürlük arasında bir ters ilişki söz konusudur. Piksel boyutu küçüldükçe, üzerine düşen enerji azalmakta ve küçük piksel boyutlarında gürültü sinyale göre daha baskın hale gelmektedir. Bu durum, belirli bir piksel boyutundan sonra, piksel boyutu küçülmesine rağmen, geometrik doğruluğun değişmemesine sebep olmaktadır. Bu durumun geçerliliği, 10 m yer piksel boyutlu SPOT stereo-görüntülerinden hava fotoğraflarıyla karşılaştırıldığında daha başarılı eşleştirme düzeyinin sağlanması ve ayrıca fotogrametrik nirengi etkinliğinin ve doğruluğunun küçük piksel boyutlarında belli bir noktadan sonra artmamasıdır (Büyüksalih ve Li, 2003).



Şekil 3.1 : Yere izdüşülmüş pikseller arasındaki uzaklık (GSD)

4. LANDSAT, IKONOS VE SPOT UYDU SİSTEMLERİ

Bu bölümde uygulamada kullanılacak olan Landsat, SPOT ve Ikonos uydu verilerinin teknik özelliklerine yer verilmiştir.

4.1 Landsat


NASA, ERTS (Earth Resources Technology Satellites) proje çalışmasına 1967 yılında başlamıştır. İlk aşamada, ERTS-1, 23 Temmuz 1972 yılında fırlatılmıştır ve 6 Ocak 1978 yılına kadar yörüngede kalmıştır. ERTS-2'nin 22 Ocak 1975 yılında fırlatılmasından önce NASA, ERTS programını diğer bir planlanmış misyon olan "Seasat" oşinografi uydu programından ayırmak için programın ismini "Landsat" olarak değiştirmiştir. Bu nedenle, ERTS-1, Landsat-1 olarak adlandırılmış ve tüm sonraki seri uydularda Landsat ismini almıştır. Landsat uyduları arasında 1-5 ve 7 misyonları başarılı şekilde yörüngeye yerleştirilirken Landsat-6 misyonu başarısızlıkla sonuçlanmıştır. Çizelge 4.1'de bu sistemlerin spektral algılama ve mekansal çözünürlükleri verilmektedir.

Çizelge 4.1 : Landsat misyonlarında kullanılan algılayıcılar

Misyon	Algılayıcı	Algılama aralığı (µm)	Mekansal çözünürlük (m)
1,2	RBV	0.475- 0.575	80
		0.580- 0.680	80
		0.690- 0.830	80
3		0.505- 0.750	30
1-5	MSS	0.5- 0.6	79/82
		0.6- 0.7	79/82
		0.7- 0.8	79/82
		0.8-1.1	79/82
3		10.4-12.6	240
4,5	TM	0.45- 0.52	30
		0.52- 0.60	30
		0.63- 0.69	30
		0.76- 0.90	30
		1.55-1.75	30
		10.4-12.5	120
		2.08- 2.35	30
6	ETM	TM bantı üzerine + 0.50- 0.90	30(120m termal bant) 15 (pan)
7	ETM+	TM bantı üzerine + 0.50- 0.90	30 (60m termal bant) 15 (pan)

4.1.1 Landsat- 1, -2, -3

Şekil 4.1'de Landsat- 1, -2 ve -3 uydularının temel konfigürasyonu gösterilmektedir. Uydular yaklaşık 815 kg ağırlığında ve yaklaşık 900 km düzeyinde yörüngesel yüksekliktedir. Yaklaşık 9° açıyla ekvator'dan geçmektedir ve birbirini izleyen yörüngeler ekvator'dan yaklaşık 2760 km uzaklıkta yer almaktadır. Algılayıcılar sadece 185km genişliğinde uydu görüntüsü kaydettiğinden, aynı günde birbirini izleyen yörüngeler arasında görüntü örtüsünde büyük boşluklar oluşmaktadır. Yörünge'nin aynı noktadan geçmesi 18 gün almaktadır. Bu nedenle, uydunun dünyayı 18 günde bir veya yılda 20 kez görüntüleme kapasitesi vardır.



Şekil 3.2 : Landsat uydularının temel konfigürasyonu

Landsat-1, -2, -3 içindeki MSS sistemi, 185 km genişlikli taramada 4 bantı içermektedir. İki görünür bant ($0.5-0.6 \mu\text{m}$ /yeşil ve $0.6-0.7 \mu\text{m}$ /kırmızı) ve iki yakın kızılötesi bant ($0.7-0.8 \mu\text{m}$ ve $0.8-1.1 \mu\text{m}$). MSS tarayıcısının anlık görüş alanı (IFOV) karedir ve hücre boyutu yaklaşık 79m olan GSD üretmektedir. Toplam görüş açısı yaklaşık 11.56° 'dir. Sistemin dönel aynası her 33 milisaniyede bir salınmaktadır. Bu tür bir düzenleme, her biri 6 detektörlü (her satır için bir adet)

dört adet dizini (her bir bant için bir adet) gerektirmektedir. Yer örnekleme aralığı 56 m düzeyine elde edilebilmektedir.

Bu durumda görüntü piksel boyutu, 56x79 m olmakta ve her bir pikselin parlaklık değeri gerçekte 79x79 m'lik yer çözünürlük hücresinden üretilmektedir. Sonuçta bir MSS görüntüsü; 2340 tarama satırı, her satırda 3240 piksel ve haliyle bant başına 7,581,600 pikseli içermektedir.

4.1.2 Landsat -4 ve -5

Landsat- 4 ve -5 önceki Landsat serisi uydulara benzer şekilde tekrarlı, dairesel, güneş eş-zamanlı ve yakın-kutupsal yörüngelere yerleştirilmiştir. Ancak, bu yörüngelerin yüksekliği 900km'lerden 705km'ye düşürülmüştür. Daha alçak yörünge, daha iyi GSD'li görüntülerin çekimine olanak vermiştir. TM, MSS ile karşılaştırıldığında hem spektral bant sayısı hemde geometrik ve radyometrik açıdan çok daha üst düzeyli bir algılayıcıdır. Dört adet bant yerine 7 adet spektral bantı vardır ve bantlar spektrumun görünür (mavi), orta-kızılötesi ve termal kısımlarını içermektedir. Geometrik açıdan TM, 30m GSD'li veri (120m'lik termal bant hariç) toplamaktadır. Böylece, yer piksel boyutu 2.6 kat azalmış, bu da jeodezik konum doğruluğunu artırmıştır. Çizelge 4.2, TM'in yedi spektral bantının ana özelliklerini ortaya koymaktadır.

Çizelge 4.2: TM spektral bantları ve özellikleri

Bant	Dalga boyu (µm)	Renk	Ana uygulamalar
1	0.45- 0.52	Mavi	Bu bant su kitlelerini delip geçebilmektedir, bu özellik, onu kıyı sularının analizi için kullanışlı yapmaktadır. Bu bant, ayrıca, toprak/bitki ayırımı, orman türü haritalaması ve kültürel detayların tanımlanmasında kullanılabilir.
2	0.52- 0.60	Yeşil	Bitki örtüsü ayırımında yeşil yansıma kullanılmaktadır. Ayrıca kültürel detayların tanımlanmasında kullanışlıdır.
3	0.63- 0.69	Kırmızı	Bitki tür ayırımını sağlamak için klorofil geçirgenlik bantında algılamaya vakfedilmiştir.
4	076- 0.90	Yakın kızılötesi	Bitki türü, tazeliği, biyomass içeriği, su topluluklarının haritalaması, toprak nemi belirleme çalışmalarında
5	1.55-1.75	Orta kızılötesi	Toprak nemi ve bitki nemi içeriği için belirleyicidir. Ayrıca, karı buluttan ayırmada kullanılır.
6	10.4-12.5	Termal kızılötesi	Bitki stres analizi, toprak nemi belirleme, sıcaklık haritalamasında kullanılmaktadır
7	2.08- 2.35	Orta kızılötesi	Mineral ve kaya türlerinin ayırımı için kullanışlıdır. Ayrıca bitki nem içeriğine de duyarlıdır.

4.1.3 Landsat- 6

Landsat-6'nın 5 Ekim 1993 yılındaki fırlatımı başarısızlıkla sonuçlandı. Bu uydu, Landsat -4 ve -5'in yörünge özelliğini içerirken algılayıcı olarak ETM algılayıcısını kullanmaktaydı. Landsat- 4 ve -5 ile veri sürekliliği sağlamak için ETM, TM ile benzer 7 spektral bantta ve eşit mekansal çözünürlükte algılama yapacaktı. ETM'in TM ile karşılaştırıldığında artışı, 15 m GSD'li 0.50- 0.90µm arasında algılama yapan 8.nci bir bantı "pankromatik bant" içermesiydi. Bu yüksek mekansal çözünürlüklü pankromatik bant verisi, 15m çözünürlükte renkli görüntü üretmek için ETM'in 30 m piksel boyutlu diğer bantlarıyla pan-sharpening algoritmasıyla birleştirilebilecekti.

4.1.4 Landsat- 7

Landsat-7, 15 Nisan 1999'da yörüngeye yerleştirildi. Bu uzay aracı üzerindeki algılama sensörü ETM+ dır ve bunun tasarımı Landsat-4 ve -5 ile veri sürekliliği sağlamaktadır. Benzer yörünge ve 185 km genişliğinde görüntüleme alanı algılanmaktadır. Ayrıca, sistem pankromatik bantta 15 m GSD üretecek şekilde dizayn edilmiştir. Görünür, yakın ve orta kızılötesi bölgedeki bantların çözünürlüğü 30 m'dir. Altıncı bant (termal) ise 60 m GSD üretmektedir, bu değer ETM'nin termal bandında 120 m'dir.

4.2 Ikonos

Dünyanın ilk ve yüksek çözünürlüklü ticari uydusu olan Ikonos -1 29 Nisan 1999 yılında fırlatılmıştır. Fakat roketin istasyondan planlanan süreden 4.5 dakika geç ayrılması sonucu uydu gerekli hıza ulaşamamış ve yörüngeyi yaklayamamıştır. Ikonos -1 uydusu Güney Pasifik Okyanusuna düşmüştür.

İkinci uydu Ikonos-2 adıyla 24 Eylül 1999'da fırlatılmıştır. Pankromatik ve çok spektrumlu görüntülerin birleştirilmesi ile "pan-sharpened" görüntüler elde edilir. Bu durumda pankromatik bantının geometrik çözünürlüğü ve çok spektrumlu bantlarının spektral çözünürlüğü birleştirilmiş olur.

Ikonos uydu görüntüleri, şehir planlama, arazi kullanımı ve analiz çalışmaları, haritacılık, tarım, ormancılık, maden aramaları, kamu kurumları (elektrik, telefon

şirketleri vb.), çevre çalışmaları, ulusal güvenlik ve telekomünikasyon, nakliye sistemleri ve acil yanıt sistemleri gibi uygulamalarda kullanılmaktadır.

İkonos uydusu yerden 681 km yükseklikte olup nadirden, pankromatik 0.82 m, çok spektrumlu bantlarda 3.2 m geometrik çözünürlüğe sahip görüntü alabilmektedir (Bkz. Çizelge 4.3 ve Çizelge 4.4). Tarama genişliği (swath) nadirde 11.3 km olup, nadirden 26° eğimde 13.8 km' dir (Space Imaging, 2004).

Çizelge 4.3 : İkonos yörüngesinin özellikleri

Yükseklik	681km
Eğim Açısı (Orbital Inclination)	98.1 derece
Yörüngedeki Hızı	4.7 mil/saniye - 7.5 km/saniye
Ekvator Geçiş Zamanı	Alçalma Durumunda $\approx$ 10:30
Yörünge Periyodu	98 dakika
Yörünge Tipi	Kutupsala yakın, güneş uyumlu

Çizelge 4.4 : İkonos görüntüsünün özellikleri

Geometrik Çözünürlük	Nadirde 0.82 m (Pankromatik Bant), 3.2 m (çok spektrumlu) 26° nadirden sapmada 1.0 m (Pankromatik Bant), 4.0 m (çok
Bant Aralıkları	Pankromatik: 0.45-0.90 μ m, Bant 1 (Mavi): 0.45-0.52 μ m, Bant 2 (Yeşil): 0.52-0.60 μ m, Bant 3 (Kırmızı): 0.63-0.69 μ m, Bant 4 (Yakın Kızılötesi): 0.76-0.90 μ m
Dinamik Aralık	11 bit

İkonos uydusu ayrıca nadirden her yöne doğru $\pm 50^\circ$ sapmalı olarak çekim yapabilmektedir. Geometrik çözünürlüğü ne olursa olsun, tüm İkonos ticari ürünleri 1 m GSD'ye yeniden örneklenerek son kullanıcıya sunulmaktadır.

Uydu görüntülerinin metadata'sında algılayıcı ve Güneş'in çekim anındaki azimut ve yükseklik açıları verilmektedir. Bu veriler gerek radyometrik ve gerekse atmosferik düzeltmede kullanılmaktadır. Bu açıların görüntü metadata dosyasında karşılıkları

şunlardır; Nominal Collection Azimuth: Uydu Azimut Açısı, Nominal Collection Elevation: Uydu yükseklik açısı, Sun Angle Azimuth: Güneş azimut açısı, Sun Angle Elevation: Güneş yükseklik açısı.

Ikonos uydusu mono görüntü çekimi dışında stereo görüntü çekimi de yapabilmektedir. SPOT uydusundan farklı olarak stereo görüntü çiftini farklı yörünge geçişinde değil, aynı yörünge geçişinde eğim özelliğini kullanarak elde eder. Bunun diğer sistemden avantajı, görüntü çiftinin ışık ve görüntü içeriğinin hemen hemen aynı olmasıdır. Ikonos GEO ürünüdür ve bantlar 4 Bant 4 Dosya şeklindedir. Yani her bant ayrı GeoTIFF dosyasıdır.

Çizelge 4.5’de gösterilen GEO ürünler daha önceden belirlenmiş bir elipsoid ve harita projeksiyonuna göre geometrik olarak düzeltilmiş ve rektifiye edilmiştir. Rektifikasyon işlemi görüntüdeki hataları düzeltir ve belirlenen harita projeksiyonuna göre yeniden örnekler (resampling). Bu ürün topoğrafyadan kaynaklanan ötelemeler hariç ± 15 m (RMSE) standart yatay doğruluğa sahiptir (Inta Spaceturk, 2006).

Çizelge 4.5 : Ikonos GEO ürün seçenekleri tablosu

Ürün tipi	Dosya formatı	Harita proj.	Datum / Elipsoid	Radyometrik çözünürlük
1mPAN	GeoTIFF	UTM	WGS84	11 bit
4m MSI	TIFF	TM	NAD 83 (GRS1980)	8 bit
1mPSM	NITF 2.0	Albers Konik Alan Koruyan		
1mPAN + 4mMSI		Lambert Konik Açık Koruyan		

4.3 SPOT

SPOT (Le Systeme Pour l’ Observation de la Terre) uydusu Fransız Uzay Merkezi tarafından planlanarak Fransa, Belçika ve İsveç tarafından üretildi. İlk kez 22 Şubat 1986’ da işlev kazandı. Landsat uyduları gibi kutup doğrultusuna yakın, güneşle eş zamanlı $98^{\circ}7$ eğimli, yer yüzeyinden 832 km yükseklikte görüntüleme yapabilmektedir. İki farklı modda çalışan yüksek çözünürlüklü iki görüntüleme cihazı olan HRV (High-Resolution Visible)’ye sahiptir. Çok spektrumlu modu 20m mekansal çözünürlüklü spektrumun yeşil (0.50-0.59 μm), kırmızı (0.61-0.68 μm) ve

yakın kızılötesi (0.79-0.89 μm) bölümünü kaplayan 3 banttan oluşmaktadır. Pankromatik modu sadece görünür bölgeyi örten tek bant (0.51-0.73 μm) ve 10 m mekansal çözünürlüğe sahiptir. Her iki algılayıcı seti birlikte aralarında 3 km'lik örtme bulunan 117 km'lik tarama genişliğini kapsar. Landsat'la kıyaslandığında SPOT uydusunun geliştirilmiş daha yüksek geometrik çözünürlüğü olduğu kadar, düşey doğrultusunun her iki yanından 27^0 'ye kadar dik olmayan görüntüleme olanağına da sahip olması bazı gelişmiş özellikleridir. Bu dik olmayan görüntü olanağı nedeniyle jeomorfoloji, jeoloji ve toprak vb. amaçlı görüntü yorumlamaları için özellikle kullanışlı olan dünya yüzeyinin stereoskopik (üç boyutlu) görüntülerini alabilmektedir.

Pankromatik görüntüler düşük spektral çözünürlüğünden dolayı bitki haritalaması için iyi bir seçim değildir. Aşağıdaki kıyaslamada olduğu gibi; alaçam ormanları ve kavak ormanları arasındaki ayrımı gözetebilecek bir çizim için pankromatik fotoğraf yerine renkli veya kızılötesi-renkli görüntü tercih edilmelidir. Çünkü kavak ve alaçam ormanları pankromatik görüntülerde düşük spektral çözünürlüğünden dolayı benzer gri tonlarında görünür. Alaçam ve kavak ağaçları renkli veya renkli-kızılötesi görüntülerde gelişmiş spektral çözünürlüklerinden dolayı belirgin bir şekilde ayrılmaktadır. Bununla birlikte, diğerlerine göre daha yüksek mekansal çözünürlüklü olan SPOT pankromatik görüntüleri, yollar, keskin sınırlar, kaya çıkıntıları, havza alanları ve diğer yüksek kontrastlı özelliklerin haritalanması için çok iyi bir seçimdir. Patika yolları veya daha küçük yüksek kontrastlı özelliklerin haritalanmasında küçük ölçekli renkli uydu görüntüleri yerine büyük ölçekli hava fotoğrafları tercih edilmelidir. Çok spektrumlu görüntünün nem ya da gölge ilişkili özelliklerin haritalanmasında önemli olabilen orta kızılötesi bantları yoktur. Ayrıca SPOT verisinde göl suyunun ısı bölgelerinin haritalanması gibi bazı uygulamalarda önemli olan termal bant bulunmamaktadır.

SPOT uydu sistemi, içinde, kullanıcıya istediği alanı seçmesinde esneklik sağlayan nokta hedefli aynaları barındırması itibariyle tektir. Bu yüksek zamansal çözünürlük, orman yangınları, sel, bitki fenolojisi gibi dinamik olayların gözlenmesinde önemli olmaktadır. Eğer bu aynalar nokta hedefli olmasaydı aynı bölgeyi tekrar görüntüleme sıklığı her 26 gün de bir şeklinde olacaktı. Çünkü nokta hedefli aynalar görüntünün farklı açılardan elde edilmesine olanak sağlamaktadır. Bindirmeli SPOT görüntüsü hava fotoğraflarındaki gibi bir stereoskopa 3 boyutlu olarak görülebilir. SPOT

görüntüleri bu stereo görüş sayesinde dünyanın herhangi bir yerinin dijital yükseklik modeli üretiminde kullanılabilir. Çizelge 4.6’da SPOT uydu sisteminin özellikleri gösterilmektedir.

Çizelge 4.6 : SPOT görüntüsünün özellikleri

Uydu	Tarih	Algılayıcı tipi	Mekansal çözünürlük (metre)	Radyometrik çözünürlük (bit)	Zamansal çözünürlük (gün)	Şerit genişliği (km)
SPOT-1-2-3	1986-/ 1990-/ 1993-96	HRV-	10	8	1-4(26)	60
		PAN-HRV	20	8	1-4(26)	60
SPOT-4	1998-	HRV-PAN	10	8	1-4(26)	60
		HRVIR	20	8	1-4(26)	60
		HRVIR	20	8	1-4(26)	60
		Vegetation	1000	4/8	1	2200
SPOT-5	2002-	HRS-PAN	10	8	1-4(26)	120
		HRG-PAN	2.5-5	8	1-4(26)	60
		HRG	10	8	1-4(26)	60
		HRG	20	8	1-4(26)	60
		Vegetation	1000	4/8	1	2250

5. GÖRÜNTÜ SINIFLANDIRMA TEKNİĞİ

Görüntü sınıflandırması işleminin bütün amacı, otomatik şekilde görüntüdeki tüm pikselleri yer örtü sınıflarına veya temalarına guruplamaktır. Çok spektrumlu yani çok bantlı veri, normalde sınıflandırma yapmak için kullanılır ve gerçekten de her bir piksel için verideki mevcut spektral “patern”lerin guruplandırılması işleminde referans olarak kullanılır. Yani bu işlem ile farklı özelliklerdeki Digital Number (DN)’lerin kombinasyonları, onların iç spektral yansıtım ve yayılım özelliklerine dayalı olarak yürütülür. Bu açıklama ışığında bir spektral “patern” terimi her bir piksel için değişik dalga boylarında elde edilmiş radyans ölçüm setlerini ifade etmektedir. Spektral “patern” tanıma, sınıflandırmanın temelidir ve spektral anlamda otomatik sınıflandırma için temel teşkil etmektedir.

Mekansal “patern” tanıma, görüntü piksellerinin onları çevreleyen piksellerle mekansal ilişkisi de göz önünde bulundurularak guruplara ayrılması anlamına gelmektedir. Sınıflandırmada görüntünün yapısı, komşu pikseller, şekil, süreklilik ve içerik gibi özellikler dikkate alınmaktadır. Bu çeşit sınıflandırıcılarda görsel yorumlama işlemi boyunca, kullanıcı tarafından yapılan sentez tekrar edilerek doğruluk arttırılır. Çünkü insan algısı, spektral patern tanıma tekniklerinden çok daha kompleks ve hesaplama yönünde daha yoğun ve karmaşıktır.

Görüntü sınıflandırma yöntemleri piksel tabanlı ve nesne tabanlı sınıflandırma olarak ikiye ayrılmaktadır. Piksel tabanlı sınıflandırmanın kendi içinde birçok yöntemi vardır. Farklı amaçlar doğrultusunda farklı sınıflandırma tekniği seçilebilmektedir. Piksel tabanlı sınıflandırma ve bu yönetime alternatif olan nesne tabanlı sınıflandırma yöntemi, bulanık mantık fonksiyonları da kullanılarak irdelenmiştir.

5.1 Piksel Tabanlı Sınıflandırma

5.1.1 Kontrollü sınıflandırma

Kontrollü sınıflandırma üç temel adımdan oluşmaktadır. İlk aşama olan eğitim aşamasında analist, örneklem alanları tanımlar ve görüntüdeki yer örtü tiplerinin her

biri için spektral özelliklerine ait nümerik bir tanımlama geliştirir. İkinci aşama olan sınıflandırma aşamasında görüntüdeki her bir piksel en yakın benzerlik gösterdiği yer örtü sınıfına kategorize edilir. Eğer piksel herhangi bir örneklem alana yeteri kadar benzer olmazsa “bilinmeyen” olarak etiketlenir. Bu işlemde her bir piksele atanan sınıf etiketi daha sonra yorumlanmış veri gurubunun ilgili hücresine kaydedilir. Böylece, çok boyutlu görüntü matrisi, yorumlanmış arazi örtüsü tiplerinden oluşan sonuç matrisinin geliştirilmesinde kullanılır. Tüm veri guruplandırıldıktan sonra, sonuçlar üçüncü aşama olan çıktı aşamasında sunulur.

İlk aşama olan sınıflandırma aşamasında, iki kanallı dijital görüntüden örneklemeler alınır. Her bir pikseli özleştiren iki boyutlu dijital değerler veya ölçüm vektörleri bir saçılım diyagramı üzerine onları çizmek suretiyle grafik olarak ifade edilebilirler. Bu diyagramda, bant- 3 DN’leri y ekseninde bant- 4 DN’leri x ekseninde çizilmiştir. Bu iki DN, her bir piksel değerini iki boyutlu “ölçüm uzayında” konumlandırmaktadır. Bu şekilde, eğer bir pikselin bant- 4 DN’si 10, bant- 3 DN’ 68 ise bu piksel için ölçüm vektörü, ölçüm uzayında koordinatı (10,68)’de gösterilen bir nokta tarafından temsil edilecektir. İkinci aşama olan sınıflandırma aşamasında, çok spektrumlu görüntünün gerçek sınıflandırması otomatik bir işlem olmasına rağmen, sınıflandırma için gereken eğitim verisi otomatik olmayan bir işlemdir. Kontrollü sınıflandırmanın eğitim eğitim aşaması hem sanattır hem de bilimdir. Bu aşama, görüntü analisti ile görüntü verisi arasında yakın karşılıklı etkileşim gerekmektedir. Bunun yanında, sağlam referans veri ve verinin uygulanacağı coğrafi bölge hakkında eksiksiz bilgiye ihtiyaç duyulmaktadır. En önemlisi, eğitim aşamasının kalitesi, sınıflandırma aşamasının başarısını ve bu nedenle bütün sınıflandırma sonucunda ortaya çıkan bilginin değerini belirlemektedir.

Eğitim sürecinin genel amacı, görüntüde sınıflandırılacak her bir arazi örtü tipi için spektral cevap paternini tanımlayan istatistik veri gurubunu kurmaktır. Eğitim aşaması boyunca her bir yer örtüsü sınıfı için “nokta bulutlarının” konumu, boyutu, şekli ve doğrultusu belirlenmektedir.

Kabul edilir sınıflandırma sonuçları üretmek için eğitim verisi, hem temsil edici hem de tam olmalıdır. Bunun anlamı, görüntü analisti, sınıflandırıcı tarafından ayrımı yapılacak her bir bilgi sınıfını meydana getiren bütün spektral sınıflar için eğitim istatistiği geliştirmelidir.

5.1.1.1 Ortalamalar sınıflandırıcısına en kısa yakınlık

En basit sınıflandırma stratejilerinden biridir. İlk olarak, her bir sınıf için her banttaki ortalama spektral değerler belirlenir. Bu değerler, her bir sınıf için ortalama vektörleri içerir. İki kanallı piksel değerleri, konumsal koordinatlar olarak göz önüne alınırsa bilinmeyen olarak tanımlı bir piksel, kendi değeri ile her bir sınıf ortalaması arasındaki uzaklığın hesaplanması yoluyla sınıflandırılırlar. Uzaklıkların hesaplanmasından sonra bilinmeyen piksel en yakın sınıfa atanmaktadır. “Ortalamalar sınıflandırıcısına minimum uzaklık” stratejisi matematiksel olarak kolaydır ve hesaplama açısından etkindir. Ancak bazı sınırlamaları vardır. En önemlisi, bu yöntem, spektral cevap verisinde farklı düzeydeki varyanslara duyarlı değildir. Bu nedenle bu sınıflandırıcı, spektral sınıfların ölçüm uzayında birbirine yakın ve yüksek varyansa sahip olduğu uygulamalarda yaygın olarak kullanılmaktadır.

5.1.1.2 Paralel kenar sınıflandırıcısı

Sınıf varyanslarının duyarlılığı örneklem alanlardaki piksellerin değerleriyle irdelenmektedir. Bu da, her bir banttaki en yüksek ve en düşük dijital rakam değerleri ile tanımlanabilir. Bilinmeyen piksel, içinde yer aldığı sınıf veya karar bölgesine göre sınıflandırılır. Bu dikdörtgen alanların çok boyutlu benzeşimleri, paralel yüzler (parallelepipeds) olarak adlandırılır. Bununla birlikte prizma sınıflandırıcı, çok hızlı ve hesaplama açısından etkin bir yöntemdir.

5.1.1.3 Gauss en yüksek olabilirlik sınıflandırıcısı

En yüksek olabilirlik sınıflandırıcısı, bilinmeyen bir piksel sınıflandırıldığı zaman sınıflara ait spektral cevap paternlerinin hem varyans hem de kovaryanslarını mutlak olarak değerlendirir. Bunu yapmak için sınıfların eğitim verisini oluşturan nokta bulutlarının dağılımının Gauss normal dağılımında olduğu farzedilir.

Bir sınıf cevap paterninin dağılımı tamamıyla ortalama vektör ve kovaryans matrisi tarafından tanımlanabilir. Verilen bu parametrelerle, herhangi bir piksel değerinin özel bir yer örtü sınıfının üyesi olma olabilirliği istatistiksel olarak hesaplanabilir. Olabilirlik yoğunluk fonksiyonları, piksel değerinin her bir sınıfa ait olan olabilirliğini hesaplamak suretiyle tanımlanamamış pikselin sınıflandırılmasında kullanılmaktadır. Esasında en yüksek olabilirlik sınıflandırıcısı, saçılım

diyagramında elips şekilli “eşit olabilirlikli konturlar” oluşturur. Bu eşit olabilirlikli konturlar, bu sınıflandırıcının kovaryansa olan duyarlılığını ifade etmektedir. En yüksek olabilirlik yaklaşımının uzantısı Bayes sınıflandırıcısıdır. Bu teknik, olabilirlik kestirimine iki ağırlık faktörü katmaktadır. İlk, analist “öncül olabilirliği” veya verilen durumda her bir sınıf için beklenen oluşum olabilirliğini belirler. Pratikte, çoğu en yüksek olabilirlik sınıflandırması bütün sınıflar için eşit oluşma olabilirliği ve yanlış sınıflandırma maliyeti düşünülerek gerçekleştirilir. Eğer bu faktörler için uygun veri mevcutsa, sınıflandırıcının Bayes yürütümü tercih edilir. En yüksek olabilirlik sınıflandırmasının ana eksikliği, her bir pikseli sınıflandırmak için gerekli olan çok yoğun hesaplamadır. Bu durum, özellikle çok sayıda spektral kanal ya da çok fazla sınıf olduğunda ortaya çıkar. Böyle durumlarda, en yüksek olabilirlik sınıflandırıcısı hesaplama açısından önceki tekniklerden çok daha yavaştır.

5.1.2 Kontrolsüz sınıflandırma

Kontrolsüz sınıflandırmada eğitim verisi yani örneklem alanlar kullanılmaz. Bunun yerine görüntüdeki bilinmeyen pikselleri inceleyen algoritmalar ve onları görüntü değerlerinde mevcut doğal gruplamalara dayanarak sınıflara sokar. Ana koşul, verilen bir örtü tipindeki değerler ölçüm uzayında birbirine yakın olmaları gerekirken farklı sınıflardaki değerler birbirine kıyasla çok iyi ayrılabilir olmalıdırlar.

Kontrolsüz sınıflandırmalardan doğan sınıflar, spektral sınıflardır. Sadece görüntü değerlerindeki doğal gruplamalara bağlı olduklarından spektral sınıfların ne olduğu önceden bilinmeyecektir.

Analist, sınıflandırılmış veriyi farklı referans veriyle karşılaştırarak sınıfların ne olduğunu belirler. Bu nedenle kontrollü sınıflandırmada her bir sınıfa ait bilgiler tanımlanır ve spektral ayırt edilebilirlikleri incelenirken kontrolsüz sınıflandırmada spektral olarak ayırt edilebilir sınıflar belirlenir ve tanımlamaları yapılır.

Kontrolsüz sınıflandırmada iki kanallı genel bir veri gurubu göz önüne alınarak örnekleneyecektir. Verideki doğal spektral gruplamalar, görsel yolla, bir saçılım diyagramının çizimiyle belirlenebilir.

5.1.3 Melez (Hibrit) sınıflandırma

Melez sınıflandırma kontrollü ve kontrolsüz sınıflandırmanın doğruluğunu artırmak ya da daha verimli kılmak amacıyla geliştirilmiştir. Örneğin kontrollü sınıflandırmada ayırt edilecek sınıfları temsil etmek üzere sınıfların belirlenmesinde analiste yardımcı olması maksadıyla kontrolsüz örneklem alanlarının sınırları görüntüde çizdirilebilir. Kontrolsüz eğitim alanları, kontrollü eğitim alanlarından kasten çok farklı olacak şekilde seçilen görüntü alanlarıdır.

Melez sınıflandırıcılar özellikle tekil örtü tipleri için spektral cevap paternlerinde karmaşık değişebilirliklerin olduğu analizlerde kullanılabilir. Bu tür durumlar bitki örtüsü haritalaması gibi uygulamalar da oldukça yaygındır. Bu durumda örtü tiplerindeki spektral değişkenlik normalde hem örtü tipleri içindeki değişimden hem de farklı bölge şartlarından kaynaklanmaktadır. Rehberli kümeleme bu tür durumlarda oldukça etkin olduğu görülmüş melez bir yaklaşımdır.

5.1.4 Spektral karışım analizi

Karışık piksellerin sınıflandırılması genellikle karışık pikseller algılayıcısı olan IFOV'unun yeryüzünde birden fazla yer örtü tipi içermesi durumunda oluşmaktadır. Görüntüdeki karışık pikseller, görüntüyü elde etmekte kullanılan uzaktan algılama sisteminin mekansal çözünürlüğü ve incelenen yüzey özelliklerinin mekansal ölçeğinin bir fonksiyonudur. Spektral karışım analizi ve bulanık (fuzzy) sınıflandırma, karışık piksellerin sınıflandırması ile ilgilenmek için tasarlanmış iki işlemdir. Piksel-altı sınıflandırma bu yöntemlerle başarılı sonuç verebilir.

Spektral karışım analizi, karışık örneklem alanların referans verisi ile karşılaştırıldığında kullanılan teknikleri içermektedir. Belirli yüzey özelliklerinin sebep olduğu, görüntüdeki spektral farklılıktan kaynaklanan bir kestirim şeklinde düşünülebilir. Sonuç olarak referans verideki piksellerin yeryüzünde kapladığı alanların yaklaşık oranlarının bir tahmininden oluşmaktadır.

Spektral karışımın analizi, arazi örtüsü sınıflandırması için kullanılan diğer görüntü işleme yöntemlerinden biraz farklıdır. Kavramsal olarak, farklı spektral cevap paternlerinin karışımının fiziksel bir modeline dayalı olduğu için bu bir istatistiki değil, deterministik bir yöntemdir. Ayrıca, sınıflandırılacak olan sınıflar sadece

piksel içinde algılandığı için kullanışlı bilgiyi piksel-altı düzeyinde sağlar. Birçok arazi örtü tipi iyi bir mekansal ölçekten görünseler bile heterojen karışımlar olarak görülmeye eğilimlidirler. Bu nedenle, bu yöntem her piksele dominant sınıfın atanmasıyla elde edilene göre daha iyi bir şekilde yüzeyin olması gereken yapısını daha gerçekçi yansıtır.

Örneğin dört-bantlı bir SPOT HRVIR çok spektrumlu görüntüsünün spektral karışım analizi, beş farklı ideal üye sınıfın kesirli oranlarının kestirimini bulmada kullanılır. Bu işlem; dört, üç veya iki ideal üye sınıfı içinde yapılabilir. Bu görüntü tek başına ek bilgi olmaksızın beş ideal üye sınıftan fazlası için kesirli sınıf tahminlerini çıkarmak amacıyla doğrusal spektral karışım analizinde kullanılamaz.

5.1.5 Fuzzy (Bulanık) sınıflandırma

Fuzzy sınıflandırma, karışık-piksel problemini bulanık mantıkla çözmeye çalışır. Burada verilen bir varlık birden fazla kategoride kısmi üyeliğe sahip olabilir. Bulanık sınıflandırmaya bir yaklaşım da bulanık kümelemedir. Bu işlem kavramsal olarak daha önce tanımlanan “K-ortalamlar” kontrolsüz sınıflandırması yaklaşımına benzerdir. Fark, spektral ölçüm uzayında sınıflar arasında “keskin” sınırlar almak yerine bulanık bölgeler kurulur. Bu nedenle, sırf tekil sınıfa atanan her bir bilinmeyen ölçüm vektörü yerine, o ölçünün ölçüm uzayındaki bir bölünmeye ne kadar yakın olduğuna bakılmaksızın üyelik derecesi değeri kullanılır. Bu değer bir piksel ölçüsünün bütün sınıfların ortalamalarına ne kadar yakın olduğunu tanımlamak için atanır. Fuzzy sınıflandırmaya diğer bir yaklaşım, fuzzy kontrollü sınıflandırmasıdır. Bu yaklaşım en yüksek olabilirlik sınıflandırmasına benzerdir; farklılık, fuzzy ortalama vektörleri ve kovaryans matrisleri istatistiksel ağırlıklı eğitim verisinden geliştirilir. Tamamen homojen olan eğitim alanlarının sınırlarını çizmek yerine, sürekli ve karışık eğitim alanlarının bir kombinasyonu kullanılabilir.

Değişik özellik tiplerinin bilinen karışımları ile fuzzy eğitim sınıfı ağırlıkları belirlenir. Bundan sonra sınıflandırılmış bir piksel üyelik derecesine atanırken onun her bir bilgi sınıfındaki üyeliğini kullanır.

5.2 Sınıflandırma Doğruluğunun Değerlendirilmesi

Sınıflandırma işleminde doğruluk analizi büyük önem taşımaktadır. Tarihsel olarak incelendiğinde, sınıflandırma teknikleri konusundaki gelişim aynı şekilde doğruluğunu ölçme konusunda olmamıştır. Bu sorun da bazen sınıflandırma teknikleri ile arazi kullanımı haritalarının üretilmesine engel olmakta ve hatta maliyet gözetilmeksizin klasik veri toplama yolları ile bu haritaların üretilmesine sebep olmaktadır. Bir sınıflandırma, doğruluğu belirleninceye kadar tamamlanmış değildir.

5.2.1 Sınıflandırma hata matrisi

Sınıflandırma doğruluğunu açıklamada kullanılan en yaygın yollardan biri, sınıflandırma hata matrisinin oluşturulmasıdır. Hata matrisleri, sınıf-sınıf, bilinen referans veri (yer gerçeği) ile ona karşılık gelen sınıflandırma sonuçları arasındaki ilişkiyi karşılaştırmaktadır. Bu tür matrisler kare matrislerdir, satır ve sütunların sayısı, sınıflandırma doğruluğu değerlendirilen sınıfların sayısına eşittir.

Görüntü analistinin hazırladığı kontrollü sınıflandırmanın eğitim aşamasında kullanılan temsili piksellerin alt gurubunun sınıflandırmanın sonucunu ne kadar iyi etkilediğinin belirlenmesi için oluşturulan bir hata matrisidir. Bu matris, örneklem alanlardaki piksellerinin sınıflandırılması ve eğitim için kullanılabilen örtü tiplerine karşı sınıflandırıcı tarafından her bir sınıfa gerçekte sınıflandırılan piksellerin listelenmesinden oluşmaktadır. Sınıflandırma performansının birkaç karakteri hata matrisi tarafından ortaya konulur.

Genel doğruluk, doğru olarak sınıflandırılmış piksellerin toplam sayısının (ana köşegen boyunca olan elemanların toplamı) referans piksellerin toplam sayısına bölümü sonucu hesaplanır. Ayrıca her bir kategorinin doğruluğu, bu kategorilerdeki doğru olarak sınıflandırılmış piksellerin sayısının karşılık gelen satır veya sütun piksel sayısından birine bölümü ile hesaplanır. Üretici doğruluğu ise her bir sınıfın doğru olarak sınıflandırılmış piksel sayısının (ana köşegen üzerinde) o sınıf için kullanılan örneklem piksel sayısına (sütun toplamı) bölümüdür. Bu da verilen örtü tipine ait örneklem piksellerin ne kadar iyi sınıflandırıldığını göstermektedir.

Kullanıcı doğruluğu, her bir sınıftaki doğru olarak sınıflandırılmış piksel sayısının o kategoride sınıflandırılan toplam piksel sayısına (satır toplamı) bölümüdür ve verilen

bir kategoriye sınıflandırılan pikselin gerçekten de o sınıfı yeryüzünde temsil etme olasılığını göstermektedir.

5.3 Nesne tabanlı sınıflandırma

Klasik piksel tabanlı yöntemlerde, sadece pikselin gri değerine dayalı detay çıkarımı esastır. Bu durum, ancak belirli bazı özelliklerin çıkarılmasıyla daha da kötüleşir. Yukarıda bahsedilen kısıtlamayı ortadan kaldırmak için nesne-tabanlı görüntü analizi uygulanır. Burada spektral değerler, şekil ve doku gibi değişik nesne özelliklerinin geniş spektrumunun tamamlanmasını sağlayan bulanık mantığa dayanmaktadır.

Günümüzde, piksel-tabanlı yöntemlere dayanan sınıflandırmalar sınırlıdır. Özellikle, yüksek çözünürlüklü verinin, zengin bilgi içeriğiyle ilgili önemli sorunları vardır. Buna örnek olarak, tutarsız sınıflandırma sonuçları veren ve araştırılan nesnenin çıkarımında beklentileri karşılamayan İkonos görüntüleri verilebilir. Bu durum, çalışmaya yürütüm-bazlı operatör kullanımını getirir. Bahsedilen klasik yöntemlerin yapısından dolayı, yeni ve nesne tabanlı görüntü analizi yazılımları kullanılabilir. Definiens nesne-tabanlı görüntü analizi yazılımı türündeki yazılımlarda kullanılan algoritmalar, sınıflandırmaların düzenlenmesi konusunda segmentleri daha uygun hale getirmek için, yapısal veya dokusal ek bilgilerle tamamlanan bir veya daha fazla görüntü segmentlerini gerektirir.

Nesne-tabanlı yaklaşım, yapıyı, dokuları ve spektral bilgileri dikkate alır. Bu sınıflandırma aşaması, komşu piksellerin gruplandırılmasının, sınıflandırmanın sonraki basamağında ele alınabilir anlamlı bölgelere dönüştürmesi 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 nesneleri de ortaya çıkar. Bu segmentasyon değişik çözünürlüklerde yapılabilirken, nesne kategorilerinin katmanlarını ayırt etmeye de izin verir.

5.3.1 Segmentasyon aşaması

Segmentasyon aşaması, Definiens yazılımında yapılan ilk işlemdir ve bu işlemin amacı görüntüden anlamlı nesneler yaratmaktır. Bunun anlamı, ilgili her nesnenin şekli, bir görüntü nesnesine dayalı olarak gösterilmelidir. Türetilmiş renk ve doku

özellikleriyle birleştirilmiş bu şekil, oluşturulan görüntü nesnelerini sınıflandırarak öncelikle görüntünün sınıflandırılması için kullanılabilir. Bu nedenle sınıflar, bir sınıf hiyerarşisi içinde düzenlenir. Her sınıf, bir alt sınıf (sub-class) ve üst sınıfa (super class) sahip olabilir ve böylece her sınıf, bir veya daha fazla üst (süper) sınıfların özellikleri de alt sınıflarında görülmektedir.

Ortaya çıkarılacak nesnelerin çok ölçekli sonuçları göz önüne alındığında küçük nesneler, anlamsal bir hiyerarşi oluşturan daha büyük nesneleri yapılandırmak için birleştirilebilir. Aynı şekilde büyük bir nesne, nesne analizinin iki ana yaklaşımına yönelen küçük nesnelere bölünebilir: Yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) yaklaşımı (Benz, 2003 ve eCognition User Guide, 2003). Definiens yazılımındaki her iki yaklaşım aşağıdaki işlemler yapılarak gerçekleştirilebilir.

Çoklu-çözünürlüklü segmentasyon işlemi kullanarak görüntü nesnelerinin hiyerarşik yapısı oluşturulmaktadır. Üst katman görüntü segmentleri küçük ölçekli nesneleri gösterirken, alt katman segmentleri ise büyük ölçekli nesneleri gösterir.

Elde edilmiş nesnelerin fiziksel özelliklerine göre sınıflandırılması aynı zamanda şu anlama gelir; sınıf isimleri ve sınıf hiyerarşileri iki özellik göz önüne alındığında örnek teşkil eder: haritası yapılmış gerçek dünya ve görüntü nesnelerinin fiziki ölçülebilir büyüklükleri. Önceki yöntemleri kullanma, sınıflandırma işlemini hızlandırırken, aynı zamanda onu daha belirginleştirir.

Komşuluk ilişkileri veya alt veya üst (süper) nesne olma durumu söz konusu olduğunda, yapı nesnelerinin anlamsal ilişkilerini tanımlama genellikle sınıf hiyerarşisindeki fiziksel sınıflandırma çözünürlüğünün geliştirilmesini sağlar.

Sınıflandırılmış nesneleri, sınıflandırma tabanlı segmentasyon için kullanılabilir anlamsal gruplar olarak birleştirilerek elde edilen komşu segmentler daha sonra CBS ortamına aktarılıp kullanılabilir. Ayrıca anlamsal gruplar, başka komşuluk analizleri için de kullanılabilir.

Bu işlemler Definiens yazılımı ile çalışılırken kullanılan aşamalardır. İlk iki işlemin yapılması zorunluyken, sonraki iki işlemin uygulanması, yazılımın kullanıcıya ve görüntünün içeriğine bağlı olarak tavsiye edilir. Segmentasyon aşamasında, aşağıdaki parametreler olabildiğince gerçeğe yakın belirlenmelidir.

Ölçek parametresi (Scale Parameter):

Bu parametre, ortalama nesne boyutunu dolaylı yoldan etkiler. Aslında bu parametre nesnelerin heterojenliğine izin veren maksimum değeri belirler. Ölçek parametresi ne kadar büyürse nesnelerin boyutu da o kadar büyür.

Renk / Biçim (Color / Shape):

Bu parametrelerle renk ve biçim çatışmasının homojenliğinin nesne üretimine etkisi düzeltilebilir. Biçim kriteri ne kadar yüksek olursa, spektral homojenliğinin nesne üretimine etkisi daha az olacaktır.

Yumuşaklık / Bütünlük (Smoothness / Compactness):

Biçim kriteri 0' dan büyük olduğunda kullanıcı, nesnelerin daha bütün (yoğun) veya daha yumuşatılmış olması gerektiğine karar verebilir.

Segmentasyon aşamasını görüntüleri sınıflandırma işlemi takip eder. Definiens yazılımı iki temel sınıflandırıcı ile çalışmayı sağlar: en yakın komşu sınıflandırıcı ve bulanık üyelik (fuzzy membership) fonksiyonları. Her ikisi de sınıf tanımcıları olarak görev yaparlar.

En yakın komşu sınıflandırıcı, kullanıcının her sınıf için karar vermesi gereken örnek nesneler yardımıyla ortaya çıkacak sınıfları tanımlarken, bulanık üyelik fonksiyonları nesnelerin belirli bir sınıfa ait olduğu veya belli bir seviyede olmadığı yerdeki önemli özellik aralıklarını tanımlarlar.

5.4 Uygulamada Kullanılan Yöntemler

5.4.1 Piksel tabanlı en yüksek olabilirlik sınıflandırması (Maximum Likelihood Classification, (MLC))

Yapılan birçok araştırma, uzaktan algılama verilerinin klasik sınıflandırmasında en etkin yöntemin MLC olduğunu göstermektedir. (Green et al. 1998, Gao 1999). Bu nedenle bu yöntem analizin başlangıç noktası olarak kabul edilmiştir. Arazi örtüsü sınıfları arasındaki spektral ayırt edilebilirlik görüntünün temel mekansal biriminin piksel yerine nesnenin alınmasıyla zenginleştirileceğini ileri sürülmüştür. Bu hipotezin test edilmesi için piksel bazında bu 11 sınıftan 9 örtü tipinin tümü arasındaki spektral ayırt edilebilirlik araştırılmaya başlanmıştır. Sınıflar arası ayırt edilebilirliği ölçmek için Öklit uzaklığı esas alınmıştır (Euclidean Distance: ED).

Benzer bir uygulama BD uzaklığının (Bhattacharya Distance) referans alınmasıyla yapılmıştır (Richards 1986). Sonuç olarak Öklit uzaklığı sınıflandırmanın başarısında belirleyici olabilir. Sınıflar arası uzaklıkların artması daha iyi sınıflandırma sonuçları anlamına gelecektir.

5.4.2 Nesne tabanlı sınıflandırma

Nesne tabanlı sınıflandırma tüm görüntünün birbirine yakın nesnelerle segmente edilmesiyle başlamaktadır. Bu çalışmada segmentasyon metodu Definiens Imaging 5.0 yazılımının içinde uygulanmıştır. Bu yöntem belirli alanların birleştirilmesi şeklinde de tanımlanabilir (Bkz. Baatz ve Schape (1999)). Kısaca bu yöntem ikili sistemdeki bir sayaç tarafından üretilen bir kararsızlık matrisinden ardışık kaynak noktaları oluşturur. Sonrasında her bir kaynak noktasından başlayarak her adımda bir çift komşu görüntü nesnesi geniş bir nesne şeklinde birleştirilecektir. Birleştirme işlemi lokal homojenlik kriterine bağlı olarak yapılmaktadır. Homojenlik kriteri aşağıda tanımlanmıştır (5.1).

$$f = \sum_{i=1}^{i=n} W_i (n_{\text{merge}} s_{\text{merge}} - (n_{\text{obj1}} s_{\text{obj1}} + n_{\text{obj2}} s_{\text{obj2}})) \quad (5.1)$$

- n : Bant sayısı
- W_i : Hesaplanan bandın ağırlığı
- n_{merge} : Birleştirilen nesnedeki piksel sayısı
- n_{obj1} : Nesne 1'deki piksel sayısı
- n_{obj2} : Nesne 2'deki piksel sayısı
- σ_{merge} : Birleştirilen nesnelerin varyansı
- σ_{obj1} : Birinci nesnenin varyansı
- σ_{obj2} : İkinci nesnenin varyansı

f ise görüntü nesnelerinin boyutları ve n adet görüntü bandının toplamlarıyla ağırlıklandırılmış lokal ton heterojenliğinden elde edilmiştir. Bu çalışmada tüm W_i 'lerdeki eşit ağırlık değeri (1) olarak belirlenmiştir.

Birleştirme işleminin bitmesi için f 'nin önceden hesaplanmış eşik değerine ulaşması gerekir. Büyük eşik değerleri ortalama büyük nesne boyuna neden olurken küçük eşik değeri ortalama küçük nesne boyuna neden olur. Bu özelliğinden dolayı bu

metodun içeriğinde eşik değeri, “ölçek parametresi” (scale parameter) olarak adlandırılmıştır. Sonuç olarak, ölçek parametresi çeşitli nesnelerin kaynaşmasından dolayı oluşan heterojenlikteki değişiminin en yüksek olasılığını hesaplayan soyut bir değerdir.

Prensipte sonsuz ölçek parametresi vardır. Ölçek parametresi için son karar, nicel bir ölçüt yerine görüntünün görsel denetimine bağlı olarak bir yorumlama ile yapılır. Ancak sınıflandırma durumunda yorumlayan kişi için hangi ölçek parametresinin sınıflandırma doğruluğunu artıracakını söylemek çok zordur. Ayrıca sınıflandırmayı tüm olası ölçek parametreleriyle yürütmek oldukça zaman alıcıdır. Bu nedenle çalışma alanı 2’deki alanın sınıflandırılması için amaçlanan doğrultuda uygun ölçeği seçen bir yöntem geliştirilmiştir. Bu yöntem aşağıdaki alt bölümde açıklanmaktadır.

5.4.3 Homojen nesnelerin segmentasyonunda en uygun ölçeği seçmek için yeni bir yöntem

Öklit uzaklığı genellikle en uygun bantların seçimine yardımcı olmak için sınıf ayırt edilebilirliğinin analizinde kullanılmıştır. Bu çalışmada ise en uygun ölçek parametresinin araştırılmasında kullanıldı. Öncelikle, birbirleriyle tutarlı olması için MLC yönteminde kullanılan aynı örneklem alanları seçilmiştir. Bu örneklem alanları dışındaki diğer pikseller sıfır değerine atanıp bu alanlara ait piksel değerlerinin korunduğu yeni bir görüntü elde edilmiştir. Sonrasında yeni görüntü bölüm 5.4.2’de değinilen çeşitli aday ölçek parametreleriyle segmente edilmiştir. Bu kısımda her nesne, piksel yerine örneklem alanın temel birimi haline getirilmiş ve benzer şekilde her nesnenin ortalama gri değeri bu nesnenin spektral bilgisini göstermek için hesaplanmıştır. Bu spektral değerlere bağlı olarak her ölçekte 9 arazi örtüsü sınıfı arasından ED değeri eldilmiş. Sonuç olarak ED’nin maksimum değere ulaştığı ölçek en uygun ölçek olarak alınarak tüm görüntü segmentasyonunda kullanılmıştır.

5.4.4 Nesne bazında en yakın komşuluk (Nearest Neighbour,NN) sınıflandırması

En uygun ölçekte yapılan segmentasyondan elde edilen görüntü nesneleri için, MLC yönteminde uygulanan aynı örneklem alanlarına bağlı olarak en yakın komşuluk sınıflandırması uygulanmıştır. Sonuç olarak her nesne bu 9 arazi örtü tipinden birine atanmıştır. En yakın komşuluk sınıflandırması aşağıdaki şekilde uygulanmıştır. İlk olarak görüntüdeki her nesnenin bir nokta olduğu bir özellik uzayı (bu çalışmada Ikonos için 4 kanaldan 4 boyutlu özellik uzayı ve SPOT 5 için 3 kanaldan 3 boyutlu

özellik uzayı) tanımlanmıştır. Bunun nedeni, her bir sınıfa ait örneklem alanların mekansal olarak kümelenme pozisyonunda yer işgal etmesidir. Bir nesnenin hangi sınıfa atanacağına dair son karar o sınıfa ait olan örneklemin verilen özellik uzayında en yakın sınıfa atanması şeklinde olacaktır. Bu şekilde tematik bir harita oluşturulmuş ve temel mekansal birim olarak pikseller kullanılarak yapılan sınıflandırma, aynı örnek bölgede maksimum likelihood sınıflandırmasıyla karşılaştırılmıştır.

5.4.5 Çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması

Genellikle semantik bir sınıf, karakteristik özellikleri ve öznitelik uzayındaki (feature space) dağılımıyla tanımlanabilir. Herhangi bir görüntüyü analiz etmek için kullanılan nesne tabanlı sınıflandırma yaklaşımında, ilgili nesne sınıflarını tanımlamak için dikkate alınacak birçok olası özellik vardır. Bu yüzden görüntü analizinin başarılı olması için her nesnenin belirgin özelliklerinin tanımlanması gerekmektedir (Nussbaum et al. 2006). Definiens yazılımı içinde mevcut olan üyelik fonksiyonları, bulanık mantık algoritmalarıyla entegre edilerek her sınıf için uygun fonksiyonlarla ayırım yapılmıştır.

6. UYGULAMA

Bu uygulamada belirlenen çalışma alanlarının arazi örtülerinin haritalanması amaçlı olarak farklı uydu görüntüleri ve farklı teknikler irdelenmiştir.

Bu amaçla, ilk olarak çalışma alanının büyük bir kısmını tek bir çerçevede gösterebilme ve spektral çeşitliliği nedeniyle Landsat görüntüsü tercih edilmiş ve kıyaslanabilir olması için iki ayrı yöntemle sınıflandırılmıştır: i) piksel tabanlı en yüksek olasılık sınıflandırması (Maksimum Likelihood Classifier) ii) çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması.

İkinci olarak, yüksek çözünürlüklü uydu görüntülerinin sınıflandırma analizinin etkin bir şekilde yapılabilmesi için çalışma alanının içinden ikinci bir alan seçilmiştir. Bu alanda 4m mekansal çözünürlüklü Ikonos ve 2.5m mekansal çözünürlüklü SPOT 5 görüntüleri karşılaştırma yapılabilmesi için yukarıda açıklanan iki ayrı yöntemle sınıflandırılmıştır. Bu kısımda çalışma alanındaki bina ve yollara ait vektörel veriler ve arazinin dijital yükseklik modeli sınıflandırmaya entegre edilerek sonuçların zenginleşmesi sağlanmıştır. Ayrıca en uygun ölçek parametresinin seçilmesi ile ilgili yeni bir yöntem denenerek sonuçlara yansıtılmıştır.


6.1 Çalışma Alanı ve Veri Hazırlama

6.1.1 Çalışma alanı

İki kısımdan oluşan çalışma alanının ilki Marmara Bölgesi'nin Doğu Trakya kısmında Karadeniz'e paralel, İstanbul Boğazı'na doğru uzanan yaklaşık 194000 ha'lık bir hattır. İkinci çalışma alanı ise Terkos havza sınırları içinde kalan, Terkos Gölü'nün güney batı yakasında, içinde yerleşim, tarım, orman ve bitki örtüsü çeşitliliğini de içeren 11000 ha'lık bir alandır (Bkz. Şekil6.1, Şekil 6.2).



Şekil 6.1 : Çalışma alanı 1.



Şekil 6.2 : Çalışma alanı 2.

6.1.2 Veri hazırlama

Mevcut veriler, 09 Haziran 2004 tarihli, 30m mekansal çözünürlüklü 6 bantlı Landsat TM görüntüsü, 2.5m (pan-sharpened=10m(yeşil, kırmızı, yakın kızılötesi)+2.5m pan) mekansal çözünürlüklü Haziran 2005 tarihli 3 bantlı SPOT 5 görüntüsü ve 4m mekansal çözünürlüklü Haziran 2005 tarihli 4 bantlı (kırmızı, yeşil, mavi ve yakın kızılötesi) Ikonos görüntüsü kullanılmıştır. Nesne tabanlı görüntü sınıflandırmasına entegre edilmesi için ikinci çalışma alanındaki bina, yol ve dijital yükseklik modeli verileri de kullanılmıştır. Landsat görüntüsü için yerleşim, yaprak döken orman, yaprak dökmeyen orman, tarım-A, tarım-B, tarım-C, çayır-çimen, toprak alan, boş alan, kum ocağı, su, ıslak alan ve çalılık olmak üzere 13 sınıf oluşturulmuştur. SPOT 5 ve Ikonos görüntüleri için ise, bina, yol, tarım-A, tarım-B, tarım-C, boş alan, su, toprak-çimen, *yeşil(alçak)*, *yeşil(orta)* ve *yeşil(yüksek)* olmak üzere 11 sınıf oluşturulmuştur. Yeşil alan sınıfının, taşıdıkları klorofil miktarı gözetilerek yansıtım değerleri dikkate alındığında 3 ayrı sınıfta incelenmiştir. Ayrıca bu sınıflar arazideki tespitlerle de ilişkilendirildiğinde hemen hemen boyları ile doğru orantılı olduğu gözlenmiştir. Aynı şekilde tarım sınıfı da mevcut yansıtım değerleri dikkate alındığında kendi içinde ürün toplanmış (*tarım-C*), ürün toplanmamış (*tarım-B*) ve ekili olmak (*tarım-A*) üzere 3 ayrı türe ayrılarak sınıflandırmaya yeni bir boyut kazandırılmıştır.

6.2 Uygulama Sonuçları

6.2.1 Spektral ayırt edilebilirlik

Elde edilen sınıflar arası Öklit uzaklıkları birbirleri ile kıyaslanarak en iyi ayırımın yapılabileceği uygun ölçekler gösterilmiştir. Piksel tabanlı MLC ile sınıflandırması için örneklem alanlar seçilmeye başlandığında *tarım-A*, *tarım-B*, *tarım-C* sınıfları iyi ayırt edilemediğinden daha fazla örnek alınmıştır.

Çizelge 6.1 : Piksel bazındaki öklit uzaklığı (ölçek parametresi = 1).

	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	91,14	0							
3	Tarım-C	298,12	336,2	0						
4	Bos_Alan	1217,97	1247,97	920,17	0					
5	Su	333,31	271,95	599,99	1498,3	0				
6	Toprak_Cayır	97,45	128,36	304,39	1213,36	392,4	0			
7	Yeşil(Alcak)	391,9	453,56	456,63	1228,27	655,65	298,39	0		
8	Yeşil(Orta)	562,67	623,33	575,93	1227,81	827,05	469,14	175,27	0	
9	Yeşil(Yukse)	632,32	693,92	653,62	1283,89	886,54	539,25	240,94	83,44	0

Dokuz sınıfın spektral ayrılabilirliğini farklı ölçeklerde, nesne bazında incelemek için Bölüm 5.4.2 ve 5.4.3’de tanımlanan yöntemler kullanılmıştır. Görüntü segmentasyonunda ölçek parametreleri 1, 5, 10, 20, 30 ve 40 alınmıştır.

Çizelge 6.2 : Farklı ölçeklerdeki ED değerleri. a) ölçek parametresi = 5, b) ölçek parametresi = 10, c) ölçek parametresi = 20, d) ölçek parametresi = 30, e) ölçek parametresi = 40

(a) Ölçek parametresi = 5

	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	91,48	0							
3	Tarım-C	298,86	356,52	0						
4	Bos_Alan	1669,07	1716,23	1370,71	0					
5	Su	355,44	282,88	621,40	1957,67	0				
6	Toprak_Cayır	110,79	156,47	320,21	1675,89	416,02	0			
7	Yeşil(Alcak)	377,54	423,45	461,92	1689,93	652,98	271,09	0		
8	Yeşil(Orta)	525,62	574,16	558,32	1674,76	805,13	420,98	153,66	0	
9	Yeşil(Yukse)	609,66	655,79	650,44	1731,77	874,08	504,09	233,22	94,39	0

Çizelge 6.2 (devamı) : Farklı ölçeklerdeki ED değerleri.

(b) Ölçek parametresi = 10

	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	96,9	0							
3	Tarım-C	301,18	353,4	0						
4	Bos_Alan	1210,07	1258,46	909,6	0					
5	Su	340,28	263,19	602,23	1493,38	0				
6	Toprak_Cayır	108,48	168,55	320,37	1212,8	404,26	0			
7	Yeşil(Alcak)	340,78	401,02	451,12	1241,39	606,14	236,49	0		
8	Yeşil(Orta)	484,55	546,93	543,11	1240,42	752,66	381,23	148,49	0	
9	Yeşil(Yuksek)	604,48	666,53	653,76	1290,85	863,88	501,55	266,32	122,15	0

(c) Ölçek parametresi = 20

	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	113,53	0							
3	Tarım-C	291,26	360,42	0						
4	Bos_Alan	1173,02	1237,69	882,81	0					
5	Su	353,08	252,78	598,95	1461,68	0				
6	Toprak_Cayır	93,8	172,93	316,48	1182,73	403,16	0			
7	Yeşil(Alcak)	346,55	422,63	472,4	1232,19	617,28	257,11	0		
8	Yeşil(Orta)	469,91	551,47	543,3	1218,44	751,13	382,3	134,25	0	
9	Yeşil(Yuksek)	507,07	582,09	608,32	1292,85	763,82	418,27	161,42	76,32	0

(d) Ölçek parametresi = 30


	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	121,73	0							
3	Tarım-C	318,36	399,31	0						
4	Bos_Alan	1159,82	1234,56	842,1	0					
5	Su	368,03	259,87	649,33	1473,63	0				
6	Toprak_Cayır	91,52	173,29	353,55	1183,39	402,2	0			
7	Yeşil(Alcak)	336,62	418,25	487,52	1228,49	606,94	250,94	0		
8	Yeşil(Orta)	459,39	547,15	552,42	1218,44	739,75	377,03	133,51	0	
9	Yeşil(Yuksek)	498,32	578,07	619,86	1292,85	750,29	412,91	162,42	76,32	0

Çizelge 6.2 (devamı) : Farklı ölçeklerdeki ED değerleri.

(e) Ölçek parametresi = 40

	Sınıf Adı	1	2	3	4	5	6	7	8	9
1	Tarım-A	0								
2	Tarım-B	125,86	0							
3	Tarım-C	314,69	399,31	0						
4	Bos_Alan	1026,97	1106,42	713,2	0					
5	Su	355,92	242,48	632,4	1330,72	0				
6	Toprak_Cayır	88,92	173,29	353,55	1054,38	385,68	0			
7	Yeşil(Alcak)	333,29	418,25	487,52	1103,36	592,63	250,94	0		
8	Yeşil(Orta)	455,56	547,15	552,42	1097,78	725,54	377,03	133,51	0	
9	Yeşil(Yuksekk)	487,63	569,58	617,88	1176,51	726,88	405,19	155,18	79,72	0


Çizelge 6.1 ve Çizelge 6.2’de gösterilen, tarım sınıf türleri arasındaki en iyi ayırımı yaptığı ölçeğin bulunması amaçlı bu analizde, örneğin *tarım-A* ve *tarım-B* arasındaki ED değeri, ölçek parametresi 1 olduğunda $ED = 91.14$, 5 olduğunda $ED = 91.48$, 10 olduğunda $ED = 96.9$, 20 olduğunda $ED = 113.53$, 30 olduğunda $ED = 121.73$ ve 40 olduğunda ise $ED = 125.86$ ’dır. Bu değerler bu iki türe uygun sınıflandırma segmentasyonunun 40 olduğunu göstermektedir. Şekil 6.3 incelendiğinde üç tarım türünün en iyi ayırt edildiği ölçeğin 40 olduğu görülmektedir.



Şekil 6.3 : Tarım-A, tarım-B ve tarım-C’ye ait ED değerlerinin altı farklı ölçek parametresinde karşılaştırılması.

6.2.2 SPOT 5 görüntüsünün sınıflandırılması

SPOT 5, 2.5m mekansal çözünürlüklü kırmızı, yeşil ve yakın kızılötesi olmak üzere 3 banda sahiptir. Yakın kızılötesi bandı da içerdiği için bitki örtüsü analizinde kullanılmaktadır (Bkz. Şekil 6.4).




Şekil 6.4 : SPOT 5 görüntüsü (123 ve 213 bant kombinasyonu).

Sınıflandırma işlemi öncesinde SPOT 5 görüntüsü üzerinden tüm arazi görsel analiz edilerek olası sınıflar incelenmiştir. Bu sınıflar, yeşil alanlar (yüksek, orta ve alçak), tarım alanları (A,B,C olmak üzere 3 tür), su, boş alan, toprak-çayır, bina ve yol olarak belirlenmiştir.

6.2.2.1 SPOT 5 görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması

Sınıflandırılacak olan türler incelendiğinde, Şekil 6.5’de de gösterilen bina ve yol detaylarındaki karmaşık yapı ve önceki sınıflandırma deneyimleri de dikkate alındığında, sınıflandırma doğruluğunu arttırmak için bina ve yol katmanları vektörel olarak sınıflandırmaya entegre edilmiştir.



Şekil 6.5 : Bina ve yolların karmaşık yapısı ve eklenecek olan vektörel veriler.




Şekil 6.6 : 1m Ikonos görüntüsü ve vektörel verilerin güncellenmesi.

Mevcut vektörel veriler 2005 tarihli 1:5000’lik halihazır haritalardan elde edilmiş olup bazı güncellemeler 1m Ikonos (pan-sharpaned) görüntüsü yardımıyla yapılarak sınıflandırma için hazır hale getirilmiştir (Bkz. Şekil 6.6).


Nesne tabanlı Definiens 5.0 yazılımının getirdiği bir yenilik de sınıflandırmada seviyelerin (hierarchy) belirlenip her seviye için uygun nesnelerin seçilebilmesi özelliğidir. Böylece, ilgilenilen spesifik nesnelere ilişkin uygun seviyeler belirlenebilmekte ve her seviyedeki sınıflandırma başka bir seviyeye aktarılabilmektedir.

Sınıflandırma işleminin ilk aşamasında bina ve yol katmanlarının sınıflandırmaya entgre edilmesi için bir segmentasyon yapılmıştır.




Şekil 6.7 : Vektörel veriler ile segmentasyon.

Segmentasyon işleminde SPOT 5 görüntüsünün bant ağırlıkları Şekil 6.7’de görüldüğü gibi 0 olarak girilirken tematik katmanların ağırlığı 1 olarak tanımlanmıştır. Bu aşamada herhangi bir işlevi olmayan ölçek parametresi hiyerarşik sıralamada önde olması için 100 olarak seçilip segmentasyon gerçekleştirilmiştir. Bu segmentasyona göre sınıflandırma yapabilmek için vektörel verilerin id’lerinden yararlanılmıştır. Bulanık mantık fonksiyonlarından “tematik object id” fonksiyonu kullanılmış ve id > 1 olan her nesne öncelikle yol sınıfına atanmıştır (Bkz. Şekil6.8). Daha sonra “yol_değil” sınıfı, “similarity to classes” fonksiyonunun “invert expression” kısmı işaretlenerek tanımlanmıştır.




Şekil 6.8 : Bina ve yol verilerinin sınıflandırmaya entegre edilmesi.

Yukarıda ifade edildiği gibi aynı fonksiyonlar bina katmanı için uygulanır ve bina ve “bina_değil” sınıfları oluşturulur. Daha sonra, yapılan bu segmentasyon işlemi için bir seviye tanımlanması gerekmektedir (seviye1). Bu tanımlama ilgili fonksiyon seçilerek minimum ve maksimum değerlerinin ortalaması 1 olacak şekilde yazılır (Bkz. Şekil 6.9). Bina ve yol katmanı bu seviyenin içine dahil edilip sınıflandırma yapılır (Bkz. Şekil 6.10).




Şekil 6.9 : Vektörel veriler için seviye tanımlanması.




Şekil 6.10 : Seviye1’deki sınıflandırma sonucu.

Vektörel veriler ile sınıflandırma yapıldıktan sonra ikinci bir segmentasyon yapılması gerekmektedir. Bu amaca yönelik ilk olarak çalışma alanı içinde nesnelerin büyüklükleri göz önünde bulundurularak ölçek parametresinin 75, renk faktörünün 0.8, sıklık faktörünün 0.3 olduğu yeni bir seviye daha belirlenmiştir (Bkz. Şekil 6.11).



Şekil 6.11 : SPOT 5 görüntüsünün ikinci segmentasyon sonucu.


İkinci segmentasyondan sonra hemen bu segmentasyona ait bir seviye belirlenir (Bkz. Şekil 6.12). Bu seviye, yeni yapılan segmentasyonun bir öncekine göre büyük ya da küçük olma durumuna göre (ölçek parametresi) belirlenir. Bu durumda yapılan yeni segmentasyon seviye1 olmuş olmaktadır. Aynı şekilde önceki segmentasyonun da seviye2 olarak değiştirilmesi gerekir. Bu durum her yeni segmentasyon için tekrarlanmalıdır.



Şekil 6.12 : Seviyenin oluşturulması ve fonksiyonu.


Seviye1’de oluşturmaya düşündüğümüz sınıflara geçmeden önce ilk segmentasyondan elde ettiğimiz sınıfların bu seviyeye taşınması gerekmektedir. Bu işlem sınıf ilişkili özellikler (class-related features) kısmındaki süper nesnelerle ilişkiler (relations to super objects) bölümünün “existence of bina” ya da yol şeklindeki fonksiyonuyla tanımlanır. Bu fonksiyon kesin değer fonksiyonlarından olup 1 değeri atanır. Diğer sınıflar da aynı şekilde tanımlanır ve sonuçta bir önceki seviyede elde edilen sınıflandırma sonuçları alt seviyeye taşınmış olur (Bkz. Şekil 6.13).

Burada süper-obje ve sub-obje diye iki kavram karşımıza çıkmaktadır ki bunlar nesnelerin segmentasyon hiyerarşisine göre üst veya alt olduklarını ifade etmektedir.




Şekil 6.13 : Seviyeler arası sınıflandırma sonuçlarının aktarılması.

Seviyeler arası sınıflandırma sonuçlarının aktarımından hemen sonra arka plan (background) ayırımının yapılmasına geçilmiştir. Arka planın yansıtım değeri 0 olduğundan Mean1 fonksiyonunda “kesin değer=0” şeklinde bir tanımlama yapılır. Sonrasında “invert similarity” fonksiyonuyla “arka plan” sınıfının tersi alınarak “Veri” sınıfı oluşturulur (Bkz. Şekil 6.14).



Şekil 6.14 : Veri ve arka zeminin ayırımı.


Seviye1’de, NDVI (Normalized Difference Vegetation Index) bitki indeksi ile yeşil alanların yeşil olmayan alanlardan ayrımının sağlanması düşünülmüştür. Bu yüzden ilk olarak NDVI fonksiyonunun yazılıma tanıtılması gerekmektedir. $NDVI = \frac{(nir - red)}{(nir + red)}$ yani yakın kızılötesi ve kırmızı bandın farkının toplamalarına oranı şeklinde formüle edilmektedir. Definiens 5.0 yazılımında “Yeni bir aritmetik özellik oluştur” (create new arithmetic feature) seçeneğine bu fonksiyonun yazılmasıyla birlikte NDVI fonksiyonu tanımlanabilmektedir (Bkz. Şekil 6.15).



Şekil 6.15 : NDVI fonksiyonun tanımlanması.

Görüntüye NDVI fonksiyonunu uygulayarak yeşil alanlar için uygun aralığın araştırmasına geçilmiştir. Bu seviyedeki mevcut nesneler üzerinde yapılan analizler sonucu $NDVI > 0.115$ alanların yeşil alan (orman, çalılık, çayır-çimen, ürün toplanmamış tarım) olduğu tespit edilmiştir (Bkz. Şekil 6.16).


Bulanık mantık fonksiyonlarından “büyüktür” fonksiyonun minimum ve maksimum olmak üzere 2 değeri söz konusudur. Burada maksimum değeri 0.115 girmemiz durumunda ≥ 0.115 değerleri için yeşil alan sınıfının %100 ağırlığında atandığını göstermektedir. Minimum değer yazılmasıyla birlikte hangi sınıfın %0 -%100 arası yeşil alana atandığı belirlenebilmektedir. Burada yeşil alanlar için 0.113 değeri uygun bulunmuştur. Bu da minimum ve maksimum değerlerin ortalaması olan 0.114 değerinin % 50 ağırlıklı olarak yeşil alan sınıfına atandığını göstermektedir. Bir sınıfın ilgili sınıfa atanabilmesi için $\geq \%50$ ağırlığında olması gerekmektedir. Minimum ve maksimum değerler yapılan segmentasyon ve uygulanan fonksiyonun görsel analizi sonucunda tespit edilir.



Şekil 6.16 : Yeşil alanların NDVI fonksiyonu ile birlikte sınıflandırılması ve minimum ve maksimum eşik değerleri.

Yeşil alan sınıfı ayırt edildikten sonra yeni bir alt seviye belirlenerek diğer sınıfların sınıflandırılmasına geçilmiştir. Bu da yeni bir ölçek, renk ve sıklık parametresi anlamına gelmektedir. Buradaki temel strateji, ayırt edilmesi istenilen en küçük türlerin boyutuna denk gelecek nesneleri içeren bir segmentasyonun yapılmasıdır.

Yeşil alanın alt türleri ve tarım alanları incelenerek ölçek parametresinin 30, renk faktörünün 0,8 ve sıklık faktörünün 0.4 olduğu yeni bir segmentasyon yapılmıştır (Bkz Şekil 6.17).




Şekil 6.17 : SPOT 5 görüntüsünün üçüncü ve son segmentasyon sonucu.

Bu segmentasyona yeni bir seviye atanarak üst seviyelerdeki sınıflar; bina, yol, veri ("arkaplan_değil"), arka plan, yeşil alan ve "yeşil alan değil" sınıfları bu seviyeye yukarıda açıklandığı gibi sınıf ilişkili özellikler kısmındaki süper objelerle ilişkiler (relations to super objects) bölümünün existence of bina, yol, diğer sınıflar şeklindeki fonksiyonların tanımlanmasıyla aktarılır. Daha sonra yeşil alan sınıfının alt türlerine geçilir. Taşıdıkları klorofil miktarına göre yüksek, orta, alçak şeklinde ifade etmeyi düşündüğümüz yeşil alanların bu ayrımı yakın kızılötesi ve kırmızı banttan oluşan bir fonksiyonla tanımlandı ve bu fonksiyona yeşil detektörü ismi verildi.

$$\text{Yeşil Detektörü} = \text{RatioLayer2} / \text{RatioLayer1}$$


Bu fonksiyon yazılıma entegre edilerek yeşil alan alt türlerinin tespiti için uygun aralıkların araştırılmasına başlandı.

Yeşil(yüksek) sınıfı için >0.47 değerlerinin uygun olduğu tespit edildi. *Yeşil(orta)* sınıfı için $0.47-0.60$ aralığı, *yeşil(alçak)* sınıfı için *yeşil(alçak)* sınıfı için $0.60-0.65$ aralığı ve *toprak çayır* sınıfı için de < 0.65 değerleri uygun bulundu. Ayrıca yeşil alan sınıfının içinde, şekil 6.18’de gösterilen vadi içindeki ova gibi düzlüklerde görülen bir tarım türünün olduğu gözlemlendi. Bu tarım türü de yeşil(yüksek) sınıfının yansıtım değerini verdiğinden ayırt edilebilmesi için dijital yükseklik modeli kullanılmıştır (Bkz. Şekil 6.18). Yani karışan sınıf sadece şekilde gösterilen bölgeler olduğu için bu bölgeler dijital yükseklik modeli verisinin ratio fonksiyonuna indirgenmesiyle ayıklanmıştır. Dijital yükseklik modeli verisi tıpkı kırmızı yeşil ve yakın kızılötesi bant gibi dördüncü bant olarak sınıflandırmaya entegre edilmiştir.




Şekil 6.18 : Çalışma alanının 3 boyutlu görünümü ve tarım yapılan alanlar.

Bu fonksiyonda < 0.13 alanlar şekilde gösterilmiştir. *Yeşil(yüksek)*, *yeşil(orta)*, *yeşil(alçak)* ve toprak çayır sınıflarına ikinci bir fonksiyon olarak “büyüktür 0.13” değeri eklenmiştir (Bkz. Şekil 6.19).



Şekil 6.19 : Dijital yükseklik modelinin sınıflandırmaya aktarılarak yeşil alt alanların çıkarımı.

Tarım-A sınıfı diye ifade ettiğimiz “ürün toplanmamış tarım” sınıfı geriye kalan yeşil alanlar olduğundan bu sınıfın tanımında “*alçak_değil, orta_değil, yüksek_değil* ve *toprak_çayır_değil*” fonksiyonları kullanıldı (Bkz. Şekil 6.20).




Şekil 6.20 : Dijital yükseklik modeli entegre edilmiş sınıflandırma sonuçları.

Yeşil alan ve alt türlerinin sınıflandırılmasından sonra “*yeşil alan değil*” sınıfının içindeki ayrıma geçilir. Öncelikle su sınıfı için NDVI fonksiyonunun “ > -0.3375 ” değeri uygun bulunmuş ve sınıflandırılmıştır. Sonrasında “*su değil*” sınıfının içinde *boş alan* sınıfına uygun bir fonksiyon yazılıma entegre edilmiştir.


$$\text{Boş Alan Detektörü} = 1/\text{Mean}(\text{Layer2})$$

Bu fonksiyonda < 0.007 değerleri *boş alan* sınıfı olarak sınıflandırılmıştır (Bkz. Şekil 6.21).




Şekil 6.21 : Boş alanların çıkarımı ve ilgili fonksiyonu.


Boş alanların sınıflandırılmasından sonra geriye kalan sınıflar *tarım-B* ve *tarım-C*'dir. *Tarım-C* sınıfı yansıtım olarak boş alana benzerlik gösterdiği için boş alan detektörünün bu sınıf için de kullanılması düşünülmüştür. Yapılan inceleme sonucunda < 0.012 değerler bu sınıf için uygun bulunmuş *tarım-B* sınıfı için de “*tarım-C değil*” fonksiyonu kullanılmıştır (Bkz. Şekil 6.22).



Şekil 6.22 : Tarım-B ve C sınıflarının ayırımında kullanılan fonksiyon ve seviye1'deki sınıflar.



Şekil 6.23 : SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucu.



Şekil 6.24 : SPOT 5 görüntüsünde nesne tabanlı sınıflandırılmış alanlar ve grafiksel gösterimi

SPOT 5 görüntüsünün üyelik fonksiyonları ve fuzzy algoritmalarıyla nesne tabanlı sınıflandırma doğruluk analizi

Çizelge 6.3 : SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi

Sınıflar	1	2	3	4	5	6	7	8	9	10	11	ST
1 Bina	3	0	0	0	0	0	0	0	0	0	0	3
2 Su	0	2	0	0	0	0	0	0	0	0	0	2
3 Tarım-A	0	0	4	0	0	0	0	0	0	0	0	4
4 Tarım-B	0	0	0	7	0	0	0	0	1	0	0	8
5 Tarım-C	0	0	0	0	5	0	0	0	0	0	0	5
6Toprak_Çayır	0	0	0	1	0	7	0	0	2	0	0	10
7 Yeşil(Alçak)	0	0	0	0	0	0	6	1	0	0	0	7
8 Yeşil(orta)	0	0	0	1	0	0	2	12	1	0	0	16
9 Yeşil(yüksek)	0	0	1	0	0	0	0	0	10	0	0	11
10 Boş_Alan	0	0	0	0	0	0	0	0	0	2	0	2
11 Yol	0	0	0	0	0	0	0	0	0	0	4	4
Sütun Toplamı	3	2	5	9	5	7	8	13	14	2	4	72

Çizelge 6.4 : SPOT 5 görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları

Üretici Doğruluğu		Kullanıcı Doğruluğu
Sınıflar	%	%
1Bina	3/3=100	3/3=100
2Su	2/2=100	2/2=100
3Tarım-A	4/5=80	4/4=100
4Tarım-B	7/9=78	7/8=88
5Tarım-C	5/5=100	5/5=100
6Toprak_Çayır	7/7=100	7/10=70
7Yeşil(Alçak)	6/8=75	6/7=86
8Yeşil(orta)	12/13=92	12/16=75
9Yeşil(yüksek)	10/14=71	10/11=91
10Boş_Alan	2/2=100	2/2=100
11Yol	4/4=100	4/4=100

Genel doğruluk = $(3+2+4+7+5+7+6+12+10+2+4)/72 = 0.8611$


K = 0.8416

Çizelge 6.3 ve Çizelge 6.4’de gösterildiği gibi elde edilen % 86.11’lik sonuçla SPOT 5 görüntüsü yüksek doğrulukla sınıflandırılmıştır. *Toprak_Çayır* ve *Yeşil(orta)* sınıflarına ait nispeten düşük doğruluk bu görüntünün gerek mekansal çözünürlüğü gerekse spektral özellikleri itibariyle bu sınıfların ayrımını tam anlamıyla

yapamadığını göstermektedir. Diğer taraftan bina ve yol sınıflarına ait vektörel verilerin sınıflandırmaya entegre edilmesi sınıfllararası karışımı azaltıp doğruluğun artmasını sağlamıştır.


6.2.2.2 SPOT 5 görüntüsünün piksel tabanlı sınıflandırılması

Erdas 9.1 yazılımı ile yapılan bu kontrollü sınıflandırmada karşılaştırmanın yapılabilmesi için nesne tabanlı uygulamada kullanılan sınıflar alınmıştır. İlgili sınıfın spektral çeşitliliği ve alansal büyüklüğü dikkate alınarak toplam 60 adet örneklem alan toplanmıştır (Bkz. Şekil 6.25).




Şekil 6.25 : Toplanan örneklem alanların dağılımı.


Örneklem alanlar toplanırken yer gerçeği bilgisine ulaşmak için yüksek çözünürlüklü uydu görüntüsü kullanılmıştır (1m Ikonos pan-sharpaned) (Bkz. Şekil 6.26).



Şekil 6.26 : Tarım-B örneklem alanı ve yer gerçeği verisi ile doğrulama.




Şekil 6.27 : SPOT 5 görüntüsü sınıflandırma sonucu.



Şekil 6.28 : SPOT 5 görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.


SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi

Doğruluk analizi, Erdas 9.1 yazılımı aracılığıyla sınıfların alanları ile orantılı şekilde tespit edilen 80 adet rastgele noktanın görüntü üzerine otomatik olarak atılmasıyla başlanmıştır (Bkz. Şekil 6.29).



Şekil 6.29 : SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi için atılan rastgele 118 nokta ve dağılımı.

Diğer uygulamalarda olduğu gibi bu uygulamada da rastgele atılan noktalar yüksek çözünürlüklü uydu görüntüleri ve farklı bant kompozitleriyle karşılaştırılarak yer gerçeği verisi sağlanmıştır (Bkz. Şekil 6.30).



Şekil 6.30 : SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizinde yer gerçeği ile karşılaştırılması.

Çizelge 6.5 : SPOT 5 görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi.

	Toplam	Toplam	Doğru	Doğruluğu (%)		Kappa
Sınıf Adı	Referans	Sınıflandırılan	Sayısı	Üretici	Kullanıcı	%
Bina	3	4	1	33.33	25.00	22
Su	2	2	2	100.00	100.00	100
TarımA	6	5	4	66.67	80.00	78
TarımB	7	6	5	71.43	83.33	81
TarımC	6	4	4	66.67	100.00	100
Toprak_Çayır	9	8	3	33.33	37.50	30
Yeşil(yüksek)	7	10	7	100.00	70.00	67
Yeşil(orta)	20	15	14	70.00	93.33	91
Yeşil(Alçak)	14	13	10	71.43	76.92	72
Boş_Alan	2	2	1	50.00	50.00	48
Yol	4	11	3	75.00	27.27	23


Genel Doğruluk = % 67.50

Toplam Kappa istatistiği = 0.6296

6.2.2.3 SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması


Çizelge 6.6 : SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.

	DOĞRULUK(%)	
Sınıflar	Piksel Tabanlı Sınıflandırma	Nesne Tabanlı Sınıflandırma
Bina	25	100
Su	100	100
Tarım-A	80	100
Tarım-B	83,33	88
Tarım-C	100	100
Toprak_Çayır	37,5	70
Yeşil(yüksek)	70	86
Yeşil(orta)	93,33	75
Yeşil(Alçak)	76,92	91
Boş_Alan	50	100
Yol	27,27	100
Kappa	63	84,16
GENEL	67,5	86,11



Şekil 6.31 : SPOT 5 görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.

SPOT 5 görüntüsü 10m mekansal çözünürlüklü çok spektrumlu (kırmızı, yeşil ve yakın kızılötesi) ve 2.5 m mekansal çözünürlüklü pankromatik bantlarının pan-sharpening işleminin yapılmasıyla 3 bantlı (yakın kızılötesi, kırmızı ve yeşil) 2.5m mekansal çözünürlüğe ulaşmıştır. Genel olarak değerlendirildiğinde mekansal olarak yüksek, radyometrik olarak orta çözünürlüklü uydu görüntüleri kategorisine girmektedir. Çizelge 6.5 ve Çizelge 6.6’da gösterildiği gibi %67’ye karşın %86’lık bir doğrulukla nesne tabanlı sınıflandırma bu uydu görüntüsü için arazi örtüsü haritası üretme açısından daha başarılıdır. Görüntü nesnelere bölünerek spektral karışıklık minimuma indirilmiş özellikle yerleşim alanlarında büyük fark gözlenmiştir (Bkz. Şekil 6.32).




Şekil 6.32 : SPOT görüntüsünün nesne ve piksel tabanlı sınıflandırma sonucunun irdelenmesi.

6.2.3 Landsat görüntüsünün sınıflandırılması

Landsat görüntüleri geniş alanların tek çekimde farklı spektral kombinasyonlarda analiz edilmesi noktasında sağladığı kolaylık nedeniyle 30m mekansal çözünürlüğüne rağmen birçok uygulamada tercih edilebilir. Daha önceden tespit edilmiş olan çalışma alanında bu uydu görüntüsü kullanılarak farklı yöntemlerle sınıflandırma yapıp sonuçları irdelenmiştir. Önce piksel tabanlı maksimum likelihood sınıflandırıcı ile sınıflandırma, daha sonra da çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması yapılmıştır.

Bu uygulamada kullanılacak olan Landsat görüntüsü 9-5-2004 tarihli, 6 bantlı ve 30m mekansal çözünürlüklüdür. Bantlar arası korelasyonu azaltmak ve daha iyi sonuçlar elde etmek maksadıyla görüntüye temel bileşenler analizi uygulanmıştır (Principal Component Analysis) (Bkz. Şekil 6.33).




Şekil 6.33 : Landsat görüntüsünün doğal görüntüsü(3,2,1) ve ana bileşenler analizi sonuç görüntüsü

Uydu görüntüsü incelenip belirlenecek sınıfların analizi yapılmıştır. Bu sınıflar; yerleşim, su, boş alan, ıslak alan, kum ocağı, toprak alan, tarım-A (ürün

toplanmamış), *tarım-B* (ekim yapılmış), *tarım-C* (ürün toplanmış), *yaprak döken orman*, *yaprak dökmeyen orman*, *çalılık* ve *çayır_çimendir*.

6.2.3.1 Landsat görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması


Nesne tabanlı sınıflandırmanın en önemli aşamalarından biri olarak kabul edilen segmentasyon işlemi bu uygulamada ölçek parametresi =10, renk faktörü =0.8, biçim faktörü =0.2 ve sıklık faktörü =0.5 olarak alınmıştır.



Şekil 6.34 : Landsat görüntüsünün segmentasyon sonucu.


Şekil 6.34’de görüldüğü gibi bu seviye, 30m mekansal çözünürlük göz önünde bulundurulduğunda birçok sınıfın ayırt edilebilirliği açısından yeterli görülmüştür.

Sınıflandırma işlemine ilk olarak arkaplan ve verinin ayırımı ile başlanılmıştır. Arkaplanın yansıtım değeri sıfır olduğundan 1 numaralı bant, program içinde tanımlı bulanık mantık fonksiyonlarından mean fonksiyonuna indirgenerek “kesin değer = 0” olan bir tanımlama yapılır ve veri – arkaplan ayırımı yapılmış olur (Bkz. Şekil 6.35).




Şekil 6.35 : Landsat görüntüsü veri-arkaplan ayırımı.

Sonrasında su sınıfının ayırımı ile devam edilmiştir. Bunun için yakın kızılötesi bandı ratio fonksiyonu ile kullanılarak uygun nesneler irdelenip < 0.21 değerler su sınıfı olarak kabul edilmiştir (Bkz. Şekil 6.36). Bu fonksiyonla su sınıfı ayırt edildikten sonra sınıflandırma prensibi olarak hemen “su_değil” sınıfı oluşturulmuştur. Bu sınıf da “invert similarity” fonksiyonuyla “suyun dışındaki tüm alanlar” şeklinde tanımlandı. Her yeni bulunan sınıfın akabinde bu işlem tekrarlanarak o sınıfın “değil”i oluşturulur (Bkz. Şekil 6.36).




Şekil 6.36 : Landsat görüntüsünde su ve su_değil sınıflarının ayırımı.

Su sınıfı ayırt edildikten hemen sonra ıslak alanların çıkarımına gidilmiştir. Bunun için de yine en uygun fonksiyonun yakın kızılötesi ile ratio eşleştirmesinin olduğu görülmüş ve uygulanmıştır. “Ratio Layer4” indirgemesi ile ıslak alanların ayırımına “yaklaşık aralık” fonksiyonu ile gidilmiştir (Şekil 6.37)




Şekil 6.37 : Islak alan sınıfının ayırımında kullanılan fonksiyon.

NDVI fonksiyonu ile artan değerlerde yeşillenme miktarının artacağı düşüncesiyle “Çayır_Çimen” sınıfının ayırımına gidilmiştir. -6.5 ile -2.5 aralığı bu sınıf için uygun bulunup sınıflandırılma yapılmıştır. Buradaki değerlerin negatif çıkması görüntüye temel bileşenler analizi uygulandığı için spektral değerler arasındaki mesafenin artmasından kaynaklanmaktadır (Bkz. Şekil 6.40)



Şekil 6.40 : Landsat görüntüsü “çayır_çimen” sınıfının çıkarımı ve fonksiyonu.


Aynı şekilde çalılık olarak tanımlanan “çayır_çimen” sınıfına göre biraz daha yüksek bitkiler barındıran sınıfının ayırımı için NDVI fonksiyonunun diğer bir aralığı olan -2.62 ile -2.19 bölgesi uygun bulunmuştur (Bkz. Şekil 6.41).




Şekil 6.41 : Landsat görüntüsünde çalılık sınıfının çıkarımı ve fonksiyonu.

Boş alan, yerleşim, kum ocağı, tarım-A, tarım-B, tarım-C, yaprak dökken ve yaprak dökmeyen ağaç sınıfları mevcut fonksiyonlarla ayırt edilemediğinden bu sınıfların ayırımı örneklem nesneler toplanarak en yakın komşuluk metodu uygulanmak suretiyle elde edilmiştir.

Bu işlem için öncelikli olarak bir özellik uzayının tanımlanması gerekmektedir. Tespit edilen örnek nesneler tanımlanan bu özellik uzayı içinde değerlendirilerek en yakın komşuluk sınıflandırıcısı ile sınıflandırılmıştır (Bkz. Şekil 6.42)




Şekil 6.42 : Landsat görüntüsünde en yakın komşuluk sınıflandırması için özellik uzayının tanımlanması.




Şekil 6.43 : Sınıflandırmaya giren sınıfların son şekli.

Uygun örneklem nesneler seçilerek sınıflandırma yapıp sonuçlar CBS ortamına aktarılmıştır.



Şekil 6.44 : Landsat görüntüsünün nesne tabanlı sınıflandırılıp CBS ortamında haritalanması.



Şekil 6.45 : Landsat görüntüsünden nesne tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.

Landsat görüntüsünün üyelik fonksiyonları ve fuzzy algoritmalarıyla nesne tabanlı sınıflandırma doğruluk analizi

Sınıflandırma tamamlandıktan sonra mevcut sınıfların yer gerçeği ile ne kadar uyumlu olduğunu belirlemek için tüm çalışma alanında sınıfların alanları ağırlığınca 112 adet rastgele nokta atılmıştır (Bkz. Şekil 6.46)



Şekil 6.46 : Doğruluk analizi için üretilen 112 nokta ve dağılımı.

Çizelge 6.7 : Landsat görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi

Sınıflar	1	2	3	4	5	6	7	8	9	10	11	12	13	ST
1(Y.Döken)	16	1	1	1	0	1	0	0	0	0	0	0	0	20
2(Y.Dökmeyen)	1	6	1	0	0	0	0	0	0	0	0	0	0	8
3(Çalılık)	0	0	10	2	0	2	0	0	1	0	0	0	0	15
4(Çayır_Çimen)	0	0	2	9	0	0	0	0	4	0	0	0	0	15
5(Yerleşim)	0	0	0	0	8	0	0	0	0	0	0	0	1	9
6(TarımA)	0	0	2	2	0	11	0	0	0	0	0	0	0	15
7(TarımB)	0	0	0	1	0	0	6	0	0	0	0	0	0	7
8(TarımC)	0	0	0	0	2	0	0	4	0	0	0	0	2	8
9(Toprak_Alan)	0	0	0	0	0	0	0	0	3	0	0	0	0	3
10(Su)	0	0	0	0	0	0	0	0	0	3	0	0	0	3
11(Kum_Ocağı)	0	0	0	0	0	0	0	0	0	0	3	0	0	3
12(Islak_Alan)	0	0	0	0	0	0	0	0	0	1	0	2	0	3
13(Boş_Alan)	0	0	0	0	0	0	0	1	0	0	0	0	2	3
Sütun Toplamı	17	7	16	15	10	14	6	5	8	4	3	2	5	112

Çizelge 6.8 : Landsat görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları

Üretici Doğruluğu		Kullanıcı Doğruluğu
Sınıflar	%	%
1(Y.Döken)	16/17 = 94	16/20 = 80
2(Y.Dökmeyen)	6/7 = 85	6/8 = 75
3(Çalılık)	10/16 = 63	10/15 = 67
4(Çayır_Çimen)	9/15 = 60	9/15 = 60
5(Yerleşim)	8/10 = 80	8/9 = 89
6(Tarım-A)	11/14 = 79	11/15 = 73
7(Tarım-B)	6/6 = 100	6/7 = 85
8(Tarım-C)	4/5 = 80	4/8 = 50
9(Toprak_Alan)	3/8 = 38	3/3 = 100
10(Su)	3/4 = 75	3/3 = 100
11(Kum_Ocağı)	3/3 = 100	3/3 = 100
12(Islak_Alan)	2/2 = 100	2/3 = 67
13(Boş_Alan)	2/5 = 40	2/3 = 67

$$\text{Genel Doğruluk} = (16+6+10+9+8+11+6+4+3+3+3+2+2)/112 = 0.7411$$

Çizelge 6.8’de de gösterildiği gibi *çalılık*, *ıslak alan*, *su* ve *toprak alan* sınıfları bulanık mantık fonksiyonlarıyla çıkarılmasına rağmen yeterli doğruluk sağlanamamıştır. *Toprak_Alan* sınıfının üretici doğruluğunun düşük çıkması *Çayır_Çimen* ve *Çalılık* sınıflarının yansıtım değerlerinin bu sınıfın değerleriyle karışmış olmasından kaynaklanmaktadır. Diğer sınıflar en yakın komşuluk sınıflandırıcısı ile sınıflandırılmış, *yerleşim*, *kum ocağı* ve *tarım-B* sınıflarında yüksek doğruluk sağlanmıştır.

Kappa (K) İstatistiği:

K istatistiği, referans veri ve otomatik bir sınıflandırıcı arasındaki gerçek uyuşum ile aynı referans verinin rastgele bir sınıflandırıcıyla arasındaki şans uyumu farkının bir ölçütü şeklinde tanımlanabilir. Diğer bir ifade ile, K istatistiği, hata matrisinin doğru değerleri elde ederken şans eseri mi yoksa gerçek bir uyuşum mu olduğunu gösterir. Genellikle 0 ile 1 arasındadır. Bu uygulamada elde edilen 0.71 değeri ölçülen sınıflandırmanın şans eseri sonuçlanması durumundan %71 daha iyi gibi düşünülebilir.

$$K = \frac{\ddot{O}.D - \S.U}{1 - \S.U} \quad (6.1)$$

Ö.D: Ölçülen doğruluk

Ş.U: Şans uyumu

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{it} * x_{ti}}{N^2 - \sum_{i=1}^r x_{it} * x_{ti}} \quad (6.2)$$

r: Hata matrisindeki satırların sayısı

x_{ii} : Satır i sütun i deki gözlemlerin sayısı (ana köşegen üzerinde)

x_{it} : Satır i'deki toplam gözlem

x_{ti} : Sütun i'deki toplam gözlem

N: Matriste içerilen toplam gözlem sayısı

$$\sum_{i=1}^r x_{ii} = 16 + 6 + 10 + 9 + 8 + 11 + 6 + 4 + 3 + 3 + 3 + 2 + 2 = 83$$

$$\sum_{i=1}^r x_{it} * x_{ti} = 20*17 + 8*7 + 15*16 + 15*15 + 9*10 + 15*14 + 7*6 + 8*5 + 3*8 + 3*3 + 3*2 + 3*5 = 1297$$


$$K = \frac{112*83 - 1297}{112^2 - 1297} = 0.71$$

6.2.3.2 Landsat görüntüsünün piksel tabanlı en yüksek olabilirlik yöntemiyle sınıflandırılması

Erdas 9.1 yazılımı ile yapılan piksel tabanlı sınıflandırmada spektral ayırımı arttırmak maksadıyla temel bileşenler analizi yapılmış görüntü kullanılmıştır. Daha anlamlı bir karşılaştırmanın yapılabilmesi için nesne tabanlı uygulamada kullanılan arazi sınıfları aynı şekilde bu uygulamada da yer almıştır. Piksel tabanlı sınıflandırma yöntemlerinden kontrollü sınıflandırma en yüksek olabilirlik (maksimum likelihood) metodu kullanılarak yapılmıştır.


Kontrollü sınıflandırmanın en önemli aşaması sınıflara ait örneklem alanların toplanmasıdır. İlgili alanlar toplanırken farklı bant kombinasyonlarıyla irdeleme,

daha yüksek çözünürlüklü, yakın tarihli görüntülerle doğrulama gibi sınıflandırmanın sonucuna etki edecek faktörler göz önünde bulundurulmuştur (Bkz. Şekil 6.47).




Şekil 6.47 : Landsat görüntüsünün piksel tabanlı sınıflandırılırken farklı band kombinasyonları ve yüksek çözünürlüklü görüntülerle irdelenmesi.

Spektral olarak kendi içinde diğerlerine oranla daha fazla farklılık gösteren veya sınıflandırılacak alana oranla daha büyük sınıflar için örneklem alan toplanırken sayıca fazla olmasına ve mümkün olduğu kadar her çeşitliliği içermesine dikkat edildi. Çalışma alanının sadece %1' ine denk gelen *kum ocağı* sınıfı ile %25-30'una denk gelen *yaprak döken ağaç* sınıfı için aynı sayıda örneklem alan alınmaması bununla ilgili verilebilecek örneklerden biridir.




Şekil 6.48 : Yerleşim sınıfına ait örneklem alanının toplanması.


Çalışma alanı boyunca 11 *yerleşim*, 7 *sı*, 9 *yaprak dökme*, 15 *yaprak döken*, 10 *tarım-A*, 7 *tarım-B*, 7 *tarım-C*, 5 *toprak alan*, 5 *kum ocağı*, 5 *boş alan*, 7 *çayır çimen*, 5 *çalılık* ve 3 *ıslak alan* olmak üzere toplam 97 adet örneklem alan toplanmıştır (Bkz. Şekil 6.50).




Şekil 6.49 : Tarım-A sınıfına ait örneklem alanının toplanması



Şekil 6.50 : Toplanan örneklem alanları ve dağılımı.




Şekil 6.51 : Landsat görüntüsünün piksel tabanlı sınıflandırılıp CBS ortamında haritalanması.



Şekil 6.52 : Landsat görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.


Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi

Bu uygulamadaki doğruluk analizi Erdas 9.1 yazılımı ile yapılmıştır. Öncelikle sınıflandırma sonucu oluşan alanlarla orantılı olarak yazılım aracılığıyla otomatik olarak rastgele 118 nokta atırılmıştır (Bkz. Şekil 6.53)



Şekil 6.53 : Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi için atılan rastgele 118 nokta ve dağılımı.

Otomatik atılan her nokta manuel olarak yer gerçeği bilgisi ile kontrol edilip doğruluk analizi gerçekleştirilmiştir. Yer gerçeği bilgisi Ikonos Haziran 2005 (pan-sharpaned) görüntüsü ve Landsat görüntüsünün farklı band kompozitleriyle yorumlanmak suretiyle sağlanmıştır (Bkz. Şekil 6.54)



Şekil 6.54 : Landsat görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi yapılırken yer gerçeği ile karşılaştırma.

Çizelge 6.9 : Landsat görüntüsünün piksel tabanlı sınıflandırma sonucunda oluşan hata matrisi.

	Toplam	Toplam	Doğru	Doğruluğu (%)		Kappa
Sınıf Adı	Referans	Sınıflandırılan	Sayısı	Üretici	Kullanıcı	%
1(Y.Döken)	23	20	19	82.61	95.00	94
2(Y.Dökmeyen)	8	8	8	100.00	100.00	100
3(Çalılık)	12	15	10	83.33	66.67	63
4(Çayır_Çimen)	10	15	9	90.00	60.00	56
5(Yerleşim)	8	15	8	100.00	53.33	50
6(TarımA)	18	15	15	83.33	100.00	100
7(TarımB)	13	7	6	46.15	85.71	84
8(TarımC)	10	8	8	80.00	100.00	100
9(Toprak_Alan)	4	3	3	75.00	100.00	100
10(Su)	4	3	3	75.00	100.00	100
11(Kum_Ocağı)	3	3	3	100.00	100.00	100
12(İslak_Alan)	2	3	2	100.00	66.67	66
13(Boş_Alan)	3	3	2	66.67	66.67	66
Toplamlar	118	118	96			

Toplam Sınıflandırma Doğruluğu = % 81.36

Kappa (K) İstatistiği:


Toplam Kappa istatistiği = 0.7917

Çizelge 6.9’da gösterildiği gibi piksel tabanlı MLC yöntemi Landsat görüntüsü için genel doğruluk anlamında nesne tabanlı yöntemle göre daha iyi sonuç vermiştir. Özellikle *Yaprak Döken*, *Yaprak Dökmeyen*, *Tarım-C*, *Toprak Alan*, *Su*, *Kum Ocağı* ve *İslak Alan* sınıfları yüksek doğrulukla elde edilmiştir. *Çayır_Çimen* ve “*çalılık*” sınıflarının kullanıcı doğruluğu, nesne tabanlı yöntemde elde edilen değer gibi düşük olması bu sınıfların ayırt edilebilirliği için farklı yöntemler denenmesi gerektiğini göstermektedir.

6.2.3.3 Landsat görüntüsünün piksel ve nesne tabanlı sonuçlarının karşılaştırılması


Çizelge 6.10 : Landsat görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.

Sınıflar	DOĞRULUK(%)	
	Piksel Tabanlı Sınıflandırma	Nesne Tabanlı Sınıflandırma
Yaprak_Döken	95	80
Yaprak_Dokmeyen	100	75
Calilik	66,67	67
Cayir_Cimen	60	60
Yerlesim	53,33	89
Tarım-A	100	73
Tarım-B	85,71	85
Tarım-C	100	50
Toprak_Alan	100	100
Su	100	100
Kum_Ocağı	100	100
Islak_Alan	66,67	67
Bos_Alan	66,67	67
Kappa	79,17	71
GENEL	81,36	74,1



Şekil 6.55 : Landsat görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.

Piksel ve nesne tabanlı sınıflandırma yöntemlerini Landsat görüntüsü için değerlendirildiğinde genel doğruluk anlamında %81,36'ya karşılık %74,1'lik doğrulukla piksel tabanlı maksimum likelihood sınıflandırıcısı daha iyi sonuç vermektedir. Sınıf bazlı düşünüldüğünde nesne tabanlı metodun sadece yerleşim sınıfı %89'a karşılık %53,33'lük doğrulukla daha iyi sonuç verdiği görülmektedir (Bkz. Çizelge 6.10 ve Şekil 6.55).




Şekil 6.56 : Landsat görüntüsündeki yerleşim sınıfının nesne ve piksel tabanlı sınıflandırma sonuçları.

Bunun nedeni, nesne tabanlı yöntemin yukarıdan aşağıya “top down”ve aşağıdan yukarıya “bottom-up” mantığı ile hareket ederek karışabilecek olası sınıfları maskeleyesidir. Ayrıca bu düşük doğruluk yerleşim türlerine ait örneklem alanlarının sayısının azlığıyla da ilişkilendirilebilir. Nesne tabanlı sınıflandırmada piksellerin radyometrik kalitesinden çok, çıkarılması düşünülen nesnelerin boyutlarının doğru bir şekilde analiz edilmesi önemli olduğu için daha yüksek çözünürlüklü görüntünün olması önemlidir. Bu nedenle *tarım-A*, *tarım-B*, *tarım-C* ve *yerleşim* gibi sınıflar üyelik fonksiyonlarıyla değil de bir özellik uzayı belirlenerek standart en yakın komşuluk metoduyla sınıflandırılmıştır. Sonuçta segmentlerin dahil olduğu bir sınıflandırma yapıldığından bu yöntem piksel tabanlı yöntemin vazgeçilmez sorunlarından olan tuz-biber etkisi sorununu ortadan kaldırmaktadır. *Toprak alan*, *su* ve *kum ocağı* sınıflarının doğrulukları her ne kadar eşit görünse de nesne tabanlı yöntemle bu sınıfların üyelik fonksiyonlarıyla önceden ayıklanarak

muhtemel karışıklık önlenmiş oldu. Piksel tabanlı sınıflandırmada piksellerin radyometrik kalitesinin etkisi tarım sınıfının doğruluklarında açıkça görülmektedir.

6.2.4 İkonos görüntüsünün sınıflandırılması


4m mekansal çözünürlüklü ve 4 bantlı (kırmızı, yeşil, mavi ve yakın kızılötesi) uydu görüntüsü üzerinde (Bkz. Şekil 6.57) görsel analiz yapılarak çıkarılabilecek sınıflar tespit edilmiştir. Bu sınıflar, yeşil alanlar (yüksek, orta ve alçak), tarım alanları (A,B,C olmak üzere 3 tür), su, boş alan, toprak-çayır, bina ve yol olmak üzere 11 adettir. Yeşil alan sınıfının içerdiği klorofil miktarı gözetilerek yansıtım değerleri dikkate alındığında 3 ayrı sınıfta incelenmesi düşünülmüştür. Ayrıca bu sınıflar arazideki tespitlerle de ilişkilendirildiğinde aşağı yukarı boyları ile doğru orantılı olduğu gözlenmiştir. Aynı şekilde tarım sınıfı da mevcut yansıtım değerleri dikkate alındığında kendi içinde “ürün toplanmış”, “ürün toplanmamış” ve “ekili” olmak üzere 3 ana türe ayrılmasının sınıflandırmayayeni bir boyut kazandıracağı beklenmektedir.



Şekil 6.57 : Sınıflandırılacak olan İkonos görüntüsünün farklı ölçek ve bant kombinasyonları.


6.2.4.1 İkonos görüntüsünün çoklu segmentasyon ve üyelik fonksiyonlarıyla oluşturulan nesne tabanlı görüntü analizi ve sınıflandırması

Sınıflandırmaya başlamadan önce bina ve yol sınıflarından karmaşık yansıtım değerleri göz önünde bulundurulduğunda önceki tecrübelerimizden de yararlanarak sınıflandırma doğruluğunu arttırmak için bu iki veri vektörel olarak sınıflandırmaya dahil edilmiştir (Bkz. Şekil 6.58)




Şekil 6.58 : Sınıflandırmaya dahil edilen vektörel veriler.

Yol ve bina verileri için bir seviye belirlenerek bu veriler o seviyenin içine konup sınıflandırılmıştır. Sonrasında yeni bir seviye yani segmentasyon için çıkarılabilecek nesnelerin büyüklükleri açısından değerlendirme yapılmıştır. Yeşil alanlar ve alt türlerinin ayırımı düşünülmüş ve ölçek parametresi = 40, renk faktörü = 0,7 ve sıklık faktörü = 0.5 olan ikinci bir segmentasyon yapılmıştır (Bkz. Şekil 6.59)




Şekil 6.59 : İkonos görüntüsünün ikinci segmentasyonu.

NDVI kullanılarak yeşil alan ve “yeşil alan değil” olmak üzere iki sınıf oluşturulur. >0.4475 değerler yeşil alan olarak alınmıştır. Yeşil alanın alt türleri olan alçak orta ve yüksek sınıfları için aynı fonksiyonun sırasıyla 0.4475-0.52, 0.52-0.63, ve >0.63 değerler alınmıştır (Bkz. Şekil 6.60).




Şekil 6.60 : İkonos görüntüsünde yeşil alan ve alt türlerinin ayrımında kullanılan fonksiyonlar.

Yeşil alanlar sınıflandırıldıktan sonra tarım alanları, su, toprak çayır ve boş alanların sınıflandırılmasına geçilmiştir. Bu alanlar nesne olarak daha küçük ve farklı olduğundan yeni bir segmentasyona ihtiyaç duyulmuştur. Çalışmanın başında en uygun ölçeği seçmek için birtakım hesaplamalar yapılmıştı. Tarım-A, tarım-B ve tarım-C sınıfları arasındaki ayrımın yapılabileceği en uygun ölçeğin 30 olduğu sonucu elde edilmişti. Bu doğrultuda yeni segmentasyonun ölçek parametresi 30, renk faktörü 0.5 ve sıklık faktörü 0.9 olmuştur (Bkz. Şekil 6.61)



Şekil 6.61 : İkonos görüntüsünün üçüncü ve son segmentasyonu.

Bu segmentasyon için bir seviye belirlenerek üst seviyelerde yapılan sınıflandırmalar bu seviyeye aktarılır. Sonrasında tarım-A sınıfının ayırt edilmesine geçilmiştir. Bunun için tıpkı kontrollü sınıflandırma yapar gibi bu türe ait örneklem alanlar seçildi ve seçilen alanlar histogram üzerinde incelenerek uygun aralık tespit edilmiş oldu. (Bkz. Şekil 6.62)




Şekil 6.62 : Tarım-A sınıfı için oluşturulan fonksiyon.

Su, boş alan, tarım-B, tarım-C ve toprak-çayır sınıfları da uygun fonksiyon ve aralıklar tespit edilerek sınıflandırılmıştır.


Çizelge 6.11 : İkonos görüntüsünün nesne tabanlı sınıflandırılmasında uygulanan fonksiyon ve kurallar

Sınıflar	Nesne Tabanlı sınıflandırmada kullanılan özellikler
Tarım-A	Ratio Layer 1(Generated) <0.226, >0.240
	Bina değil (inherited)
	Arkaplan değil (inherited)
	Yol değil (inherited)
	Level1 (inherited)
Tarım-B	Ratio Layer 4 < 0.29
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level1 (inherited)
	Su değil (inherited), Tarım-A değil (inherited), Boş_alan değil (inherited)
Tarım-C	Toprak_çayır değil, Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level1 (inherited)
	Su değil (inherited), Tarım-A değil (inherited), Tarım-B değil (inherited)
Toprak-Çayır	Ratio Layer 4 < 0.3495
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level1 (inherited)
	Su değil (inherited), Tarım-A değil (inherited), Tarım-B değil (inherited)
Yeşil (Alçak)	NDVI < 0.4475, >0.52
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level2 (inherited), Yeşil alan içinde (inherited)
Yeşil (Orta)	NDVI < 0.52, >0.63
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level2 (inherited), Yeşil alan içinde (inherited)
Yeşil (Yüksek)	NDVI > 0.63
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level2 (inherited), Yeşil alan içinde (inherited)
Su	Ratio Layer 4 < 0.205
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level1 (inherited)
	Tarım-A değil (inherited)
Boş Alan	1/Brightness <=0.00135
	Bina değil (inherited), Arkaplan değil (inherited), Yol değil (inherited)
	Level1 (inherited)
	Su değil (inherited), Tarım-A değil (inherited)
Bina	Object ID: Thematic Layer 2 < 0
	Yol değil (inherited)
	Level3 (inherited)
Yol	Object ID: Thematic Layer 1 < 0
	Level3 (inherited)

Çizelge 6.11 de, İkonos görüntüsünün nesne tabanlı yöntemle sınıflandırılırken her sınıfa uygulanan fonksiyonlar ve kurallar tanımlanmıştır. (inherited) kavramı o sınıfın ilişkili olduğu sınıfı göstermektedir.



Şekil 6.63 : İkonos görüntüsünün nesne tabanlı sınıflandırma sonucu.



Şekil 6.64 : İkonos görüntüsünden nesne tabanlı sınıflandırılan alanlar ve grafiksel gösterimi

İkonos görüntüsünün nesne tabanlı sınıflandırma doğruluk analizi

Çizelge 6.12 : İkonos görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan hata matrisi

Sınıflar	1	2	3	4	5	6	7	8	9	10	11	ST
1Bina	4	0	0	0	0	0	0	0	0	0	0	4
2Yol	0	6	0	0	0	0	0	0	0	0	0	6
3Yeşil(Alçak)	0	0	6	1	0	0	0	0	1	0	0	8
4Yeşil(orta)	0	0	1	11	1	0	0	0	1	0	0	14
5Yeşil(yüksek)	0	0	0	3	17	0	0	0	0	0	0	20
6TarımA	0	1	0	0	2	6	0	0	0	0	0	9
7TarımB	1	0	0	0	0	0	3	0	0	0	0	4
8TarımC	0	0	0	0	0	0	0	8	2	0	0	10
9Toprak_Çayır	0	1	1	0	0	1	0	1	7	0	0	11
10Boş_Alan	0	0	0	0	0	0	1	0	0	2	0	3
11Su	0	0	0	0	0	0	0	0	0	0	2	2
Sütun Toplamı	5	8	8	15	20	7	4	9	11	2	2	91

Çizelge 6.13 : İkonos görüntüsünün nesne tabanlı sınıflandırma sonucunda oluşan üretici ve kullanıcı doğrulukları

Üretici Doğruluğu		Kullanıcı Doğruluğu
Sınıflar	%	%
1Bina	4/5=80	4/4=100
2Yol	6/8=75	6/6=100
3Yeşil(Alçak)	6/8=75	6/8=75
4Yeşil(orta)	11/15=73	11/14=79
5Yeşil(yüksek)	17/20=85	17/20=85
6TarımA	6/7=86	6/9=67
7TarımB	3/4=75	3/4=75
8TarımC	8/9=89	8/10=80
9Toprak_Çayır	7/9=64	7/11=64
10Boş_Alan	2/2=100	2/3=75
11Su	2/2=100	2/2=100

Genel doğruluk = $(4+6+6+11+17+6+3+8+7+2+2)/91 = 72/91 = 0.7912$

Çizelge 6.12 ve Çizelge 6.13’de görüldüğü gibi bina ve yol sınıflarının vektörel olarak sınıflandırmaya entegre edilmesiyle bu sınıflara ait %100’lük bir doğruluk elde edilmiş, diğer sınıflarla karışması engellenmiştir. Sınıflandırmada yakın kızılötesi bandın da kullanılmasıyla NDVI oluşturularak “yeşil alan” ve alt türleri

için %75-85 arası bir doğruluk elde edilmiştir. “*Toprak_Çayır*” hem yansıtım değeri hem de doğadaki şekli itibaiyle *Tarım-A* ve *Tarım-C* sınıfı ile karıştığından %64’lük bir doğruluk elde edilmiştir. Benzer sorunlar “*Boş_Alan*” ve *Tarım-B* sınıfları için de geçerli olduğundan bu sınıfların doğruluğu %75’tir. %79’luk genel doğruluğuyla nesne tabanlı sınıflandırma, yüksek çözünürlüklü Ikonos görüntüsünün arazi kullanım haritası üretme açısından önünü açmaktadır.

Kappa (K) İstatistiği:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{it} * x_{ti}}{N^2 - \sum_{i=1}^r x_{it} * x_{ti}} \quad (6.3)$$

r: Hata matrisindeki satırların sayısı

x_{ii} : Satır i sütun i deki gözlemlerin sayısı (ana köşegen üzerinde)

x_{it} : Satır i’deki toplam gözlem

x_{ti} :Sütun i’deki toplam gözlem

N: Matriste içerilen toplam gözlem sayısı


$$\sum_{i=1}^r x_{ii} = 4 + 6 + 6 + 11 + 17 + 6 + 3 + 8 + 7 + 2 + 2 = 72$$

$$\sum_{i=1}^r x_{it} * x_{ti} = 4*5 + 6*8 + 8*8 + 14*15 + 20*20 + 9*7 + 4*4 + 10*9 + 11*11 + 3*2 + 2*2 = 1051$$

$$K = \frac{91*72 - 1051}{91^2 - 1051} = 0.76$$


6.2.4.2 İkonos görüntüsünün piksel tabanlı sınıflandırılması

Erdas 9.1 yazılımında yapılan piksel tabanlı sınıflandırmada sınıflararası karışıklığı minimuma indirmek için bina ve yol sınıfı birleştirilerek tek bir sınıf olarak sınıflandırılmaya girmiştir. Çalışma alanında 28 adet bina-yol, 20 adet Tarım-A, 16 adet Tarım-B, 14 Tarım-C, 12 Yeşil(Yüksek), 10 Yeşil(Orta), 10 Yeşil(Alçak), 7 Boş Alan ve 14 Torak_Çayır olmak üzere toplam 131 adet örneklem alan toplanmıştır (Bkz. Şekil 6.65).




Şekil 6.65 : İkonos görüntüsünde toplanan örneklem alanlar ve dağılımı

Kontrollü sınıflandırmanın en önemli aşaması olan örneklem alanların toplanırken, çalışma alanının her bölgesinden olmasına ve mümkün olduğunca sınıflara ait tüm çeşitliliği içermesine özen gösterildi. Toplanan bu örneklem alanlar en yüksek olabilirlik sınıflandırıcı ile sınıflandırılarak sınıflandırma sonucu ve alanların grafiksel gösterimi Şekil 6.66 ve şekil 6.67’de gösterilmiştir.




Şekil 6.66 : İkonos görüntüsünün piksel tabanlı sınıflandırma sonucu.



Şekil 6.67 : İkonos görüntüsünden piksel tabanlı sınıflandırılan alanlar ve grafiksel gösterimi.

Ikonos görüntüsünün piksel tabanlı sınıflandırma doğruluk analizi:

Doğruluk analizi, Erdas 9.1 yazılımıyla görüntü üzerine sınıfların alanları ağırlığınca rastgele dağılmış 93 noktanın atılmasıyla yapılmıştır. Atılan bu noktaların yer gerçeği bilgileri, aynı tarihli Ikonos (1m pan-sharpaned) görüntüsünden elde edilerek karşılaştırılmıştır. (Bkz. Şekil 6.68)



Şekil 6.68 : Sınıflandırılan Ikonos görüntüsünün yer gerçeği bilgisi ile karşılaştırılması.


Çizelge 6.14 : Ikonos görüntüsü için piksel tabanlı sınıflandırma sonuçları.

	Toplam	Toplam	Dogru	Doğruluğu (%)		Kappa
Sınıf Adı	Referans	Sınıflandırılan	Sayısı	Üretici	Kullanıcı	%
Bina+Yol	3	11	2	66.67	18.00	15
Yeşil(Alçak)	14	13	9	64.29	69.00	64
Yeşil(orta)	19	15	11	57.89	73.33	66
Yeşil(yüksek)	14	17	12	85.71	70.59	65
TarımA	7	5	3	42.86	60.00	57
TarımB	17	9	7	41.18	77.78	73
TarımC	5	4	3	60.00	75.00	74
Toprak_Çayır	10	15	8	80.00	53.33	48
Boş_Alan	1	2	1	100.00	50.00	49
Su	2	2	2	100.00	100.00	100
Toplamlar	93	93	58			

Genel doğruluk = % 62.37

Toplam Kappa Değeri = 0.5867

Bina+Yol sınıfının yeteri kadar örneklem alan toplanmasına rağmen %18’lik bir doğrulukla çıkması çoğunlukla tarım sınıfı ile yolların karışmasından kaynaklanmaktadır (Bkz. Şekil 6.69).




Şekil 6.69 : İkonos görüntüsünün piksel tabanlı sınıflandırılmasında karışan sınıflar.

Tarım-B, *Tarım-C* ve *Su* sınıfları bu sınıflandırmada diğer sınıflara göre daha yüksek doğrulukla çıkmıştır. *Toprak_Çayır* ve *Boş_Alan* sınıfı da *yol* ve *tarım* sınıflarıyla karışarak %50 civarında doğruluk vermiştir.


6.2.4.3 İkonos görüntüsü için piksel ve nesne tabanlı sonuçlarının karşılaştırılması

Çizelge 6.15 ve Şekil 6.72’de de gösterildiği gibi yüksek çözünürlüklü İkonos görüntüsünün nesne tabanlı sınıflandırılması %62’ye karşın %79’luk bir doğrulukla daha iyi sonuç vermiştir. Vektörel verilerin de sınıflandırmaya entegre olmasıyla nesne tabanlı sınıflandırmada sınıflararası karışıklık azalmış bina ve yol sınıflarında %100’lük bir doğruluğa ulaşılmıştır. Bu değer piksel tabanlı sınıflandırmada %18’dir. Nesne tabanlı sınıflandırma stratejilerinden “top-down” yöntemiyle sınıflandırılacak türler boyut olarak büyükten küçüğe doğru sınıflandırılmış ilk etapta yeşil alan türlerinin ayıklanması sağlanmıştır. *Yeşil(alçak)* türünün doğruluğu piksel tabanlı sınıflandırmada %69.23 iken nesne tabanlı sınıflandırmada %75’e çıkmıştır. Bulanık mantık fonksiyonları ile sınıflara ait aralıklar hesaplandığı için bir çok karışıklık görüntünün spektral bilgisinin yettiği oranda minimuma indirilmiştir. Piksel tabanlı sınıflandırmanın temel sorunu tuz biber etkisi Şekil 6.70’de gösterildiği gibi bu yöntemde karşımıza çıkmamaktadır. Şekil 6.69’de görülen

bina_yol ve *tarım* sınıfları arasındaki karışıklık bu yöntemde olmamaktadır (Bkz. Şekil 6.71).




Şekil 6.70 : Piksel ve nesne tabanlı sınıflandırma sonucunda tuz-biber etkisi.



Şekil 6.71 : Şekil 6.69’da gösterilen alandaki karışıklığın nesne tabanlı sınıflandırma sonucu.

Çizelge 6.15 : İkonos görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması.

Sınıflar	DOĞRULUK(%)	
	Piksel Tabanlı Sınıflandırma	Nesne Tabanlı Sınıflandırma
Bina+Yol	18,18	100
Yeşil(Alçak)	69,23	75
Yeşil(orta)	73,33	79
Yeşil(yüksek)	70,59	85
Tarım-A	60	67
Tarım-B	77,78	75
Tarım-C	75	80
Toprak_Çayır	53,33	64
Boş_Alan	50	75
Su	100	100
Kappa	58,67	76
GENEL	62,37	79



Şekil 6.72 : İkonos görüntüsü için piksel ve nesne tabanlı sınıflandırma sonuçlarının grafiksel gösterimi.

7. SONUÇLAR VE ÖNERİLER

Doğu Trakya Bölgesi içinde kalan biri 194000 ha'lık diğeri 11000'ha'lık iki ayrı çalışma alanında Haziran 2005 tarihli Ikonos (4m, 4 bant), SPOT 5 (2.5m, 3 bant) ve Landsat (30m, 6 bant) görüntüleri nesne ve piksel tabanlı yöntemlerle sınıflandırılarak arazi örtüsü haritaları üretilmiş ve her iki yöntemin de avantajları ve dezavantajları olduğu belirlenmiştir.

Nesne tabanlı sınıflandırmada segmentasyon önemli bir işlemdir. Görüntünün nesnelere bölünerek segmente edilmesini sağlayan ölçek parametresine genellikle kullanıcı tarafından karar verilmelidir. Ancak bu karar kişisel olmalıdır çünkü bu işlem büyük ölçüde yorumlayıcının tecrübesine bağlı olmaktadır. Segmentasyon için en uygun ölçek parametresinin seçiminde yol gösterici olması için ED kantitatif bir indeks gibi kullanılmıştır. Bu indeks tüm olası değerler arasından en uygun ölçek parametresinin seçimi için kullanılmıştır. En uygun ölçek en yüksek ED değerine sahip olan şekilde tanımlanmıştır. Bu yaklaşım nesne tabanlı sınıflandırmayı daha verimli ve daha efektif yapmaktadır.

Ikonos ve SPOT 5 gibi yüksek çözünürlüklü görüntülerin sınıflandırmasının mümkün olduğunca mekansal verilerin kullanılarak yapılması konusunda uzaktan algılamada artan bir görüş birliği söz konusudur. Daha önceki sınıflandırma deneyimlerimizden de yararlanarak yol ve bina verisi sınıflandırmaya bir katman olarak entegre edilmiş ve buna göre bir segmentasyon yapılarak sınıflandırılmışlardır. Geliştirilen birtakım matematiksel fonksiyonların yazılıma entegre edilmesiyle bazı sınıfların ayırımına gidilmiştir. Çalışma alanı içinde görülen bazı tarım türlerinin sınıflandırılması için dijital yükseklik modeli sınıflandırmaya dahil edilmiştir. Top-down stratejisi ile çalışan nesne tabanlı sınıflandırmada sınıflandırılacak nesneler büyükten küçüğe doğru sınıflandırıldığı için karışıklıklar giderilmiştir. Aynı şekilde oluşturulan farklı seviyeler daha yüksek doğruluk elde etmemizi sağlamıştır. Buna karşın piksel tabanlı sınıflandırma da yüksek çözünürlüklü Ikonos ve SPOT 5 görüntüleri için özellikle bina ve yol sınıflarında

%18 ve %25'lik doğruluklarla gereken başarı sağlanamamıştır. Ikonos görüntüsü için piksel tabanlı sınıflandırma doğruluğu %62, nesne tabanlı sınıflandırma doğruluğu ise %76 olarak hesaplanmıştır. SPOT 5 görüntüsü için piksel tabanlı sınıflandırma doğruluğu %67.5 iken nesne tabanlı sınıflandırma doğruluğu %86'dır. SPOT 5 görüntüsündeki bu yüksek doğruluk, hem dijital yükseklik modeli hem de bina-yol katmanlarının sınıflandırmaya entegre edilmesiyle açıklanabilir.

Landsat görüntüsü için sonuçlar biraz daha farklıdır. Nesne tabanlı sınıflandırmanın en büyük avantajlarından biri görüntüyü nesnelere ayırıp, bu nesneleri bulanık mantık veya kendi belirleyeceğimiz fonksiyonlarla sınıflandırmaktır. Ancak bu yöntem Landsat görüntüsü için başarılı sonuç vermemiştir. İlgili türlere ilişkin fonksiyon aralıkları tespit edilememektedir. 13 sınıftan sadece 4 sınıf bulanık mantık fonksiyonlarıyla ayrılmış, diğerleri ise segmentasyon sonrası en yakın komşuluk sınıflandırması ile sınıflandırılmıştır. Landsat görüntüsündeki sınıflar arası ayırt edilebilirlik, 30m mekansal çözünürlüğünden dolayı, segmente edilen nesnelere yapılan sınıflandırmaya kıyasla sadece pikseller kullanıldığında daha fazladır. PCA'nın da uygulanmasıyla bantlar arası korelasyon minimuma indirgenerek sınıfların daha iyi ayrılması sağlanmıştır. Piksel tabanlı MLC sınıflandırması %74'e karşı %81'lik doğrulukla daha iyi sonuç vermiştir. Nesne tabanlı yöntemin Landsat görüntüsündeki başarısı yerleşim sınıfında elde ettiği %53'e karşın %89'luk doğruluktur. Segmente edilen nesnelerle sınıflandırmanın yapılması tuz-biber etkisi sorununu ortadan kaldırarak kısmen daha iyi sonuç vermiştir.

Gelişen teknoloji ile arazi kullanımı ve arazi örtüsü haritası üretimi farklı bir boyut kazanmıştır. Sadece pikseller yerine piksellerin renk, sıklık, komşuluk gibi birtakım fonksiyonlarını da kullanan nesne tabanlı sınıflandırma, özellikle yüksek çözünürlüklü uydu görüntülerinden bu haritaların üretimi açısından bir çok disiplinin dikkatini çekebilecek bir potansiyel olmuştur. Diğer taraftan orta çözünürlüklü uydular için klasik piksel tabanlı sınıflandırmanın avantajları da göz ardı edilmemelidir. Elde edilen sonuçların tutarlı olduğunu ortaya koymak için farklı çalışma alanlarında daha fazla incelemenin yapılması gerekmektedir.


KAYNAKLAR

- Büyüksalih, G.**, 2004 *Dijital görüntü işleme ders notları*, ZKÜ.
- Buyuksalih, İ.**, 2006 *Landsat Geocover Ortho ve LC verilerinin Geometrik Doğruluk ve Değişim Belirleme Amaçlı Analizleri*, Yüksek Lisans Tezi.
- Canty J. Morton**, 2007: *Image Analysis, Classification and Change Detection in Remote Sensing, (with algorithms for Envi/IDL)*, Taylor & Francis Group.
- Gao Y., Mas J.F., Niemyer I.**, 2004: *Object-Based Image Analysis for Mapping Land-Cover in a Forest Area*.
- Laliberte S. Andrea, Rango Albert, Havstad M. Kris**, 2004: *Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico*, *Remote Sensing of Environment* 93 (2004) 198-210.
- Schott R. John**, 2007: *Remote Sensing The Image Chain Approach*. 2nd edition, Rochester Institute of Technology, OXFORD University Press.
- Verbyla L David**, 1999. *Satellite Remote Sensing of Natural Resources*, Mapping Sciences Series, New York.
- Wang L., Sousa W. P., Gong P.**, 2004: *Integration of object-based and pixel-based classification for mapping mangroves with Ikonos imagery*, Taylor & Francis Group, *Int. J. Remote Sensing*, 20 December, 2004.


EKLER

EK A.1 : İkonos görüntüsünde sınıflar arası öklit uzaklıklarının grafiksel gösterimi


EK A.1




a) Scale5




b) Scale10



c) Scale20



d) Scale30



e) Scale40

Şekil A.1 : İkonos görüntüsünde sınıflar arası öklit uzaklıklarının grafiksel gösterimi
a) Scale5, b) Scale10, c) Scale20, d) Scale30, e) Scale40

ÖZGEÇMİŞ



Ad Soyad: Serdar BAYBURT

Doğum Yeri ve Tarihi: İZMİT 06.10.1980

Lisans Üniversitesi: Yıldız Teknik Üniversitesi (2003)

Yayın Listesi:

▪ **Bayburt S.**, Büyüksalih G., Jacobsen K., and Kersten T., 2008: Detection of changes in Istanbul area with medium and high resolution space images. *The XXI ISPRS Congress, July 3-11, 2008 Beijing, China.*

