

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK ÖLÇEKLİ KARTOGRAFİK GÖSTERİMLERDE
MEKANSAL BİLGİNİN NİCELİK ANALİZİ**

DOKTORA TEZİ

Serdar BİLGİ

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

MART 2012

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK ÖLÇEKLİ KARTOGRAFİK GÖSTERİMLERDE
MEKANSAL BİLGİNİN NİCELİK ANALİZİ**

DOKTORA TEZİ

**Serdar BİLGİ
(501032607)**

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

**Tez Danışmanı: Prof. Dr. Cengizhan İPBÜKER
Eş Danışman: Prof. Dr. Okan K. ERSOY**

MART 2012

İTÜ, Fen Bilimleri Enstitüsü'nün 501032607 numaralı Doktora Öğrencisi **Serdar BİLGİ**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**ÇOK ÖLÇEKLİ KARTOGRAFİK GÖSTERİMLERDE MEKANSAL BİLGİNİN NİCELİK ANALİZİ**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Cengizhan İPBÜKER**
İstanbul Teknik Üniversitesi

Eş Danışman : **Prof.Dr. Okan K. ERSOY**
Purdue University/ABD

Jüri Üyeleri : **Prof. Dr. Doğan UÇAR**
İstanbul Teknik Üniversitesi

Prof. Dr. Mehmet SELÇUK
Yıldız Teknik Üniversitesi

Prof. Dr. Necla ULUĞTEKİN
İstanbul Teknik Üniversitesi

Prof. Dr. Mustafa YANALAK
İstanbul Teknik Üniversitesi

Doç. Dr. Türkay GÖKGÖZ
Yıldız Teknik Üniversitesi

Teslim Tarihi : **30 Ocak 2012**
Savunma Tarihi : **21 Mart 2012**

Eşim Lutfiye ve oğullarım Emirhan ile Arda'ya,

ÖNSÖZ

“Çok Ölçekli Kartografik Gösterimlerde Mekansal Bilginin Nicelik Analizi” başlıklı doktora çalışmam süresince değerli katkılarda bulunan danışmanım Prof.Dr. Cengizhan İPBÜKER’e, çalışmamın Amerika Purdue Üniversitesi Elektrik ve Bilgisayar Mühendisliği Bölümü’nde yapılan kısmını yöneten eş danışmanın Prof.Dr. Okan K. ERSOY’a, İTÜ Geomatik Mühendisliği Bölümünden Prof.Dr. Necla ULUĞTEKİN ve Prof.Dr. Doğan UÇAR’a, YTÜ Harita Mühendisliği Bölümünden Prof.Dr. Mehmet SELÇUK ve Doç.Dr. Türkay GÖKGÖZ’e ve Selçuk Üniversitesi Harita Mühendisliği Bölüm Başkanı Prof.Dr. İ. Öztuğ BİLDİRİCİ’ye teşekkür ederim.

Amerika’da çalışmalarım süresince yüksek çözünürlüklü uydu görüntülerinin temini konusundaki yardımlarından dolayı Purdue Üniversitesi Uzaktan Algılama Uygulamaları Laboratuvarı Müdürü Larry L. BIEHL’e ve Matlab yazılımı konusunda desteğini aldığım İTÜ Bilgisayar Mühendisliği Bölümü öğretim elemanı Dr. Gülşen TAŞKIN KAYA’ya teşekkür ederim.

Çalışmalarımın yurtdışı kısmını destekleyen TÜBİTAK’a teşekkür ederim.

Doktora çalışmasına başladığım ilk günlerden bu yana bana verdiği moral destekleri ve güvenden dolayı sevgili hocalarım Doç.Dr. Yunus KALKAN’a, İTÜ Rektörü Prof.Dr. Muhammed ŞAHİN’e, İTÜ KKTC Rektörü Prof.Dr. Mustafa YANALAK’a ve Hitit Üniversitesi Rektörü Prof. Dr. Reha M. ALKAN’a, İTÜ İnşaat Fakültesi Dekanı Prof.Dr. Gaye ONURSAL DENLİ ve bölümümüz öğretim üyesi Doç.Dr. Hakan DENLİ’ye, İTÜ Geomatik Mühendisliği Bölüm Başkan yardımcıları Dr. Ufuk ÖZERMAN ve Doç.Dr. Şinasi KAYA’ya, bölümümüz öğretim elemanlarından Yrd.Doç.Dr. Turan ERDEN, Yrd.Doç.Dr. Himmet KARAMAN, Yrd.Doç.Dr. A. Özgür DOĞRU, Dr. Hakan YAVAŞOĞLU, Ar. Gör. Filiz KURTCEBE ALTIN ve Ar. Gör. Uğur ALTIN’a teşekkür ederim.

Çalışmalarım sırasında desteklerini aldığım YTÜ Kartografya Anabilim Dalı öğretim üyeleri Yrd.Doç.Dr. Melih BAŞARANER ve Yrd.Doç.Dr. Fatih GÜLGEN’e, Çanakkale Onsekiz Mart Üniversitesi Geomatik Mühendisliği Bölümü Başkanı Yrd.Doç.Dr. Mehmet Ali YÜCEL’e teşekkür ederim.

Yurtdışında kaldığım süre içerisinde her daim yanımda olan Purdue Üniversitesi Türk Öğrenci Birliği Başkanı Burak TÜRKMAN’a, değerli mensupları Duygun GÖKTÜRK, Şerife AĞCAOĞLU, Tuğba YÜKSEL, Cem AKATAY, Özhan KÖYBAŞI, Burak BİTLİS ve değerli meslektaşım Dr. Serkan URAL’a, kendilerini ailem kadar yakın hissettiğim Cindy-Peter ZULL, Carol-Larry WEISI ve Nihayet-Okan ERSOY çiftlerine teşekkür ederim.

Doktora çalışmam süresince en büyük desteğim olan eşim Lutfiye’ye ve aileme en içten teşekkürlerimi sunuyorum.

Mart 2012

Serdar BİLGİ
Geomatik Yüksek Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
2. HARİTANIN MEKANSAL BİLGİSİNİN MEVCUT NİCEL ÖLÇME YÖNTEMLERİ ile DEĞERLENDİRİLMESİ.....	7
2.1 Temel Kavramlar.....	7
2.1.1 Kartografik iletişim ağı	7
2.1.2 Genelleştirme	8
2.1.3 Çok ölçekli kartografik gösterimler	9
2.1.4 Topoloji kavramı	9
2.1.5 Entropi kavramı.....	11
2.2 İstatistiksel Yöntem.....	12
2.2.1 Haritanın istatistiksel bilgisi: harita işaretlerinin entropisi	12
2.2.2 Kenar belirleme (edge detection) yöntemi.....	13
2.2.2.1 Sobel yöntemi	14
2.2.2.2 Prewitt yöntemi	14
2.2.2.3 Roberts yöntemi	15
2.2.2.4 Laplacian of Gaussian (LoG) yöntemi	15
2.2.2.5 Zero-Cross yöntemi.....	15
2.2.2.6 Canny yöntemi	15
2.2.3 Eşik değeri (thresholding) yöntemi.....	16
2.2.3.1 Temel eşik değeri	16
2.2.3.2 Bant eşik değeri.....	16
2.2.3.3 Yüzde eşik değeri.....	16
2.2.4 Sınıflandırma.....	17
2.2.4.1 Kontrolsüz sınıflandırma.....	17
2.2.4.2 Kontrollü sınıflandırma.....	17
2.2.4.3 Destek vektör makineleri yöntemi ile sınıflandırma.....	17
2.2.4.4 Destek vektör seçme ve adaptasyon yöntemi (DVSA).....	21
2.3 Topolojik Yöntem	23
2.4 Metrik Yöntem	23
2.4.1 Voronoi diyagramları	24
2.4.2 Harita üzerindeki metrik bilgi	26
3. UYGULAMALAR	29
3.1 Kullanılan Veriler ve Çalışma Alanı Verisi Özellikleri	29

3.2 İstatistiksel Yöntem Uygulamaları	30
3.2.1 Eşit ölçekli ve eşit obje sayılı haritaların karşılaştırılması	30
3.2.2 Farklı obje sayılı haritaların karşılaştırılması	32
3.2.3 Kenar belirleme yöntemi uygulamaları	33
3.2.3.1 209x136 piksel uydu görüntüsü uygulaması	34
3.2.3.2 1 m çözünürlüklü Ikonos görüntüsü uygulaması	35
3.2.3.3 Orbview uydu görüntüsünde Canny algoritması ile kenar belirleme	36
3.2.4 Eşik değer yöntemi uygulamaları	38
3.2.4.1 Uydu görüntüsünde bina örneği - pankromatik görüntü	38
3.2.4.2 Uydu görüntüsünde bina örneği-multispektral görüntü	39
3.2.4.3 Piksellerin gri tonu aralık ölçütüne göre ayrıştırılması uygulaması	41
3.2.4.4 Uydu görüntüsünde bina örneği- pankromatik görüntü	41
3.2.4.5 Uydu görüntüsünde bina örneği-multispektral görüntü	44
3.2.5 Sınıflandırma uygulamaları	46
3.2.5.1 Kontrolsüz sınıflandırma uygulamaları	46
3.2.5.2 Kontrollü sınıflandırma uygulamaları	55
3.2.5.3 DVSA yöntemi	60
3.2.5.4 Erdas imagine objective yazılımı ile obje belirleme ve saydırma uygulamaları	65
3.3 Topolojik Yöntem Uygulamaları	88
3.3.1 Eşit bağlantı sayılı topolojik ağların karşılaştırılması	88
3.3.2 Farklı ölçekli haritaların karşılaştırılması	90
3.3.3 İstatistiksel ve topolojik yöntemin aynı örnek üzerinde karşılaştırılması	93
3.4 Metrik Yöntem Uygulamaları	95
3.4.1 Eşit ölçekli ve eşit obje sayılı haritaların karşılaştırılması	95
3.4.2 Farklı ölçekli haritaların karşılaştırılması	98
3.4.3 Aynı bölgeye ait haritanın farklı genelleştirme sonuçlarının karşılaştırılması	103
3.4.4 Farklı yöntemler ile genelleştirilen haritaların karşılaştırılması	117
3.4.4.1 Mesafe yöntemi	120
3.4.4.2 Açık yöntemi	122
3.4.4.3 Ağ temelli basitleştirme yöntemi	124
4. SONUÇ ve ÖNERİLER.....	129
KAYNAKLAR.....	135
EKLER.....	143
ÖZGEÇMİŞ.....	147

KISALTMALAR

CBS	: Coğrafi Bilgi Sistemi
DVM	: Destek Vektör Makineleri
DVSA	: Destek Vektör Seçme ve Adaptasyon
H(M)	: Metrik Entropi
H(X)	: İstatistiksel Entropi
ITaP	: Information Technology at Purdue
KNN	: K Nearest Neighbour Method
LARS	: Laboratory for Applications of Remote Sensing
LibSVM	: Linear Support Vector Machines
LVQ	: Learning Vector Quantization
MRDB	: Multiple Representational Databases
Matlab	: MATrix LABoratory
NASA	: National Aeronautics and Space Administration
RGB	: Red-Green-Blue
ROC	: Raster Object Creators
ROO	: Raster Object Operators
RPP	: Raster Pixel Processor
RVC	: Raster to Vector Conversation
SFP	: Single Feature Probability
SVM	: Support Vector Machines
SVSA	: Support Vector Selection and Adaptation
VCO	: Vector Cleanup Operators
VOO	: Vector Object Operators
VOP	: Vector Object Processor

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Uygulama sonuçları.....	31
Çizelge 3.2 : Uygulama sonuçları.....	33
Çizelge 3.3 : İstanbul Kemer Country uygulaması parametreleri.	76
Çizelge 3.4 : Purdue West Lafayette uygulaması parametreleri.....	79
Çizelge 3.5 : Purdue Üniversitesi öğrenci sitesi uygulaması parametreleri.	81
Çizelge 3.6 : Erdas Subroad2 uygulaması parametreleri.	83
Çizelge 3.7 : Purdue öğrenci siteleri uygulaması parametreleri.	84
Çizelge 3.8 : Erdas trees uygulaması parametreleri.....	86
Çizelge 3.9 : Purdue öğrenci siteleri uygulaması parametreleri.	87
Çizelge 3.10 : Uygulama sonuçları.....	89
Çizelge 3.11 : 1:5 000 ölçekli haritanın obje türüne göre bağlantı sayıları.	91
Çizelge 3.12 : 1:25 000 ölçekli haritanın obje türüne göre bağlantı sayıları.	92
Çizelge 3.13 : Uygulama sonuçları.....	92
Çizelge 3.14 : Şekil 3.2'deki haritanın obje türüne göre bağlantı sayıları.	93
Çizelge 3.15 : Şekil 3.2'deki haritanın obje türüne göre bağlantı sayıları.	94
Çizelge 3.16 : Uygulama sonuçları.....	95
Çizelge 3.17 : Uygulama sonuçları.....	98
Çizelge 3.18 : Farklı ölçekteki haritaların metrik bilgi miktarları.	102
Çizelge 3.19 : Farklı ölçekteki haritaların istatistiksel bilgi miktarları.	103
Çizelge 3.20 : Haritaların ortak hesap alanlarının belirlenmesi.	104
Çizelge 3.21 : Farklı kurumlarca genelleştirilen haritaların metrik bilgileri.	115
Çizelge 3.22 : Uygulama hesap detayları.	121
Çizelge 3.23 : Uygulama hesap detayları.	123
Çizelge 3.24 : Uygulama hesap detayları.	125
Çizelge 3.25 : Üç farklı yöntem ile genelleştirilen haritaların metrik bilgileri.	126

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Kartografik iletişim ağı (Kolácný, 1977).	8
Şekil 2.2 : Ağ topolojisi ve temel topoloji bileşenleri.	10
Şekil 2.3 : Poligon topolojisi ve temel topoloji bileşenleri (Bildirici, 2003).....	10
Şekil 2.4 : İki farklı sınıfa ait veri.....	19
Şekil 2.5 : Bir çözüm biçimi.	19
Şekil 2.6 : Başka bir çözüm biçimi.	19
Şekil 2.7 : Diğer çözümler.	20
Şekil 2.8 : A_1 ve A_2 hiper düzlemlerinin marjinleri.	20
Şekil 2.9 : Girdi uzayında obje sınıfları ve hiper düzlem.	21
Şekil 2.10 : Daha yüksek boyutlu öznitelik uzayında obje sınıfları ve hiperdüzlem.	21
Şekil 2.11 : Voronoi diyagramı.	25
Şekil 2.12 : Delaunay üçgenlemesi.....	25
Şekil 2.13 : Birinci harita.....	26
Şekil 2.14 : Birinci haritanın Voronoi diyagramları.	26
Şekil 2.15 : İkinci harita.....	26
Şekil 2.16 : İkinci haritanın Voronoi diyagramları.....	26
Şekil 2.17 : Dokuz bölge ile mozaiklendirilmiş harita örnekleri.	27
Şekil 3.1 : Eşit sayıda, fakat farklı dağılımda objeler içeren iki harita.....	30
Şekil 3.2 : Birinci örnek.....	32
Şekil 3.3 : İkinci örnek.....	32
Şekil 3.4 : Sekiz binalı uydu görüntüsü örneği.....	34
Şekil 3.5 : Altı farklı yöntem ile çalışılan görüntüdeki kenar çizgileri.	34
Şekil 3.6 : Orijinal uydu görüntüsü.	35
Şekil 3.7 : Altı farklı algoritma ile elde edilen kenar çizgileri.	36
Şekil 3.8 : Yükseklikleri renklerle gösterilmiş Orbview uydu görüntüsü.	37
Şekil 3.9 : Belirlenebilen kenar çizgileri.	37
Şekil 3.10 : Uygulamada kullanılan pankromatik uydu görüntüsü.	38
Şekil 3.11 : Gri tonu eşik değerlerine göre elde edilen sonuçlar.	39
Şekil 3.12 : Sekiz bina bulunduran orijinal multispektral uydu görüntüsü.	40
Şekil 3.13 : Gri tonu/beyaz oranına göre elde edilen sonuçlar.	41
Şekil 3.14 : Gri tonu aralığına göre elde edilen sonuçlar.	44
Şekil 3.15 : Gri tonu aralığına göre elde edilen sonuçlar.	45
Şekil 3.16 : 38 bina içeren düzenli bir alan örneği.	47
Şekil 3.17 : K-means algoritması uygulama sonuçları.	49
Şekil 3.18 : 34 bina içeren düzenli bir alan örneği.	50
Şekil 3.19 : K-means algoritması uygulama sonuçları.	50
Şekil 3.20 : Ikonos 1 m çözünürlüklü orijinal uydu görüntüsü.	51
Şekil 3.21 : K-means algoritması uygulama sonuçları.	52
Şekil 3.22 : Ikonos 4 m çözünürlüklü uydu görüntüsü.	52
Şekil 3.23 : K-means algoritması uygulama sonuçları.	53

Şekil 3.24 : Program tarafından bina olarak sayılan objeler.	53
Şekil 3.25 : İkonos 4 m çözünürlüklü orijinal uydu görüntüsü.	54
Şekil 3.26 : K-means algoritması uygulama sonuçları.	54
Şekil 3.27 : En başarılı sınıf ve bina olarak sayılan objeler.	55
Şekil 3.28 : Washington DC Mall Hydice görüntüsü ve özellikleri.	56
Şekil 3.29 : Sınıf oluşturma ve eğitim verisi hazırlama işlemleri ve sınıflandırılmış Washington DC Mall görüntüsü.	57
Şekil 3.30 : MultiSpec ekranında uygulama görüntüsü ve özellikleri.	58
Şekil 3.31 : Kontrolsüz sınıflandırma uygulaması sonuç görüntüsü.	59
Şekil 3.32 : Kontrollü sınıflandırma uygulaması sonuç görüntüsü.	59
Şekil 3.33 : Questdlg fonksiyonu ve manuel sınıf sayısı seçimi penceresi.	62
Şekil 3.34 : Manuel olarak üç sınıf seçme işlemi.	62
Şekil 3.35 : Piksellerin lokal koordinatlar ile grafik üzerinde gösterimi.	63
Şekil 3.36 : B matrisindeki koordinatlarla çizilen Voronoi diyagramları ve parametreler.	63
Şekil 3.37 : Manuel sınıflandırma işlemi sonrası RGB matrisi dosyası.	65
Şekil 3.38 : Orijinal uydu görüntüsü.	66
Şekil 3.39 : Uydu görüntüsünde manuel olarak sayılan 62 adet bina.	67
Şekil 3.40 : Raster piksel işlemci parametreleri ve kullanılan değerler.	68
Şekil 3.41 : Raster obje yaratıcıları parametreleri ve kullanılan değerler.	68
Şekil 3.42 : Olasılık parametresi ve kullanılan değerler.	69
Şekil 3.43 : Boyut filtresi parametresi ve kullanılan değerler.	69
Şekil 3.44 : Kümeleme parametresi ve kullanılan değerler.	70
Şekil 3.45 : Raster vektör dönüşümü parametreleri ve kullanılan değerler.	70
Şekil 3.46 : Genelleştirme parametresi ve kullanılan değerler.	71
Şekil 3.47 : Geometri için kullanılan örnek alanlar.	71
Şekil 3.48 : Geometri: alan parametresi için kullanılan değerler.	72
Şekil 3.49 : Geometri: 2. eksen/1. eksen için kullanılan değerler.	72
Şekil 3.50 : Geometri: dörtgensellik için kullanılan değerler.	73
Şekil 3.51 : Olasılık filtresi ve kullanılan değerler.	73
Şekil 3.52 : Ada filtresi ve kullanılan değerler.	74
Şekil 3.53 : Yumuşatma ve kullanılan değerler.	74
Şekil 3.54 : Dikgenlik ve kullanılan değerler.	75
Şekil 3.55 : Uygulama sonucu sayılan 59 adet bina ve 2 yol objesi.	75
Şekil 3.56 : İstanbul Kemer Country yerleşim alanı uydu görüntüsü.	76
Şekil 3.57 : Uygulama sonucu belirlenen ve sayılan binalar.	77
Şekil 3.58 : Purdue West Lafayette merkez kampüsü uydu görüntüsü.	78
Şekil 3.59 : Uygulama sonucu belirlenen ve sayılan binalar.	79
Şekil 3.60 : İkonos 1 m çözünürlüklü Purdue öğrenci sitesi görüntüsü.	80
Şekil 3.61 : Uygulama sonucu belirlenen ve sayılan binalar.	81
Şekil 3.62 : Yol uygulamasında kullanılan orijinal uydu görüntüsü.	83
Şekil 3.63 : Uygulanan parametreler neticesinde elde edilen yol ağı.	84
Şekil 3.64 : Yazılım tarafından belirlenen Purdue öğrenci siteleri yol ağı.	85
Şekil 3.65 : Uygulamada kullanılan uydu görüntüsü.	85
Şekil 3.66 : Uygulama sonucu ve kullanılan parametreler.	86
Şekil 3.67 : Uygulama sonucu ve kullanılan parametreler.	88
Şekil 3.68 : #1 yol ağı.	89
Şekil 3.69 : #2 yol ağı.	89
Şekil 3.70 : 1:5 000 ölçekli harita.	90
Şekil 3.71 : 1:25 000 ölçekli harita.	90

Şekil 3.72 : 1:5 000 ölçekli haritanın bağlantı noktalarının sayılması.	91
Şekil 3.73 : 1: 25 000 ölçekli haritanın düğüm noktalarının sayılması.	92
Şekil 3.74 : Bina, yol ve ada objelerinin düğüm noktalarının sayılması.	93
Şekil 3.75 : Bina, yol ve parsel objelerinin düğüm noktalarının sayılması.	94
Şekil 3.76 : Farklı dağılımda objeler içeren haritaların Voronoi diyagramları.	96
Şekil 3.77 : Voronoi bölgelerinin sayısallaştırılması.	96
Şekil 3.78 : Voronoi bölgelerinin sayısallaştırılması.	97
Şekil 3.79 : 1:25 000 ölçekli harita.	99
Şekil 3.80 : Haritanın Voronoi diyagramı.	99
Şekil 3.81 : 1:50 000 ölçekli harita.	99
Şekil 3.82 : Haritanın Voronoi diyagramı.	99
Şekil 3.83 : 1:100 000 ölçekli harita.	99
Şekil 3.84 : Haritanın Voronoi diyagramı.	99
Şekil 3.85 : 1:250 000 ölçekli harita.	99
Şekil 3.86 : Haritanın Voronoi diyagramı.	99
Şekil 3.87 : 1:25 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması. ...	100
Şekil 3.88 : 1:50 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması. ...	101
Şekil 3.89 : 1: 100 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması.	101
Şekil 3.90 : 1 : 250 000 ölçekli harita.	102
Şekil 3.91 : 1 : 10 000 ölçekli topoğrafik harita.	105
Şekil 3.92 : Farklı kurumlar tarafından genelleştirilen haritalar.	106
Şekil 3.93 : 1 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	107
Şekil 3.94 : 2 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	108
Şekil 3.95 : 3 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	109
Şekil 3.96 : 4 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	110
Şekil 3.97 : 5 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	111
Şekil 3.98 : 6 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	112
Şekil 3.99 : 7 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	113
Şekil 3.100 : 8 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	114
Şekil 3.101 : 1 : 25 000 ölçekli orijinal harita.	118
Şekil 3.102 : (a) Mesafe yöntemi, (b) Açı yöntemi, (c) Ağ temelli basitleştirme yöntemi ile genelleştirilen 1: 100 000 ölçekli haritalar.	118
Şekil 3.103 : Mesafe yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	120
Şekil 3.104 : Açı yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	122
Şekil 3.105 : Ağ temelli basitleştirme yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.	124

ÇOK ÖLÇEKLİ KARTOGRAFİK GÖSTERİMLERDE MEKANSAL BİLGİNİN NİCELİK ANALİZİ

ÖZET

Bu çalışmada, haritaların, içerdikleri mekansal bilgi miktarının nicel bir ölçüt kullanılarak belirlenmesine yönelik araştırmalar ve uygulamalar yapılmıştır. Mekansal bilgi miktarının ölçülmesi amacıyla önerilen yöntemlerden istatistiksel, topolojik ve metrik yöntemlerin geçerliliği araştırılmıştır. Bu yöntemlerin temelini oluşturan Entropi ve Voronoi diyagramları kavramlarına değinilmiştir.

Söz konusu yöntemler için çok sayıda uygulama yapılmış, sonuçlarına değinilmiştir. Çalışmada ilk araştırılan yöntem olan istatistiksel yöntemin hesap algoritmasını oluşturan entropi teoreminde temel bileşen obje sayılarıdır. Bu nedenle çalışma verisi olarak seçilen analog haritalar ve uydu görüntü haritaları üzerinde obje sayılarının gerçekçi olarak belirlenmesine yönelik çalışmalar yapılmıştır. Bu çalışmalar kapsamında ilk olarak Matlab yazılımı görüntü işleme modülünde kenar belirleme (edge detection) yöntemleri araştırılmış ve uygulamalarla test edilmiştir. Çalışmada kenar belirleme yöntemlerinden Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny yöntemleri kısaca tanımlanmış ve uygulamalarda kullanılarak sonuçlarına yer verilmiştir.

Kenar belirleme yöntemlerinden sonra eşik değer (thresholding) yöntemleri araştırılmış ve uygulamaları gerçekleştirilmiştir. Eşik değer yönteminin uygulamaları için Matlab yazılımının görüntü işleme modülü kullanılmıştır. Söz konusu uygulamalarda temel, bant ve yüzde eşik değer yöntemleri kullanılmış ve sonuçlarına yer verilmiştir.

Kenar belirleme ve eşik değer yöntemlerinin test edilmesi ve sonuçlarının elde edilmesinden sonra sınıflandırma yöntemleri araştırılmıştır. Bu bağlamda kontrollü ve kontrolsüz sınıflandırma yöntemleri ile farklı görüntüler üzerinde uygulamalar gerçekleştirilmiştir. Kontrolsüz sınıflandırma yönteminde, yazılım tarafından görüntüde bina olarak algılanan objelere daha net ölçütler getiren bir algoritma olan K-ortalama değer algoritmaları ile çalışılmıştır.

Kontrollü sınıflandırma uygulamalarında ise farklı ölçütler kullanarak daha başarılı sonuçlarla bina saydırabilmek için eğitim verileri kullanımına olanak sağlayan yazılımlar ile çalışılmıştır. Yazılımlardan ilki MultiSpec yazılımıdır. MultiSpec yazılımından sonra son yıllarda obje tanıma uygulamalarında daha yaygın olarak kullanılmaya başlanan, eğitici bir sınıflandırma algoritması olan destek vektör makineleri (DVM)-support vector machines (SVM) yöntemi ve lineer olmayan verinin sınıflandırılması için geliştirilen bir yöntem olan destek vektör seçme ve adaptasyon (DVSA) yöntemi araştırılmıştır. Bu amaçla DVSA algoritmasına eğitim ve test verisi hazırlayan, DVSA yöntemi ile sınıflandırılan görüntüdeki piksellerin koordinatlarını merkez alarak Voronoi diyagramları çizen bir program derlenmiş ve sınıflandırma uygulamalarında kullanılmıştır.

MultiSpec ve DVSA alıřmalarından sonra Erdas yazılımının imagine objective modl kullanılmıřtır. Erdas imagine objective modl ile farklı uydulara ait yksek znrlkl grntler zerinde farklı ltler kullanarak bina, yol ve aa objelerinin belirlenmesi ve saydırılması uygulamaları yapılmıřtır.

alıřmada bir diğerk mekansal bilgi lme yntemi olan topolojik yntem zerine arařtırmalar ve farklı haritalar zerinde uygulamalar ve karřılařtırmalar yapılmıřtır.

Topolojik yntemden sonra haritada yer alan harita iřaretlerinin kapladığı alan ve etrafındaki bořluk miktarları ile ilintili yeni bir kavram olan metrik yntem arařtırılmıř ve farklı rnek haritalar zerinde testler ve karřılařtırmalar yapılmıřtır.

alıřmanın sonucu; farklı kartograflar veya otomatik genelleřtirme yazılımları ile retilen farklı genelleřtirme zmleri arasında metrik yntem ile bir karřılařtırma yapılabileceğidir. Gnmzde bařka kartografik genelleřtirme değerkendirme algoritmalarının geliřtirilmesi gerektiği noktada, metrik yntem, bu eksikliğı gidermek yolunda yapılan bir alıřma olarak da değerkendirilmelidir.

QUANTITATIVE ANALYSES OF SPATIAL INFORMATION IN MULTI-SCALE CARTOGRAPHIC REPRESENTATIONS

SUMMARY

In this study, quantitative measures for spatial information of maps were analyzed with some experimental evaluations by using quantitative criterion. Feasibility of statistical, topological, and metric methods that are used in order to measure quantity of spatial information, were investigated. Applications were carried out for every method and the results were mentioned. Entropy and Voronoi diagrams, which constitute the basis of these methods, were explained.

Numerous applications were used to evaluate these methods and the results were mentioned. Number of the objects is the basis component for Entropy theorem which forms the computation algorithm of statistical method that was investigated firstly in the PhD dissertation. The importance of number of the objects caused doing some research in order to evaluate analog and remote sensing image maps for counting the object numbers correctly in this study. Within this context, edge detection method was used in Matlab software and tested with some applications. Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross and Canny methods were mentioned and tested for edge detection.

Following the edge detection processes, “thresholding methods” were investigated and their applications were taken place. Image processing module of Matlab software was used for the thresholding applications. basic, band and percentile (P-tile) thresholding methods were used in these applications and the results were mentioned in this work.

Research for the classification methods was carried out following edge detection and thresholding processes. At this part of the study, several applications were employed on different images by using supervised and unsupervised classification methods. In unsupervised classification. K-means algorithm was chosen over other alternatives because the algorithm brings better noticeability criteria in detecting the objects on the image.

Within the supervised classification applications, a number of software tools, which are capable of getting better application results on object recognition, were used. The first software was MultiSpec. The second software tool that was used employed support vector machines (SVM) algorithm which has gained broad usage within the study area in recent years. In addition, the tool also employed support vector selection and adaptation (SVSA) method which provides functionality to classify the non-linear data. To be able to use those methods within the dissertation, a program code was formed in Matlab that prepares training and test data to SVSA algorithm and draws Voronoi diagrams assuming as the center (origin) of the pixel's coordinates on the classified images. The program code was also used within the classification processes.

Following the MultiSpec and DVSA-SVSA processes, imagine objective module of Erdas software was used to recognize and count the buildings, roads and trees by using different criteria on the high-resolution images of different satellites.

Topologic method, another spatial information measurement method, was also studied within the applications and made comparisons by using different maps.

Metric method, a similar method to Entropy theorem, was also studied, applied, and made comparisons through using different sample maps. The method relates the area of map objects and the amount of the space around them.

As a result of the study, it is found that the metric method can be used to compare different generalized maps which were produced by different cartographers or different automatic generalization software. More evaluation algorithms must be developed for cartographic generalization contemporary, within this context, the study must be thought for making up this deficiency.

1. GİRİŞ

Harita, haritası yapılan bölge ile ilgili, belirli bir konudaki mekansal ilişkilerin görselleştirilmesi ve nesnel gerçekliğin grafik sunumu için belirli kartografik kurallar çerçevesinde topoğrafik veya tematik olarak çeşitli ortamlarda üretilmiş, etkili bir iletişim aracıdır.

Haritalarda mekansal bilgi kartografik işaretlerle ifade edilir. Kartograflar, haritalarını tasarımlarken etkili bir iletişim sağlayabilmek için kullanıcılara optimum bilgiyi sunan, “iyi” tasarımlanmış bir harita üretmek gayretindedirler. Harita tasarımı; coğrafi bilginin amaç ve ölçeğe bağlı olarak özetleme, sınıflandırma, genelleştirme, işaretleştirme ve baskı işlemlerini de içeren modelleme, estetik ve otomasyon işlemlerini içeren bir süreçtir. Büyük usta Max Eckert; “iyi” bir harita, doğru, eksiksiz, okunabilir (gözün ayırma gücüne uygun), okunaklı (açık ve anlaşılır) ve güzel olmalıdır” der.

Geometrik anlamda ölçek, harita üzerindeki uzunluğun yeryüzünde karşılık geldiği uzunluğa oranı olarak tanımlanır. Ancak ölçek, haritada yer alan objelerin gösterimi ve obje yoğunluğu üzerinde doğrudan etkili bir parametredir. Harita tasarımı sürecinde amaç, ölçek ve yeryüzü gerçekliğinin özetlenmesinin (abstraction) derecesine bağlı olarak sunulacak objelerin de seçiminin yapılması gerekmektedir (Uluğtekin ve Doğru, 2005).

Harita kullanıcıları bir harita ölçeği telaffuz edildiğinde, bu haritanın kapladığı alan ve içerdiği nesnel bilgi miktarı bakımından zihninde bir mekan canlandırabilir. Analog haritalarda ölçek, tasviri yapılacak nesnel bilgi miktarına kendiliğinden bir kısıtlama getirir. Harita üzerindeki kartografik işaretlerin ve objelerin yoğunluğu bir anlamda ölçekle sınırlandırılır. Bir haritada obje yoğunluğu arttıkça haritanın görsel etkisi azalmakta, kullanıcının haritayı anlaması güçleşmektedir. Ancak, haritaların sayısal üretiminde, özetleme ve genelleştirme işlemlerinde obje tür ve sayılarının belirlenmesi için ölçek dışında başka matematik ölçütler kullanılmamaktadır.

Ortak bir mekansal veritabanından elde edilen veriler ile üretilen farklı ölçek, amaç ve veri çözünürlüğündeki gösterimler çok ölçekli kartografik gösterimler olarak isimlendirilir. Çok ölçekli kartografik gösterimlerde mekansal bilgi miktarının nicel olarak ifade edilmesinde entropi kavramı bir ölçüt olarak kullanılabilir. Entropi kısaca evrendeki düzensizlik eğilimine verilen, bir sistemin düzensizliğinin ölçüsü olarak kullanılan bir kavramdır (Shannon, 1948).

Çalışmanın amacı, haritaları, içerdikleri mekansal bilgi miktarı bakımından nicel bir ölçüt kullanarak karakterize edecek araçlar sunmaktır.

Böylesi bir nicel ölçüt literatürde var olan farklı genelleştirme algoritmalarının uygulanması neticesinde ortaya çıkan haritaların karşılaştırılması, böylece genelleştirme algoritmasının başarısının ortaya konulması açısından da önemli bir bileşendir. Söz konusu nicel ölçütün, aynı ölçekteki iki haritanın içerdikleri bilgi miktarı açısından karşılaştırılması, türetme haritanın tasarımında genelleştirmenin bilgi kalitesine ilişkin yeni bir kavram yaratmak için kullanılması önerilir.

Bölüm 2’de haritanın mekansal bilgisinin mevcut nicel ölçme yöntemleri ile değerlendirilmesi hakkında bilgi verilecektir. Bu kapsamda istatistiksel, topolojik ve metrik yöntem başlıkları altında sunulacak üç yöntem denenmiştir.

İstatistiksel yöntemde temel bileşen, haritada yer alan objelerin tür sayıları ve bu türlere ait olan obje sayılarıdır. Böylesi bir değerlendirmede obje sayılarının gerçekçi olarak belirlenmesi son derece önemlidir. İstatistiksel yöntemin değerlendirilmesi konusunda analog haritalar ve uydu görüntü haritaları üzerinde çalışılmıştır. Bu haritaların karşılaştırılması amacıyla obje türleri ve sayıları manuel olarak sayılmış ve yöntemde kullanılmıştır. Sonrasında ise günümüzde harita üretimi için veri kaynağı olarak kullanılan hava fotoğrafları ve uydu görüntüleri üzerinde obje türlerinin ve obje sayılarının otomatik olarak belirlenmesine yönelik çalışmalar gerçekleştirilmiştir.

Bu çalışmalar kapsamında ilk olarak raster görüntülerde yer alan objelerin kenarlarının belirlenerek kapalı alan olarak vektöre çevrilmesi ve sayılması amacıyla kenar belirleme yönteminde (edge detection) kullanılan Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny algoritmaları araştırılmış ve teorilerine yer verilmiştir.

Kenar belirleme yönteminden sonra spektral yansıma değerleri kullanılarak görüntüler üzerinde objelerin belirlenmesi amacıyla eşik değer yöntemi (thresholding) araştırılmıştır. Bu bağlamda temel, bant ve yüzde (p-tile) eşik değer yöntemlerine değinilmiştir. Obje belirleme çalışmalarında son olarak sınıflandırma yöntemleri araştırılmış, kontrollü ve kontrolsüz sınıflandırma tekniklerine değinilmiştir. Kontrollü sınıflandırma; yapay öğrenme (machine learning) yöntemi olan destek vektör seçme ve adaptasyon algoritması çalışma konularına dahil edilmiştir.

Haritadaki mekansal bilginin ölçülmesi konusundaki yöntemlerden diğeri olan ve düğüm noktalarının komşuluk sayılarını esas alarak çalışan topolojik yöntem konusunda bilgiler verilmiştir.

Metrik yöntem, objelerin harita üzerinde kapladığı alanları ve mekansal dağılımlarını esas alan ve bu amaçla Voronoi diyagramlarını kullanan bir yöntemdir. Bu bağlamda Delaunay üçgenleri ve Voronoi dörtgenleri konuları ele alınmıştır.

Bölüm 3’de yer alan uygulamalar başlığı altında tez çalışmasında kullanılan verilerin ve çalışma alanı görüntülerinin özellikleri hakkında bilgi verildikten sonra haritalardaki mekansal bilgi miktarının ölçülmesi kapsamında gerçekleştirilen uygulamalara yer verilmiştir. Eşit ölçekli ve eşit obje sayılı haritaların istatistiksel bilgi miktarları karşılaştırılmış, farklı kartograflar ve farklı yazılımlar tarafından genelleştirilmiş eşit ölçekli haritaların istatistiksel bilgi miktarlarındaki değişim incelenmiştir. Sonrasında istatistiksel bilgi miktarının hesabı için entropi teoreminin gerekli parametrelerden olan obje türü sayısı ve bu obje türlerine ait objelerin sayılarının otomatik olarak belirlenebilmesi için analog haritalar ve uydu görüntüleri üzerinde çalışmalar yapılmıştır. Söz konusu çalışmalarda Matlab yazılımının görüntü işleme modülü kullanılmıştır. Kenar belirleme (edge detection) yönteminde Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny algoritmaları ile farklı görüntüler kullanılarak uygulamalar gerçekleştirilmiş ve sonuçları karşılaştırılmıştır. Devamında ise farklı görüntüler üzerinde eşik değer (thresholding) yöntemi ile obje belirleme uygulamaları gerçekleştirilmiş, sonuçlarına yer verilmiştir.

Eşik değer yöntemi uygulamalarında Matlab yazılımında temel eşik değeri, bant eşik değeri ve yüzde (p-tile) eşik değeri yöntemlerine uygun komutlar kullanılarak,

deneyisel spektral yansıma değerleri ile uygulamalar yapılmış, sonuçlarına yer verilmiştir.

Obje belirleme konusunda son olarak sınıflandırma yöntemleri ile uygulamalar gerçekleştirilmiştir.

Sınıflandırma yönteminde kontrollü ve kontrolsüz sınıflandırma teknikleri ayrı başlıklar altında ele alınmıştır. Kontrolsüz sınıflandırma tekniğinde Matlab yazılımı kullanılarak K-ortalama değer (K-Means) algoritması ile farklı mekansal çözünürlüklü Ikonos uydu görüntüleri ile uygulamalar gerçekleştirilmiş, farklı parametre değerleri ile elde edilen obje sayısı sonuçlarına yer verilmiştir. Kontrollü sınıflandırma tekniği ile objelerin sınıflandırılması uygulamalarında ise Purdue Üniversitesi Uzaktan Algılama Uygulamaları Laboratuvarı, Purdue Bilgi Teknolojileri ve NASA'nın desteği ile geliştirilen MultiSpec yazılımı ile sınıflandırma uygulamaları yapılarak sonuçlarına yer verilmiştir. Ayrıca, Matlab destek vektör makineleri-DVM (support vector machines-SVM) ve yapay öğrenme (machine learning) yöntemi olan destek vektör seçme ve adaptasyon-DVSA (support vector selection and adaptation-SVSA) algoritması ile uygulamalar gerçekleştirilmiştir. MultiSpec ve Matlab yazılımları haricinde Erdas yazılımının obje belirleme modülü olan objective yazılımı da kullanılmıştır. Erdas imagine objective yazılımı kullanılarak değişik görüntü parametreleri ve yazılımda mevcut fonksiyonlar kullanılarak yüksek çözünürlüklü uydu görüntüleri ile uygulamalar gerçekleştirilmiş, elde edilen sonuçlara yer verilmiştir.

Kontrollü sınıflandırma konusunda, yine uydu görüntüleri üzerinde obje sayılmasına ilişkin Matlab algoritmaları ile kullanıcının manuel olarak sınıflandırma yapabileceği ve sınıflandırma neticesinde obje merkezlerini temel alarak Voronoi diyagramları çizen ve metrik bilgi miktarının ölçülmesinde kullanılan Voronoi diyagramlarının alanlarını hesaplayan ve tez kapsamında derlenen program açıklanmıştır.

Topolojik bilgi miktarının ölçülmesi konusunda eşit bağlantı sayılı topolojik ağlar karşılaştırılmış, 1:5 000 ölçekten 1:25 000 ölçeğe genelleştirilen haritaların topolojik bilgi miktarlarındaki değişim incelenmiştir. İstatistiksel ve topolojik bilgi miktarlarındaki değişim aynı haritalar kullanılarak test edilmiş ve karşılaştırılmıştır.

Metrik yöntem konusunda gerçekleştirilen uygulamalar kapsamında, eşit sayıda obje içeren haritaların metrik bilgi miktarlarındaki değişim karşılaştırılmış, aynı bölgenin

gösterimini yapan ve 1:25 000 ölçekten 1:250 000 ölçeğe genelleştirilen dört haritanın metrik yöntem ile ölçülen bilgi miktarları arasındaki değişim incelenmiş ve sonuçlar istatistiksel ve topolojik yöntemlerle elde edilen sonuçlarla karşılaştırılmıştır. Bu konuda son olarak farklı kurumlar tarafından genelleştirme ile üretilmiş aynı bölgenin sekiz farklı haritası kullanılarak metrik yöntemin testi yapılmış ve sonuçlarına yer verilmiştir.

Bölüm 4’de çalışmanın genel değerlendirilmesi yapılmaktadır. Ayrıca, metrik bilgi miktarı ile farklı ölçeklerde genelleştirmeler sonucu elde edilmiş haritalardaki obje sayıları arasında ilişki irdelenmiş ve elde edilen sonuçlar klasik Töpfer yöntemi ile üretilen sonuçlarla karşılaştırılmıştır.

2. HARİTANIN MEKANSAL BİLGİSİNİN MEVCUT NİCEL ÖLÇME YÖNTEMLERİ ile DEĞERLENDİRİLMESİ


Harita bilgisinin nicel olarak ölçülmesi üzerine yapılan çalışmalardan bir tanesi istatistiksel bilgi, diğeri ise topolojik bilgi üzerinedir. Yeni bilgi ölçmelerinden söz edebilmek için, sözkonusu ölçmelerin avantajlarını ve eksik yanlarını ortaya çıkarmak için literatürde mevcut çalışmaların üzerine bir değerlendirme yapmak ve uygulamalar ile destekleyerek sonuçların irdelenmesi amaçlanmaktadır.

2.1 Temel Kavramlar

Haritalarda kullanılan işaret ve kurallar beraberce “harita dili” olarak isimlendirilir. Haritalarda kullanılan işaretler gerçek mekanda, yeryüzünde bulunan ve haritaya konu olan objeleri harita üzerinde temsil ederler. Harita işaretleri kartografik iletişim ağında bilgi iletimini sağlayan, bilgi taşıyan elemanlardır (Uçar, 1992). Dolayısı ile söz konusu harita işaretlerine birtakım bilgiler yüklenmiştir. Objeler gerçek dünyada mevcut olan, bir mekan kaplayan varlıklardır. Bu varlığın işaretler aracılığı ile kartografik gösterimi kartografik obje olarak adlandırılır.

2.1.1 Kartografik iletişim ağı

Klasik anlamda kartografik iletişim ağı, kartograf ile harita kullanıcıları arasında gerçekleşen iletişimi tanımlayan ağıdır. Bu ağın iletişim aracı haritadır. Kartografik iletişim ağı şekil 2.1’de görüldüğü gibi şematik hale getirilebilir. Kartografik iletişimde hedef, yeryüzü gerçekliğinin kullanıcıya en “iyi” biçimde aktarılmasıdır. Bu nedenle günümüzde gelişen teknolojinin kullanımı ile harita üreten ve kullanan arasındaki “ortak belleğin” geliştirilmesi çalışmaları sürmektedir.



Şekil 2.1 : Kartografik iletişim ağı (Kolácný, 1977).

2.1.2 Genelleştirme

Genelleştirme Kartografyanın ana konularından biridir. Klasik anlamda kartografik genelleştirme, amaç ve ölçeğe bağlı olarak türetme haritaların elde edilmesi sırasında ortaya çıkan bilgi karmaşıklığının azaltılması, türetme ölçek için gereksiz bilgilerin elenmesi, harita objeleri arasındaki belirgin mantıksal ilişkilerin ve estetik kalitenin korunması işlemlerinin bileşkesi olarak tanımlanabilir. Genelleştirmede temel amaç grafik netliği çok iyi olan haritalar üreterek haritanın görünümünün ve aktarılmak istenen bilginin kolayca anlaşılmasını sağlamaktır (Bildirici ve Uçar, 1997). Genelleştirme, tamamlayıcı terimi olan soyutlama ile yakından ilgilidir. Soyutlama (abstraction), genel ve önemli bileşenleri korumak amacıyla somut gerçeklikten özel ya da gereksiz ayrıntıların elenmesi anlamına gelir (Brassel ve Weibel, 2002). Genelleştirme işleminde, haritadaki detayların hedeflenen harita için taşıdıkları önem ve yaptıkları katkıya göre özetlenmesi ve basitleştirilmesi işlemleri gerçekleştirilir (Bundy ve diğ., 1995; Joao, 1995). Genelleştirme neticesinde, gerçek bir olgu kullanıcının ihtiyaçları doğrultusunda yeterli okunabilirlik düzeyinde temsil edilir. Günümüzde, mekansal işlemlerin hangi ölçekte veya ölçek aralığında oluştuğunun bilinmesine olan ihtiyaç genelleştirmeyi ilerleten, geliştiren faktördür (Müller, 1990).

2.1.3 Çok ölçekli kartografik gösterimler

Haritalar fiziksel yeryüzünün belirli bir amaca uygun biçimde özetlenmiş gösterimleridir. Belirli bir amaca yönelik hazırlanan haritaların ölçekleri ve tasarımları birbirinden farklıdır. Bu farklılıkların; gösterime konu olan verilerin belirlenmesi, toplanması, tanımlanması, düzenlenmesi, saklanması ve sunulması aşamalarında uygulanacak kurallar ve gerçekleştirilecek işlemlere bağlı olarak ortaya çıktığı belirlenmiştir (The MurMur Consortium, 2000).

Özellikle son yıllarda mekansal veri tabanlarını çok amaçlı ve verimli kullanma isteği, bugün veri tabanı güdümlü kartografya (database-driven cartography) ve çoklu gösterimli veri tabanı kavramını (ÇGVT - MRDB-Multiple Representational Databases) doğurmuştur. Çoklu gösterimli veri tabanı, çoklu çözünürlüklü veri tabanı (multiple resolution database) olarak da isimlendirilmektedir (Hampe ve Sester, 2002; Anders ve Bobrich, 2004). Çoklu gösterimli veri tabanı, aynı gerçek dünya olgularını farklı doğruluk, duyarlık ve çözünürlükte tutmak için kullanılan mekansal veri tabanı olarak tanımlanır (Başaraner, 2005; Devogele ve diğ., 1996; Weibel ve Dutton, 1999). Böylelikle, çeşitli çözünürlüklerde/ölçeklerde ve/veya çeşitli konularda veri tabanları ve haritaların tek bir temel veri tabanından türetilmesi ve güncelleştirilmesi hedeflenmektedir. (Selçuk ve diğ., 2006). Bu yaklaşımda, uygulamaya yönelik farklı amaç ve ölçekteki ürünlerin tasarımında kullanılacak veritabanlarının, ortak ve temel bir veritabanından otomatik genelleştirme ile türetilmesi amaçlanmaktadır (Kilpelainen, 1997; Ruas, 2002; Dunkars, 2004; Sarjakoski, 2007, Doğru, 2009). ÇGVT'nin ortaya çıkış nedenleri arasında, çok çözünürlüklü/ölçekli analiz yapılması ve güncelleştirmelerin diğer ölçek düzeylerine otomatik yayılması sayılabilir (Hampe ve diğ., 2003; Bedard ve Bernier, 2002; Hampe ve Sester, 2002).

Çok ölçekli kartografik gösterimler tek bir mekansal veritabanından elde edilen veriler ile hazırlanan farklı ölçek, amaç ve veri çözünürlüğündeki gösterimleridir (Timpf ve Devogele, 1997).


2.1.4 Topoloji kavramı

Topoloji, mekansal veriler için, geometrik olarak tanımlanabilen koordinat, uzunluk, alan, mesafe gibi metrik ilişkilere ilaveten, komşuluk, çakışıklık, içermeye, kesişme, paylaşma, birleşme gibi mantıksal ilişkilerin de tanımlanabildiği bir yapı ya da


mantıksal ilişkilerin tanımlanmasına yarayan bir yol, bir yöntemdir (Bank, 1997). Kartografya’da topoloji konusu farklı çalışmalarda detaylı olarak ele alınmıştır (Pavia, 1998; Hardy ve diğ., 2003; Doğru, 2009).

Temel topoloji bileşenleri, merkez (centroid), düğüm noktası (node) ve bağlantı (link) olmak üzere üç tanedir. Topoloji türleri ile ilgili objelere göre üçe ayrılır:

- Düğüm noktalarından oluşan “nokta topolojisi”,
- Düğüm noktaları ve bağlantılardan oluşan “ağ topolojisi” (şekil 2.2),
- Düğüm noktaları, merkezler ve bağlantı çizgisi objelerinden oluşan “poligon topolojisi” (şekil 2.3).



Şekil 2.2 : Ağ topolojisi ve temel topoloji bileşenleri.



Şekil 2.3 : Poligon topolojisi ve temel topoloji bileşenleri (Bildirici, 2003).

Bağlantı çizgileri, bir düğüm noktasında başlayıp bir başka düğüm noktasında sona eren topoloji bileşenidir. Merkez noktaları, kapalı alanın (poligonun) içinde herhangi bir yerde bulunan topoloji bileşenidir. Merkez noktalarının şeklin ağırlık merkezi gibi özel bir noktada olmaları gerekmez. Temel topoloji bileşenlerinden düğüm noktalarına bir ya da ikiden çok bağlantı objesi bağlanmalıdır. Bir düğüm noktasından yalnızca iki bağlantı elemanı çıkıyorsa o düğüm noktası topolojik olarak anlamlı değildir. Bu tür düğüm noktaları yalancı düğüm noktası (pseudo node) olarak adlandırılır (Bildirici, 2003).

2.1.5 Entropi kavramı

Haritanın içerdği mekansal bilginin ölçülmesi çalışmaları 1948 yılına kadar uzanmaktadır. Harita bilgisinin nicel olarak değerlendirilmesi bağlamında ilk önerilen yöntem entropi yöntemidir.

Entropi kavramı ilk olarak termodinamiğin ikinci yasası şeklinde ifade edilmiştir. Entropi kısaca evrendeki düzensizlik eğilimine verilen, bir sistemin düzensizliğinin ölçüsü olarak kullanılan bir kavramdır (Shannon, 1948).

Haritanın içerdği bilgi miktarının nicel olarak ölçülmesi konusunda entropi kavramını ilk öneren kişi Shannon (1948)'dur. Daha sonra haritanın bilgi miktarının nicel olarak ölçülmesi çalışmaları “bilgi teorisi” olarak adlandırılmış ve iletişim teorisine uygulanmıştır. Mesaj iletişimi modellenirken tek bir mesajın olası tüm mesaj setlerinden bir eleman olduğu varsayılmış, dolayısı ile bu modellemede olasılık kavramı kullanılmıştır (Shannon ve Weaver, 1949).

Entropi kavramının iletişim alanında kullanılması çalışmaları, haritanın içerdği bilginin nicel olarak ölçülmesinde de kullanılarak Kartografya disiplinde yeni araştırmalara konu olmuştur. Bu araştırmalar çerçevesinde literatürde ilgili konulardaki yayınlarda taramalar yapılmış ve özet bilgilere yer verilmiştir.

Shannon'un bilginin ölçülmesi uygulaması Sukhov tarafından Kartografyada uygulanmaya çalışılmıştır (Sukhov, 1967). Bu çalışmalar, entropi kavramının iletişimde Shannon tarafından kullanılmasından sonra, haritanın içerdği bilginin nicel ölçümü çalışmalarının öncüleri olmuşlardır. Sukhov'un çalışmalarında istatistiksel bilgi ele alınmıştır.

Neumann 1987 ve 1994 yıllarında haritaların topolojik bilgisi üzerine çalışmalar yapmıştır. Neumann, iletişim teorisi içerisinde geliştirilen bilgi konseptini kullanarak, eşyükseklik eğrili bir harita için topolojik bilginin ölçümünü araştırmış, komşu eşyükseklik eğrileri arasındaki topolojik ilişkiyi kaydetmek için bir topolojik ağ oluşturarak bu ağın entropisini hesaplamıştır.

Bjorke (1996), farklı ölçekteki haritaların karşılaştırılması, harita tasarımının değerlendirilmesi gibi amaçlarla harita bilgisinin nicel olarak ölçülmesi çalışmalarını yapmıştır.

Li ve Huang (2002), çalışmasında harita bilgisinin ölçülmesi için literatürde önerilen yöntemler değerlendirilmiştir. Ancak sözkonusu yöntemler kullanılarak gerçekleştirilen ölçmelerin sadece istatistiksel bilgi ve bazı türden topolojik bilgi için anlamlı olduğu belirtilmiş, metrik, topolojik ve tematik bilgi için yeni bir takım nicel ölçmeler önerilmiştir. Çalışmanın neticesinde ise metrik bilginin istatistiksel bilgiden daha anlamlı olduğu vurgulanmıştır. Ayrıca tematik bilgi için pratikte kullanılmak üzere yeni bir ölçme formülü önerilmiştir.

2.2 İstatistiksel Yöntem

2.2.1 Haritanın istatistiksel bilgisi: harita işaretlerinin entropisi

Entropi kavramının iletişimde Shannon tarafından kullanılmasından sonra Sukhov, (1967) ve (1970) yayınlarında entropi kavramını kartografik iletişim için uyarlamıştır. Sukhov'un çalışmasında istatistiksel bilgi ele alınmıştır. Bu bağlamda, sadece haritada temsil edilen harita işareti türleri hesaba katılmıştır.

N, haritadaki toplam harita işareti sayısı, M, harita işaretlerinin türlerinin sayısı ve K_i , i.türden harita işaretlerinin sayısı kabul edildiğinde;

$$N = K_1 + K_2 + \dots + K_M \quad (2.1)$$

olur.

Haritadaki işaretlerin her bir türünün olasılığı,

$$P_i = \frac{K_i}{N} \quad (2.2)$$

olur.

P_i , i. harita işaretinin türünün olasılığıdır, $i=1,2,\dots,M$.

Bu durumda haritanın entropisi denklem 2.3'de görüldüğü gibi hesaplanabilir.

$$H(X) = H(P_1, P_2, \dots, P_M) = - \sum_{i=1}^M P_i \ln(P_i) \quad (2.3)$$

İstatistiksel yöntemde temel bileşen, haritada yer alan objelerin tür sayıları ve bu türlere ait olan obje sayılarıdır. Böylesi bir değerlendirmede obje sayılarının gerçekçi olarak belirlenmesi son derece önemlidir. İstatistiksel yöntemin değerlendirilmesi konusunda analog haritalar ve uydu görüntü haritaları üzerinde çalışılmıştır. Analog

haritaların obje türleri ve sayıları manuel olarak sayılmış ve yöntemde kullanılmıştır. Sonrasında ise günümüzde harita üretimi için veri kaynağı olarak kullanılan hava fotoğrafları ve uydu görüntüleri üzerinde obje türlerinin ve obje sayılarının otomatik olarak belirlenmesine yönelik çalışmalar gerçekleştirilmiştir. Böyle bir çalışmaya gidilmesinin sebebi istatistiksel yöntemin metodolojisini uygulayabilmek için grafik obje sayısına ihtiyaç duyulmasıdır.

Bu çalışmalar kapsamında ilk olarak raster görüntülerde yer alan objelerin kenarlarının belirlenerek kapalı doğru olarak vektöre çevrilmesi ve sayılması amacıyla kenar belirleme yönteminde (edge detection) kullanılan Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny algoritmaları araştırılmış ve teorilerine yer verilmiştir (Bkz. bölüm 2.2.2).

Kenar belirleme yönteminden sonra spektral yansıma değerleri kullanılarak görüntüler üzerinde objelerin belirlenmesi amacıyla eşik değer yöntemi (thresholding) araştırılmıştır. Bu bağlamda temel, bant ve yüzde (p-tile) eşik değer yöntemlerine değinilmiştir (Bkz. bölüm 2.2.3).

Obje belirleme çalışmalarında son olarak sınıflandırma yöntemleri araştırılmış, kontrollü ve kontrolsüz sınıflandırma tekniklerine değinilmiştir. Kontrollü sınıflandırma; yapay öğrenme (machine learning) yöntemi olan destek vektör seçme ve adaptasyon algoritması çalışma konularına dahil edilmiştir (Bkz. bölüm 2.2.4.4).

2.2.2 Kenar belirleme (edge detection) yöntemi

Kenar belirleme işlemi görüntüdeki piksel değerlerinin değişim gösterdiği yerlerin belirlenmesi işlemidir. Bir kenar, görüntü içeriğinde genellikle parlaklıktaki çok ani ve büyük bir değişim şeklinde tanımlanabilmektedir (Timur ve Sarı, 2010). Objeler tanıma, hedef izleme ve bölütleme (segmentation) gibi işlemlerin içerisinde ilk aşama olarak kullanıldığı için, söz konusu işlemlerin başarısını doğrudan etkileyen ve literatürde çeşitli yöntemleri önerilen temel bir işlemidir (Marr ve Hildreth, 1980; Silvente-Garcia, et.al., 1997; Canny, 1986; Perona ve Malik, 1990; Lu ve Jain, 1992; Mallat ve Zhong, 1992). Kenar belirleme işlemi görüntünün daha keskin görünmesini sağlamaktadır. Görüntüdeki kenar çizgilerinin belirlenmesi işlemi objelerin saydırılması amacı ile kullanılmaktadır. Görüntüdeki objelerin yayılımları ve kapladıkları alan belirlenmektedir (McAndrew, 2004). Kenar belirleme işleminin bir diğer önemi, objelerin tanımlanmasında en temel geometrik bilgi olan şeklin

ortaya konulması ve bu bilginin kullanılarak şekilsel olarak objenin yeniden oluşturulmasına olanak tanınmasıdır (Dhaliwal, 1990). Bu amaçla tezde Matlab yazılımında yer alan kenar belirleme yöntemleri kullanılmıştır.

Matlab yazılımının kenar belirleme yöntemlerinin kullanılmasındaki amaç kenar belirleme yeteneği kullanılarak görüntüdeki objelerin sınırlarının ve geometrilerinin kapalı alan biçiminde belirlenebilmesidir.

Objelerin sayılabilmesi için kenarlarının çoklu doğru olarak belirlenmesi birinci adımdır. Çoklu doğrulardan kapalı alan elde edilmesi ve böylelikle obje tanımlanması amaçlanmış, altı farklı yöntem ile uygulamalar yapılmıştır. Kullanılan yöntemler;

- Sobel yöntemi,
- Prewitt yöntemi,
- Roberts yöntemi,
- Laplacian of Gaussian yöntemi,
- Zero-Cross yöntemi,
- Canny yöntemi'dir.

Bu yöntemlerin çalışma biçimlerine ilişkin özet bilgiler derlenmiş ve kısaca özetlenmiştir.

2.2.2.1 Sobel yöntemi

Sobel yöntemi, eğimin maksimum olduğu noktalarda kenar oluşturur (Sobel ve Feldman, 1968). Görüntüdeki parazitlere karşı Roberts, Laplacian of Gaussian yöntemlerine oranla daha duyarlıdır (Dong, et.al., 2005).

2.2.2.2 Prewitt yöntemi

Prewitt yaklaşımını kullanır, eğimin maksimum olduğu noktalarda kenarları dönerek köşe oluşturur. Gauss kenar modelini kullanır. Bu model genellikle tasarımda kolaylık sağlamasına rağmen, uygulamada sorun çıkarır. Söz konusu sorunlardan ilki, doğal görüntülerde sadece kenarların yer almamasıdır (Konishi, et.al., 2003). İkincisi ise, birbirine yakın nesnelerin yarattığı karmaşık durum kenar modeliyle uyuşmamaktadır (Heijden, 1995).

2.2.2.3 Roberts yöntemi

Roberts yöntemi görüntüyü çizgisel bir yapıda işler, çizgisel yapıyı üç boyutlu hale dönüştürür ve son olarak da üç boyutlu yapıyı tüm gizli çizgileri kaldırılmış hali ile görüntüler (Robert, 1965). Sobel, Roberts ve Prewitt yöntemlerinin, kenarların bulanık olması veya parazit içermesi durumlarında iyi çalışmadıkları bilinmektedir. Ayrıca, bu yöntemlerin parazitli görüntülerde açı ve yön konularında problemlerinin olduğu (Basu, 2002) ve köşelerde iyi çalışmadıkları gösterilmiştir (Michell, et.al., 1989).

2.2.2.4 Laplacian of Gaussian (LoG) yöntemi

Görüntüyü Gaussian filtresi ile yumuşattıktan sonra zero-cross metodunu kullanarak kenarları oluşturur. İlk olarak Marr ve Hildreth (1980) tarafından önerilmiştir. LoG yöntemi çeşitli ölçeklerde uygulanabilen çok çözünürlüklü bir yöntemdir (Şenel, 2007). Doğal görüntülere uygulandığında, LoG iyi bir kenar bulma yöntemi değildir ve parazite karşı hassas olması nedeniyle uygulanmadan önce, bilgi kaybı göze alınarak görüntünün yumuşatılması gereklidir (Garcia-Silvente, et.al., 1997).

2.2.2.5 Zero-Cross yöntemi

Zero-Cross yöntemi kenarlardaki renk yoğunluğu değişiminin etkin olarak belirlenebilmesi amacıyla Marr ve Hildreth (1980) tarafından önerilmiştir. Yöntem görüntüyü Gaussian filtresi ile yumuşatır ve kenarları ikinci türevin sıfırı ile ilişkilendirir (Clark, 1989). Bu amaç doğrultusunda yöntemin iki özelliğe sahip olması gerekir. Birincisi, görüntünün birinci ya da ikinci dereceden türevinin alınması için diferansiyel bir operatör olmalıdır. İkincisi ise istenen ölçekte hareket edebilme yeteneğine sahip olmalıdır. Böylece büyük filtreler gölge kenarlarını tespit etmek için, küçük filtreler ise görüntüdeki keskin detayların belirlenmesi için kullanılabilir. Zero-Cross yönteminde kullanıcının belirlediği bir filtre ile görüntü temizlenir.

2.2.2.6 Canny yöntemi

Yöntem, bir pikselin kenar üzerinde olup olmadığına komşularına bakarak karar vermektedir (Şenel, 2007). Belirgin ve belirgin olmayan kenarları belirlemek için iki tane eşik değeri kullanılır. Belirgin olmayan kenarlar ancak belirgin kenarlara bağlı oldukları durumlarda dikkate alınarak oluşturulurlar. Canny metodu parazit miktarı

fazla olan görüntülerde diğer metotlara göre pek başarılı olamaz, fakat belirgin olmayan kenarların belirlenmesinde oldukça başarılıdır (McAndrew, 2004). Canny yöntemi, LoG gibi yöntemlere göre zayıf kenarlara karşı daha hassastır. Bu durum kendisini kenarlarda titremelerin olması ve yanlış kenarların bulunmasıyla belli eder (Basu, 2002).

2.2.3 Eşik değer (thresholding) yöntemi

Eşik değer yöntemi birçok görüntü işleme uygulamalarında gerekli bir işlem adımıdır (Tsai, 1985). Bu yöntem piksellerin verilen ölçüte göre ayrıştırılması için kullanılmaktadır. Eşik değer yöntemi objeleri zeminden ayırmak için kullanılan en yaygın yöntemdir (Abutaleb, 1989; Illingworth ve Kittler, 1986; Mao ve Liang, 1995). Eşik değer yöntemleri;

2.2.3.1 Temel eşik değeri

Temel eşik değeri yöntemi hala etkili olan en basit bölütleme yöntemidir (Sonka ve Fitzpatrick, 2004). Bu yöntemde görüntüdeki her bir pikselin gri tonu değerine bakılır. Pikselin gri tonu değerinin eşik değerden büyük ya da küçük olduğu esas alınarak piksel değeri maksimuma ya da minimuma indirgenir.

$$\text{Bir piksel;} \quad \begin{cases} >S \text{ gri tonuna sahipse beyazdır,} \\ <S \text{ gri tonuna sahipse siyahtır.} \end{cases}$$

2.2.3.2 Bant eşik değeri

Bant eşik değeri, temel eşik değerine benzer çalışmaktadır ancak tek bir eşik değeri yerine iki eşik değerine sahiptir. Pikselin gri tonu değeri, eşik değer aralığında ise maksimuma, aralık dışında ise minimuma indirgenir (Henden, 2004).

$$\text{Bir piksel;} \quad \begin{cases} S_1 \leq S \leq S_2 \text{ gri ton değerine sahipse beyazdır,} \\ \text{Farklı bir gri ton değerine sahipse siyahtır.} \end{cases}$$

2.2.3.3 Yüzde eşik değeri

Yüzde eşik değeri yöntemi görüntü gri değeri histogramının analizi üzerine kurulmuş ilk eşik değer yöntemlerinden biridir (Samopa ve Asano, 2009). Yöntem görüntüdeki objelerin zeminden daha parlak olduğunu ve resim alanının sabit bir yüzdesi

olduğunu kabul eder. Söz konusu resim alanının yüzdesi $P\%$ olarak ifade edilmektedir. Eşik değer, objedeki en az $P\%$ gri tonu değerine karşılık gelen gri tonu değeri olarak tanımlanır.

2.2.4 Sınıflandırma

Görüntü sınıflandırması, arazi örtüsü türleri (örneğin; su, tahıl, orman, çimen vs.) spektral yansıma değerlerinin, bir spektral desen tanımlama teorisi ile analiz edilerek görüntünün benzer spektral sınıflara ayrılmasıdır. Diğer bir deyişle sınıflandırma işlemi; bir görüntüyü oluşturan piksellerin niteliklerini belirlemektir (Türker, 1999).

Sık kullanılan sınıflandırma aşamaları kullanılan yöntemeye göre kontrollü ve kontrolsüz sınıflandırma olarak iki ana kısma ayrılabilir.

2.2.4.1 Kontrolsüz sınıflandırma

Kontrolsüz sınıflandırma işleminde öncelikle spektral kümeler belirlenir. Bu tamamen yansıma değerlerine dayalı sayısal bir işlem olarak yapılır. Daha sonra bu kümeler sınıf oluşturmak üzere kullanılır (Url-1).

2.2.4.2 Kontrollü sınıflandırma

Kontrollü sınıflandırma işleminde kullanıcı görüntüde bilgi sahibi olduğu homojen örnek alanları tanımlar ve bu alanlar bilgisayar sınıflandırma algoritmasında eğitim alanları olarak temel alınarak sınıflandırma işlemi yapılır (Url-1).

2.2.4.3 Destek vektör makineleri yöntemi ile sınıflandırma

Destek vektör makineleri (DVM) – Support vector machines (SVM) yöntemi, sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinin çözümü için Vapnik (1995) tarafından önerilen eğitici bir öğrenme algoritmasıdır. Son yıllarda daha yaygın olarak kullanılmaya başlanan destek vektör makineleri, yazı tanıma, nesne tanıma, ses tanıma, yüz tanıma gibi uygulamalarda kullanılmıştır (Borges, 1998). Uzaktan algılama verilerinin sınıflandırılmasında da DVM yaygın olarak kullanılmaktadır. Sınıflandırma destek vektörleri kullanılarak değil, sonrasında Lagrange katsayılarına bağlı oluşturulan hiper düzlem kullanarak yapılır.

DVM sınıflandırma tekniği, istatistiksel öğrenme teorisine dayalı bir eğitilmiş sınıflandırma tekniğidir. DVM sınıflandırmasında başlıca üç aşama bulunmaktadır:

- Eğitim hücrelerinin özellik vektörü olarak ifade edilmesi,
- Özellik vektörlerinin kernel fonksiyonları kullanılarak özellik uzayına eşlenmesi,
- Sınıfları en uygun şekilde ayıran n-boyutlu bir hiper düzlemin (ayırma yüzeyi) oluşturulmasıdır.

Destek vektör makineleri algoritmalarının amacı sınıflandırma yaparken iki sınıfı birbirlerinden hata yapmaksızın ayıracak optimum bir hiperdüzlemin (ayırma yüzeyinin) bulunmasıdır. Bulunan bu düzleme en yakın vektörler de destek vektörleri olarak isimlendirilmektedir. Optimum hiperdüzlemin bulunması problemi, marjini en çok uzatan w vektörünün bulunması ile çözülmektedir. Marjin, hiperdüzleme en yakın noktadan hiperdüzleme olan en kısa dik uzaklıktır. Başlangıçta DVM sınıflandırma tekniği, iki sınıflı sınıflandırma problemlerinde kullanılmak üzere tasarlanmış, daha sonra çok sınıflı sınıflandırmalar için de kullanılmak üzere geliştirilmiştir.

Sınıflandırma, veriyi eğitim ve test verisi haline getirmektir. Eğitim verisindeki her bir örnek bir tane hedef değer (sınıf etiketleri gibi) ve çeşitli sayıda öznitelikler (özellikler veya gözlenen değişkenler) içermektedir. DVM'nin amacı test verisinin hedef değerlerini tahmin eden (eğitim verisine dayalı) bir model üretmektir.

Optimal bir hiperdüzlem için $wx+b=0$, w ve b , hiperdüzlemin elemanı olmalıdır. Burada x , N boyutlu bir uzayın (R) elemanıdır. İki sınıflı x verisini içeren bir sınıflandırma probleminde optimal hiperdüzlem 2.4 eşitliği ile ifade edilmektedir.

$$f(x) = \text{sign}(wx + b) = \text{sign}\left[\sum_{i=1}^{N_s} \alpha_i m_i x_i \cdot x\right] \quad (2.4)$$

Bu eşitlikte;

N_s , destek vektörlerinin sayısını,

x_i , i . destek vektörünü,

α_i , i . Lagrange çarpanını,


$m_i \in \{-1, +1\}$ x 'in hangi sınıfa ait olduğunu ifade etmektedir.

DVM sınıflandırma tekniği hem doğrusal olarak ayırma edilebilen hem de edilemeyen veri kümesini sınıflandırabilmektedir.

Doğrusal olarak ayrılabilen veriler için destek vektör makineleri


Doğrusal olarak ayrılabilen veriler söz konusu olduğunda DVM algoritmasının çalışma süreci aşağıdaki gibi özetlenebilir:

Öncelikle iki farklı sınıfa ait veriyi ayıracak doğrusal bir sınır gereklidir (şekil 2.4). Bu sınır hiper düzlem olarak adlandırılmaktadır.




Şekil 2.4 : İki farklı sınıfa ait veri.

Böylesi bir çözüm farklı geometrilerdeki hiper düzlemler ile sağlanabilir. Örneğin şekil 2.5'deki A_1 hiper düzlemi sağlıklı bir sınıflandırmayı sağlayabilmektedir.




Şekil 2.5 : Bir çözüm biçimi.

Şekil 2.6'da gösterilen A_2 hiper düzlemi de sınıflandırmayı sağlayabilmektedir.




Şekil 2.6 : Başka bir çözüm biçimi.

Böylesi bir obje dizilişini sağlıklı olarak sınıflandırabilecek farklı geometrilerde hiper düzlemler de bulunabilir (şekil 2.7).



Şekil 2.7 : Diğer çözümler.

Söz konusu durumda, DVM algoritmaları optimum hiper düzlemin bulunması amacıyla farklı sınıftan örnekler arasındaki uzaklığı (marjini) en çok uzatan w vektörünü bulacaktır (şekil 2.8). Örnek sınıflandırma problemine göre A_1 hiper düzlemi, A_2 hiper düzleminden daha iyi bir çözüm olacaktır.



Şekil 2.8 : A_1 ve A_2 hiper düzlemlerinin marjinleri.

DVM ile karşılaştırma yapılacak sınıf sayısı ikiden fazla ise iki farklı yaklaşım kullanılmaktadır;


- Bire-karşı-bir veya,
- Bire-karşı-kalanlar

Bire-karşı-bir yaklaşımında, her bir ikili sınıf için destek vektör makinesi ayrı ayrı çalıştırmakta ve her ikili sınıfa karşılık gelen karar sınır fonksiyonu oluşturulmaktadır.


Bire-karşı-kalanlar yaklaşımında ise her sınıf için “o ve kalanlar” olarak iki sınıf oluşturulup DVM eğitilmektedir. Sınıfı bilinmeyen vektörün ayırt etme yüzeyine olan uzaklığına bakılarak en büyük uzaklığı veren sınıf seçilmektedir.

Doğrusal olarak ayrılamayan veriler için destek vektör makineleri

Doğrusal olarak ayrılamayan verilerin doğrusal ayrılabilirliği artırılarak lineer olmayan bir kernel fonksiyonu (şekil 2.9) kullanılarak daha yüksek boyutlu başka bir uzaya taşınmakta ve bu yüksek boyutlu uzayda en uygun hiper düzlem bulunarak sınıflandırma yapılmaktadır (şekil 2.10). Eğitim kümesi elemanları, doğrusal olmayan bir fonksiyon (f) aracılığı ile daha yüksek boyutlu bir öznitelik uzayına dönüştürülmektedir. Eğitim verileri kullanılarak hiper düzlem bulunduktan sonra, test verileri sınırın hangi tarafında kalmışsa o sınıfa dahil edilir.



Şekil 2.9 : Girdi uzayında obje sınıfları ve hiper düzlem.



Şekil 2.10 : Daha yüksek boyutlu öznitelik uzayında obje sınıfları ve hiperdüzlem.

2.2.4.4 Destek vektör seçme ve adaptasyon yöntemi (DVSA)

Destek vektör seçme ve adaptasyon (DVSA) – Support vector selection and adaptation method (SVSA) yöntemi lineer ve lineer olmayan verinin sınıflandırılması için geliştirilen bir yöntemdir. Bu yöntemdeki referans vektörler lineer destek vektör makineleri (LibSVM) yönteminden elde edilmektedir. DVSA yöntemi “seçme” ve “adaptasyon” olarak isimlendirilmiş iki adımdan oluşmaktadır. Bu iki adımda öncelikle destek vektörler LibSVM’den elde edilmekte, bazı vektörler reddedilmekte, diğerleri ise seçilerek referans vektörü olarak uyarlanmaktadır. Sınıflandırma, referans vektörleri üzerinden K en yakın komşuluk algoritması (K

nearest neighbour method-KNN) kullanılarak gerçekleştirilmektedir (Kaya ve diğ., 2011). İlk adımda, tüm destek vektörler eğitim verileri kullanılarak KNN algoritması ile sınıflandırılmaktadır. Yanlış sınıflandırılan destek vektörleri reddedilmekte, kalan vektörler ise referans vektörleri olarak seçilmektedir.

İkinci adımda, referans vektörleri öğrenme vektörü nicelemesi yöntemi (Learning vector quantization-LVQ) kullanılarak karar sınırına doğru uzaklaştırılmakta ya da yaklaştırılmaktadır. Uyarılama sürecinin sonunda referans vektörleri oluşturulmuş olacaktır. Sınıflandırma süresince, her bir girdi vektörü minimum mesafe kuralına göre belirlenmektedir. Mesafeler girdi vektörünün tüm referans vektörlerine olan uzaklığına göre hesaplanmaktadır.

DVSA yöntemi sentetik ve gerçek veri ile test edilmiştir. Elde edilen sonuçlar DVSA yönteminin bilinen DVM yöntemi ile rekabet edebildiğini göstermektedir.

Ancak, lineer olmayan DVM yaklaşımında bazı zorluklarla karşılaşilmektedir. Bu zorluklar aşağıda maddelenmiştir.

- Eğitim verisinin boyutu büyüdükçe, problem çözümü için kullanılması gereken bellek büyümekte ve bir uygulamayı parçalara ayırtırmaya gereksinim duyulmaktadır. Sonrasında ise her bir uygulama parçasını iterasyon silsileleri ile çözme yoluna gidilmesi gerekmektedir (Platt, 1999).
- $m \times m$ boyutlu bir matris ile ifade edilen çekirdek fonksiyonu oldukça yoğun bir matris olduğu için işlemcinin m^2 numaralarını hesaplaması uzun zaman almaktadır.
- Sınıflandırma doğruluğunun artırılması noktasında kernel fonksiyonunun seçimi oldukça önemlidir. Ancak, özellikle veri yapısının çok iyi bilinmediği durumlarda, veri için hangi kernel türünün kullanılmasının optimum bir çözüm sağlayacağını kestirilmesi genel olarak zordur. Model seçimi teknikleri optimum bir kernel türünün seçilebilmesi açısından temel yoldur. Genellikle, optimal kernel seçenekleri deneme yanılma bazlı, uygulamaya dayalı kurallar yardımıyla belirlenir.
- Lineer olmayan DVM'den en iyi sınıflandırma performansının alınabilmesi için seçilen kernel türünün parametreleri ayrıca belirlenmelidir. Seçilen kernel türünün en iyi parametrelerini tahmin edebilmek için çapraz doğrulama algoritması kullanılabilir. Ancak, söz konusu durum da doğrusal

olmayan DVM'nin uygulanan çapraz doğrulama yöntemlerine bağlı olarak birçok kez çalıştırılması anlamına gelmekte, bu durum da uygulanması sırasında ekstra zaman almaktadır.

Bahsedilen zorlukları aşmak amacıyla destek vektör seçimi ve adaptasyonu (SVSA) isimli yeni bir yöntem geliştirilmiş ve uzaktan algılama görüntülerinin sınıflandırılması için uygulanmıştır. Yeni yöntemin geliştirilmesindeki amaç, lineer DVM'nin sadece karar verme sınırına en yakın vektörleri durumundaki destek vektörlerinin kullanılarak lineer olmayan DVM'nin performansının artırılmasıdır (Kaya ve diğ., 2011).

Daha fazla sayıda destek vektörünün seçilmesi sınıflandırmaya yardımcı olmaktadır. Sınıflandırma doğruluğunun artırılması için seçilen destek vektörlerinin referans vektörleri olarak uyarlanması lineer olmayan sınıflandırmaya faydalı olduğu kadar lineer sınıflandırmaya da faydalıdır. Sonrasındaki süreçte, sınıflandırma, etiketlenmiş referans vektörler üzerinden çalışmaktadır.

2.3 Topolojik Yöntem

Neumann (1994), haritanın topolojik bilgisini belirleyebilmek için iki aşamadan oluşan bir metot önermiştir. Önerisinin birinci aşamasında düğüm noktalarını komşuluk ilişkileri gibi bazı kurallara göre sınıflandırmak, böylece çiftli grafik oluşturmak yer almaktadır. İkinci aşamasında ise eşitlik (2.1)'i kullanarak haritadaki toplam obje sayısını, eşitlik (2.2)'yi kullanarak haritada yer alan obje türlerinin olasılıklarını ve eşitlik (2.3)'ü kullanarak da entropiyi hesaplamak yer almaktadır.

Sözü edilen topolojik bilginin kullanılabilirliği Bjorke (1996) tarafından sorgulanmıştır. Bjorke, harita işaretlerinin topolojik düzenlerini dikkate alarak topolojik bilginin diğer bir tanımını bulmuştur. Tek bir entropi adı yerine entropi takımı kavramını kullanmıştır. Ayrıca haritadaki işaretler arasındaki uzaklığın değişimini temel alan metrik entropi kavramını öne sürmüştür.

2.4 Metrik Yöntem

Haritalar, objeler hakkında, konum, şekil ve boyutla ilgili geometrik bilgiyi, objeler arasındaki topolojik-mekansal ilişkileri ve objelerin türleri hakkındaki tematik bilgiyi

içermektedir. Bu nedenle haritaların metrik, topolojik ve tematik bilgilerini değerlendirebilen yeni bir takım bilgi ölçmelerinin geliştirilmeye ihtiyacı vardır.

Metrik bilgi dikkate alındığında, objenin konumunun belirlenmesi sorun teşkil etmemekte ancak boyutunun ve şeklinin değerlendirilmesi kolay olmamaktadır. Objenin şeklinin belirlenebilmesi için bir yaklaşım da harita işaretinin boyutu üzerine kuruludur. Fakat söz konusu mutlak yaklaşımla gelen önemli eksiklikler vardır, aşağıda değerlendirilecektir:

Nokta tipli harita işaretinin boyutu her zaman için bir alan gösteriminde kullanılan harita işaretinden daha küçüktür, dolayısı ile böylesi bir durumdaki değerlendirme yanlış olabilir.

Diğer bir eksiklik ise objenin kapladığı alanın göreceli olmasıdır. Örneğin objeyi çevreleyen boş bir alan vardır ve bu boş alan objeyi geri kalan alandan ayırır. Objenin etrafındaki boş alan genişledikçe kullanıcının objeyi hatırlaması daha kolay olur. Bu durumda kullanıcıya sunduğu bilgi miktarı daha fazlaymış gibi düşünülür. Objelerin etraflarındaki boş alanların belirlenmesi amacıyla her bir objeyi içerisine alacak şekilde bölgeler oluşturularak tüm harita alanının mozaiklendirilmesinin en uygun çözüm olduğu düşünülmektedir. Bu çözüme en uygun yöntem Voronoi diyagramlarıdır (Lee ve Li, 2000).


2.4.1 Voronoi diyagramları

Düzlemde yer alan sonlu nokta kümesine ait herhangi bir noktaya, kümedeki diğer noktalardan daha yakın konumda bulunan düzlem noktalarının geometrik yerine o noktanın Voronoi çokgeni (poligonu) denilmektedir (Başaraner, 2005; Yanalak, 2001; Yanalak, 1997). Kümedeki tüm noktaların Voronoi çokgenlerinin birleşimi, o kümenin Voronoi diyagramını oluşturur. Bir Voronoi diyagramı iki boyutlu bir yüzeyin, her biri bir objeyle ilişkilendirilmiş olan, N tane çokyüzlü (poligonal) bölgeye bölünmesi için gereklidir.


Voronoi diyagramı literatürde Dirichlet, Thiessen veya Wigner-Seitz diyagramı olarak da anılmaktadır (Sukumar ve diğ., 2001, Watson, 1984).

Şekil 2.11’de bir veri kümesi ve bu kümeye ait Voronoi diyagramı görülmektedir. Bu diyagram en yakın nokta problemleri için kullanılan bir yapıdır. Bir noktanın Voronoi çokgeni herhangi bir noktayı, kendisine en yakın konumdaki komşu

noktalardan ayırmaktadır. Çokgenin kenarları, nokta ile komşu noktaları birleştiren doğru parçalarının kenar orta dikmelerinden oluşmakta, her nokta kendisine ait komşu noktalar ile birleştirildiğinde Delaunay üçgenlemesi elde edilmektedir (Worboys, 1995). Şekil 2.12’de Voronoi diyagramı verilmiş olan kümenin Delaunay üçgenleri görülmektedir.



Şekil 2.11 : Voronoi diyagramı.




Şekil 2.12 : Delaunay üçgenlemesi.

Objeye ile ilişkilendirilen bölge, diğer objelerden çok o objeye yakın noktalardan oluşan bölgedir. Bir obje ile ilişkilendirilen çokyüzlü bölge, o objenin “Voronoi Bölgesi” veya Thiessen Çokyüzlüsü olarak adlandırılır ve onu çevreleyen üçgen köşelerinin dik açıortaylarından oluşur. Bu şekildeki Voronoi bölgesi haritada yer alan objenin “etki bölgesi” veya “mekansal yakınlığı”dır. Voronoi bölgeleri boşluk veya üst üstelik olmaksızın tüm alanı kaplayan konveks çokyüzlülerden oluşan bir doku oluşturacaktır. Böylece bir harita objesinin Voronoi diyagramı obje etrafındaki boşluğun uygun bir parçası olmaktadır.

Voronoi bölgesi, harita objesinin etrafındaki boş alanın uygun bölümlenmesinin belirlenmesi için yeterli değildir, fakat komşuluk ilişkisi için iyi bir çözümdür (Gold, 1992). Chen, Li ve Gold (2001) çalışmasında da harita objeleri arasındaki mekansal ilişkileri tanımlamak için Voronoi bölgeleri kullanılmıştır.


Eşit sayıda fakat farklı dağılımda harita işaretleri içeren iki harita şekil 2.13 ve 2.15’de, bu haritaların Voronoi diyagramları şekil 2.14 ve 2.16’da gösterilmiştir.




Şekil 2.13 : Birinci harita.



Şekil 2.14 : Birinci haritanın Voronoi diyagramları.



Şekil 2.15 : İkinci harita.



Şekil 2.16 : İkinci haritanın Voronoi diyagramları.

2.4.2 Harita üzerindeki metrik bilgi

Bu bölümde sözü edilen metrik bilgi harita işaretlerinin kapladığı alan ile ilintili bir kavramdır. Yani, bir haritada yer alan harita işaretlerinin kapladığı boşluk miktarları birbirleri ile yaklaşık olarak eşit ise harita daha fazla bilgi içermektedir. Boşluk miktarları değişkenlik gösterdiği ölçüde haritadaki bilgi miktarı azalmaktadır.

Bu durum göz önüne alındığında haritanın Voronoi bölgesi ile tüm haritanın belirlenmiş bir kısmının alanı arasındaki oranın entropinin belirlenmesindeki olasılık olarak kullanılması anlamlıdır (Li ve Huang, 2002). S, tüm alan olarak kabul edilerek S_i , $i=1,2,...,n$ olarak mozaiklendirildiğinde aşağıdaki gibi bir olasılık öne sürülebilir:

$$P_i = \frac{S_i}{S} \quad (2.5)$$

Metrik bilginin entropisi, $H(M)$ şöyle bulunabilir:


$$H(M) = H(P_1, P_2, \dots, P_n) = - \sum_{i=1}^n \frac{S_i}{S} (\ln S_i - \ln S) \quad (2.6)$$

P_i olasılık değeri $i=1,2,\dots,n$ için aynı değerlere sahip olduğunda $H(M)$ maksimum değerde olur, diğer bir deyişle S_i alanı eşit olduğu zaman yine $H(M)$ maksimum değerine sahip olur. Matematiksel olarak,

$$H(M)_{\max} = H(P_1, P_2, \dots, P_n | P_1=P_2=\dots=P_n) = \log_2 n \quad (2.7)$$

(2.6) eşitliği, Li ve Huang (2002) tarafından literatüre dahil edilmiştir. Ancak bu eşitlik matematiksel olarak (2.3) eşitliği ile aynıdır. İki eşitlik arasında sadece parametreler değişmekte, (2.3) eşitliğinde haritadaki işaretlerin her bir türünün olasılığı olarak P_i , (2.6) eşitliğinde ise objenin Voronoi alanının tüm alana oranı olan S_i/S kullanılmıştır. Doktora çalışmasında her iki eşitlik de kaynağındaki orijinal halleri ile kullanılmıştır.

Örneğin şekil 2.17’de gösterilen iki harita da dokuz bölge ile mozaiklendirilmiştir fakat farklı miktarda metrik bilgi içermektedir. 2.6 numaralı eşitlik neticesinde şekil 2.17 (b)’deki örnek harita maksimum $H(M)$ değerine sahiptir. Bu koşulda eşit sayıda obje için, harita işaretleri daha düzgün dağıtıldığında entropinin fazla olacağı söylenebilir (Li ve Huang, 2002).



Şekil 2.17 : Dokuz bölge ile mozaiklendirilmiş harita örnekleri.

Doktora çalışmasında, bu bölümde tanımları yapılan mekansal bilginin ölçülmesi yöntemlerinden istatistiksel, topolojik ve metrik yöntem konularında uygulamalar gerçekleştirilmiş, detaylarına ve sonuçlarına bölüm 3’de yer verilmiştir.

3. UYGULAMALAR

Bu bölümde teorik olarak araştırılan konuların pratikteki sonuçlarını tespit için gerçekleştirilen uygulamalara yer verilmiştir. Uygulamalarda, haritada yer alan istatistiksel ve topolojik bilginin ölçülmesi için literatürde önerilmiş olan entropi yöntemine ilişkin çalışmalar ve sonuçlar yer almaktadır. İlerleyen bölümlerde entropi yöntemine esas olması bakımından harita üzerindeki objelerin otomatik sayılabilmesi amaçlı Matlab yazılımında ve Erdas imagine objective yazılımında gerçekleştirilen uygulamalara ve sonuçlarına yer verilmiştir.

3.1 Kullanılan Veriler ve Çalışma Alanı Verisi Özellikleri

Haritadaki mekansal bilginin ölçülmesi konusundaki yöntemlerden ilki olan istatistiksel Yöntemde temel bileşen, haritada yer alan objelerin tür sayıları ve bu türlere ait olan obje sayılarıdır. Bu nedenle obje türlerinin ve sayılarının doğru olarak belirlenmesi çok önemlidir. İstatistiksel yöntem uygulamalarında kullanılan haritalarda obje türleri ve sayıları manuel olarak sayılmıştır. Ancak günümüzde harita üretimi için veri kaynağı olarak kullanılan hava fotoğrafları ve uydu görüntüleri üzerinde obje türlerinin ve obje sayılarının çokluğu göz önünde bulundurularak obje türlerinin ve sayılarının otomatik olarak belirlenmesine yönelik çalışmalar gerçekleştirilmiştir.


Bu çalışmalar kapsamında ilk olarak raster görüntülerde yer alan objelerin kenarlarının belirlenerek kapalı doğru olarak vektöre çevrilmesi ve sayılması amacıyla kenar belirleme yönteminde (edge detection) kullanılan Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny algoritmaları araştırılmış ve teorilerine yer verilmiştir (bkz. Bölüm 2.2.2). Kenar belirleme yönteminden sonra spektral yansıma değerleri kullanılarak görüntüler üzerinde objelerin belirlenmesi amacıyla eşik değer yöntemi (thresholding) araştırılmıştır (bkz. Bölüm 2.2.3). Bu bağlamda temel, bant ve yüzde (p-tile) eşik değer yöntemlerine değinilmiştir. Objeler belirlenme çalışmalarında son olarak sınıflandırma yöntemleri araştırılmış, kontrollü ve kontrolsüz sınıflandırma tekniklerine değinilmiştir. Kontrollü sınıflandırma; yapay öğrenme (machine learning) yöntemi olan destek vektör seçme ve adaptasyon algoritması çalışma konularına dahil edilmiştir (bkz. Bölüm 2.2.4.4).

3.2 İstatistiksel Yöntem Uygulamaları

Bu bölümde istatistiksel bilgi miktarının belirlenebilmesi için, eşit ölçekli ve eşit obje sayılı haritaların karşılaştırılması uygulamasına ve ayrıca eşit ölçekli ve farklı kartograflar/yazılımlar/yöntemler kullanılarak genelleştirilmiş haritaların karşılaştırılması uygulamalarına yer verilmiştir.

3.2.1 Eşit ölçekli ve eşit obje sayılı haritaların karşılaştırılması

Bu uygulamada Knopfli (1983)'de yayınlanmış olan ve şekil 3.1(a) ve 3.1(b)'de gösterilen haritalar uygulama örneği olarak kullanılmıştır. Haritalar eşit sayıda kartografik obje içermektedir. Ancak bu objelerin konumları farklı dağılıma sahiptir.



Şekil 3.1 : Eşit sayıda, fakat farklı dağılımda objeler içeren iki harita.

Her iki harita da üç tür obje içermektedir, yollar, binalar ve ağaçlar. Her iki haritada da eşit sayıda obje türü mevcuttur. 7 yol, 17 bina ve 16 ağaçtan oluşan toplam 40 obje bulunmaktadır.

N, haritadaki toplam obje sayısı, M, obje türlerinin sayısı ve K, i.türden objelerin sayısı kabul edildiğinde eşitlik (2.1) kullanılarak;

şekil 3.1(a) haritası için $N_1=40$, $M_1=3$,

şekil 3.1(b) haritası için $N_2=40$, $M_2=3$

olarak hesaplanır.

Objelerin her bir türünün olasılığı eşitlik (2.2) kullanılarak;

şekil 3.1(a) haritası için;

$$P_{1(yol)} = \frac{7}{40}, P_{2(bina)} = \frac{17}{40}, P_{3(ağaç)} = \frac{16}{40}$$

şekil 3.1(b) haritası için;

$$P_{1(yol)} = \frac{7}{40}, P_{2(bina)} = \frac{17}{40}, P_{3(ağaç)} = \frac{16}{40}$$

oranları ile gerçekleşir.

Eşitlik (2.3) kullanılarak entropi aşağıdaki gibi hesaplanabilir.

$$H(X_1) = H(P_{yol}, P_{bina}, P_{agac}) = -\sum_{i=1}^M P_i \ln(P_i) \quad (3.1)$$

Eşitlik (3.1)'e göre her iki harita da aynı miktarda istatistiksel bilgiye sahiptir, $H(X)=1.04$.

Uygulama sonuçları çizelge 3.1'de özetlenmiştir.

Çizelge 3.1 : Uygulama sonuçları.


		M	N	P ₁	P ₂	P ₃	H(X)	
Şekil 3.1(a)	7	17	16	40	0.175	0.425	0.400	1.04
Şekil 3.1(b)	7	17	16	40	0.175	0.425	0.400	1.04

Ancak gerçekte her iki haritada yer alan objelerin dağılımları birbirinden farklıdır. Şekil 3.1(a)'da gösterilen objelerin çoğu sol alt köşeden sağ üst köşeye uzanmakta olan köşegenin sağında yer almaktadır ve üç obje türü de binaların arasına serpiştirilmiş konumdadır. Ana yol boyunca iki sıra bina yer almaktadır. Şekil 3.1(b)'de ise sol alt köşeden sağ üst köşeye uzanmakta olan köşegenin sol tarafında ağaçlarla kaplı bir alan yer almakta ve aksi yönde de binaların bulunduğu alan yer almaktadır. Yollar ise yaklaşık olarak köşegen boyunca uzanmaktadır. Gerçekte ise, her iki harita da mekansal gerçekliğin değişik yapılarını göstermektedir.


Sonuç olarak, bu yol ile hesaplanan entropide ile farklı türlerden olan obje sayıları hesaba katılmakta fakat bu objelerin mekansal düzenleri dikkate alınmamaktadır. Dolayısı ile istatistiksel bilgi miktarları eşit çıkmaktadır.

3.2.2 Farklı obje sayılı haritaların karşılaştırılması

Uygulamada, şekil 3.2’de gösterilen Ordu ili Fatsa ilçesine ait bir harita ile şekil 3.3’de gösterilen kadastro adası haritası kullanılmıştır.



Şekil 3.2 : Birinci örnek.



Şekil 3.3 : İkinci örnek.

Şekil 3.2 haritası için obje türlerinin sayıları:

- 3 yol,
- 15 bina,
- 5 ağaç,
- 4 elektrik direği,
- 4 poligon noktası,

toplam 31 harita objesidir.

Şekil 3.3 haritası için obje türlerinin sayıları:

- 4 yol,
- 1 bina,
- 13 ağaç,
- 7 elektrik direği,
- 4 poligon noktası,
- 6 rogar kapağı

toplam 35 harita objesidir.

N, haritadaki toplam obje sayısı, M, obje türlerinin sayısı ve K, i.türden obje sayısı kabul edilerek (2.1) eşitliği kullanılarak $N_1=31$, $M_1=5$ ve $N_2=35$, $M_2=6$ olarak gerçekleştir.

gHaritadaki objelerin her bir türünün olasılığı (2.2) eşitliği kullanılarak ve P_i , i. obje türünün olasılığı $i=1,2,...,M$ kabul edilerek,

$$P_{1(yol)}=\frac{3}{31}, P_{2(bina)}=\frac{15}{31}, P_{3(ağaç)}=\frac{5}{31}, P_{4(ekk.dir.)}=\frac{4}{31}, P_{5(pol)}=\frac{4}{31}$$

$$P_{1(yol)}=\frac{4}{35}, P_{2(bina)}=\frac{1}{35}, P_{3(ağaç)}=\frac{13}{35}, P_{4(ekk.dir.)}=\frac{7}{35}, P_{5(pol)}=\frac{4}{35}, P_{6(roğar)}=\frac{6}{35}$$

oranları ile gerçekleşir.

Bu şartlarda haritaların entropisi (2.3) eşitliği kullanılarak aşağıda görüldüğü gibi hesaplanabilir.

$$H(X_1) = H(P_{yol}, P_{bina}, P_{agac}, P_{ekk.dir.}, P_{pol}, P_{bina}) = -\sum_{i=1}^M P_i \ln(P_i)$$

Hesap sonucunda şekil 3.2’de gösterilen birinci haritanın istatistiksel bilgisi 1.40, şekil 3.3’de gösterilen ikinci haritanın istatistiksel bilgisi 1.59 elde edilmiştir. Uygulama sonuçları çizelge 3.2’de özetlenmiştir.

Çizelge 3.2 : Uygulama sonuçları.

	M						N	P₁	P₂	P₃	P₄	P₅	P₆	H(X)
Şekil 3.2	3	15	5	4	4		31	0.097	0.484	0.161	0.129	0.129	0.000	1.40
Şekil 3.3	4	1	13	7	4	6	35	0.114	0.029	0.371	0.200	0.114	0.171	1.59

3.2.3 Kenar belirleme yöntemi uygulamaları

Kenar çizgileri bir objenin görüntü zemini ve diğer objelerle arasındaki sınırı gösterir. Buradan hareketle, bir görüntüdeki kenar çizgileri hassas olarak belirlenebilirse tüm objeler belirlenebilir, alanı, çevresi ve geometrisi ölçülebilir (Nadernejad ve diğ., 2008). Uygulamalarda kullanılan görüntülerdeki objelerin kenarlarının belirlenmesi amacıyla Matlab yazılımının görüntü işleme modülünde yer alan kenar belirleme algoritmaları kullanılmıştır. Söz konusu algoritmalar Sobel, Prewitt, Roberts, Laplacian of Gaussian (LOG), Zero-Cross ve Canny Algoritmaları ile uygulamalar gerçekleştirilmiş, sonuçlarına yer verilmiştir.

3.2.3.1 209x136 piksel uydu görüntüsü uygulaması

Uygulamada 209x136 piksel büyüklüğünde bir yerleşim bölgesine uydu görüntüsü kullanılmıştır (şekil 3.4). Farklı kenar belirleme algoritmaları uygulanmış ve sonuç görüntüleri verilmiştir.



Şekil 3.4 : Sekiz binalı uydu görüntüsü örneği.



Sobel Algoritması.



Prewitt Algoritması.



Roberts Algoritması.



Laplacian of Gaussian Algoritması.



Zero-Cross Algoritması.



Canny Algoritması.


Şekil 3.5 : Altı farklı yöntem ile çalışılan görüntüdeki kenar çizgileri.

Uygulamada kullanılan Matlab kodları aşağıdadır. Program çalıştırılırken kullanılacak olan algoritma, kodun dördüncü satırında tırnak içerisinde belirtilmektedir.

```
close all;  
clear all;  
I = imread('serdar_8ev_sb_v1.tif');  
BW1 = edge(I, 'sobel');  
imshow(BW1);
```

3.2.3.2 1 m çözünürlüklü Ikonos görüntüsü uygulaması

Uygulamada kullanılan uydu görüntüsü 1 m çözünürlüklü Ikonos görüntüsüdür (şekil 3.6). İçerik olarak birbirine yakın konumlandırılmış binalardan oluşmaktadır.




Şekil 3.6 : Orijinal uydu görüntüsü.

Uygulamada kullanılan Matlab kodları aşağıdadır. Program çalıştırılırken kullanılacak olan algoritma, kodun dördüncü satırında tırnak içerisinde belirtilmektedir.

```
close all;  
clear all;  
I = imread('IKONOS_ist1_sb.tif');  
BW1 = edge(I,'sobel');  
imshow(BW1);
```


Uygulamada kullanılan orijinal görüntüdeki kenar çizgileri farklı algoritmalarla farklı şekillerde elde edilmiş ve şekil 3.7’de özetlenmiştir.



Sobel Algoritması.



Prewitt Algoritması.




Roberts Algoritması.



Laplacian of Gaussian Algoritması.



Zero-Cross Algoritması.




Canny Algoritması.

Şekil 3.7 : Altı farklı algoritma ile elde edilen kenar çizgileri.


3.2.3.3 Orbview uydu görüntüsünde Canny algoritması ile kenar belirleme

Orbview uydu görüntüsü kullanılarak farklı bir kenar belirleme uygulaması yapılmıştır. Şekil 3.8’de gösterilen uydu görüntüsü bir yerleşim alanına aittir (Yanalak ve diğ., 2008). Görüntüde yer alan objeler yüksekliklerine göre renklere ayrılarak gösterilmiştir. Görüntüde farklı renklerle temsil edilen objelerin kenarlarının daha kolay belirlenebileceği düşünülmektedir.



Şekil 3.8 : Yükseklikleri renkler ile görselleştirilmiş Orbview uydu görüntüsü.

Orijinal görüntüye farklı yöntemler uygulanarak kenar çizgileri belirlenmeye çalışılmıştır. En iyi sonuç Canny yönteminde elde edilmiştir. Sonuç olarak şekil 3.9’da görüldüğü üzere binaların belirlenebilen kenarları çoklu doğru biçiminde oluşmamış, dolayısı ile binalar kapalı alanlı objeler olarak elde edilememiştir.



Şekil 3.9 : Belirlenebilen kenar çizgileri.

3.2.4 Eşik değeri yöntemi uygulamaları

3.2.4.1 Uydu görüntüsünde bina örneği - pankromatik görüntü

Uygulamada kullanılan uydu görüntüsünde sekiz bina yer almaktadır (şekil 3.10).




Şekil 3.10 : Uygulamada kullanılan pankromatik uydu görüntüsü.

Kullanılan Matlab kodları aşağıdaki gibidir.

```
close all;  
clear all;s=imread('serdar_8ev_sb_v2.tif');  
imshow(s),figure,imshow(s>100);
```

Gri tonu eşik değerlerine göre sonuçlar şekil 3.11’de görüldüğü gibi elde edilmiştir. Görüntüdeki binaların beyaz olarak sınıflandırıldığı en başarılı sonuç gri tonu değerinin 240’tan büyük olduğu uygulama olarak görülmektedir. Fakat binaların geometrileri büyük oranda kaybedilmiştir. Bu nedenle sınıflandırılan objelerin alanları ölçüsünde obje olarak algılanmasını gerektirecek farklı bir kontrol algoritmasının yazılması ihtiyacı doğmuştur.



Şekil 3.11 : Gri tonu eşik değerlerine göre elde edilen sonuçlar.

3.2.4.2 Uydu görüntüsünde bina örneği-multispektral görüntü

Multispektral görüntüler için Matlab yazılımında “im2bw” komutu kullanılmıştır. Im2bw komutundan sonra kullanılacak değer 0 ile 1 arasında (0 ve 1 dahil) olmalıdır. Bu değer, gri tonu değerinin beyaz değere oranı ($\text{Gri tonu}/255$) olarak kullanılmaktadır.

Uygulamada şekil 3.12’de görülen, sekiz bina içeren multispektral uydu görüntüsü kullanılmıştır. Kullanılan Matlab kodları aşağıdaki gibidir.

```
close all;  
clear all;  
s=imread('serdar_8ev_r_v1.tif');  
imshow(s),figure,im2bw(s,0.43);
```



Şekil 3.12 : Sekiz bina bulunduran orijinal multispektral uydu görüntüsü.

Şekil 3.13’de görüldüğü üzere şekil 3.11 ile benzer sonuçlar ortaya çıkmıştır. Ancak “im2bw” komutu, hem pankromatik hem de multispektral görüntülerde kullanılabileceği için “imshow” komutundan daha etkili kullanım sağladığı düşünülmektedir.



(a): Oran>0.39



(b): Oran>0.55



(c): Oran>0.71




(d): Oran>0.78



(e): Oran>0.86 *



(e): Oran>0.94



(f): Oran>0.98

Şekil 3.13 : Gri tonu/beyaz oranına göre elde edilen sonuçlar.

3.2.4.3 Piksellerin gri tonu aralık ölçütüne göre ayrıştırılması uygulaması

Aralık olarak belirlenen gri tonu değeri ile binaların çatılarının sahip oldukları gri ton değeri aralıkları dikkate alınarak daha sağlıklı bir ayrıştırma yapılabileceği tahmin edilmektedir.


3.2.4.4 Uydu görüntüsünde bina örneği- pankromatik görüntü

Uygulamada şekil 3.10'da kullanılan, sekiz bina içeren pankromatik uydu görüntüsü kullanılmıştır.

Kullanılan Matlab kodları aşağıdaki gibidir.

```
close all;  
clear all;  
s=imread('serdar_8ev_sb_v2.tif');  
imshow(s),figure,imshow(s>50 & s<100);
```

Sonuçlarda da görüleceği üzere gri tonu aralığı kısaltıldıkça binaların seçilmesi güçleşmektedir. Uygulamalardaki en iyi sonuçlar gri tonunun 170 - 180 den başlayıp 220 ve 240 ile biten aralıklarında elde edilmiştir (şekil 3.14(a-z)).



(a): 120<Gri Tonu <140



(b): 120<Gri Tonu <160




(c): 120<Gri Tonu <190



(d): 120<Gri Tonu <220



(e): 140<Gri Tonu <150



(f): 140<Gri Tonu <160



(g): 140<Gri Tonu <200



(h): 140<Gri Tonu <240



(i): $150 < \text{Gri Tonu} < 230$



(j): $150 < \text{Gri Tonu} < 255$



(k): $160 < \text{Gri Tonu} < 240$



(l): $160 < \text{Gri Tonu} < 255$



(m): $170 < \text{Gri Tonu} < 200$



(n): $170 < \text{Gri Tonu} < 220 *$




(o): $170 < \text{Gri Tonu} < 230$




(p): $180 < \text{Gri Tonu} < 230$




(r): $180 < \text{Gri Tonu} < 240 *$




(s): $180 < \text{Gri Tonu} < 250$



(t): $190 < \text{Gri Tonu} < 240$



(u): $190 < \text{Gri Tonu} < 255$



Şekil 3.14 : Gri tonu aralığına göre elde edilen sonuçlar.

3.2.4.5 Uydu görüntüsünde bina örneği-multispektral görüntü

Uygulamada şekil 3.12’de görülen, sekiz bina içeren multispektral uydu görüntüsü kullanılmıştır. Kullanılan Matlab kodları aşağıdaki gibidir.

```
close all;
clear all;
s=imread('serdar_8ev_r_v1.tif');
imshow(im2bw(s,0.6)) & (im2bw(s,0.7))
```

Bu uygulamada 3.2.4.4 uygulamasında başarılı olmuş sonuçlar göz önüne alınarak bir aralık oran belirlenmiştir ve değişken oranlar kullanılarak şekil 3.15’de görülen sonuçlar elde edilmiştir.



(a): $0.6 < \text{Oran} < 0.7$



(b): $0.6 < \text{Oran} < 0.8$



(c): $0.7 < \text{Oran} < 0.8$



(d): $0.7 < \text{Oran} < 0.9$



(e): $0.8 < \text{Oran} < 0.85$



(f): $0.8 < \text{Oran} < 0.9$



(g): $0.85 < \text{Oran} < 0.95$



(h): $0.9 < \text{Oran} < 0.95 *$

Şekil 3.15 : Gri tonu aralığına göre elde edilen sonuçlar.

Uydu görüntülerinde de görüldüğü üzere bina çatıları kırmızı renklidir ve doğada kırmızı renkli çok fazla obje bulunmamaktadır. Bu nedenle pankromatik görüntülere göre multispektral uydu görüntülerinde gri tonu oranı aralığı belirlenerek yapılan çalışmalarda daha başarılı sonuçlar elde edildiği gözlenmiştir.

3.2.5 Sınıflandırma uygulamaları

Sınıflandırma yöntemi ile gerçekleştirilen uygulamalar, kontrolsüz ve kontrollü sınıflandırma başlıkları altında yazılmıştır. Kontrolsüz sınıflandırma ve kontrollü sınıflandırma işlemlerinin kısa tanımlarına bölüm 2.2.4.1 ve 2.2.4.2’de yer verilmiştir. Kontrolsüz sınıflandırma başlığı altında Matlab yazılımında K-Means algoritması kullanılarak gerçekleştirilen uygulamalara ve sonuçlarına yer verilmiştir.

Kontrollü sınıflandırma başlığı altında ise iki farklı yöntem ile gerçekleştirilen uygulamalara ve sonuçlarına yer verilmiştir. Söz konusu yöntemlerden birincisi destek vektör seçme ve adaptasyon (DVSA) yöntemi, ikincisi ise Erdas yazılımının imagine objective modülü kullanılarak gerçekleştirilen uygulamalardır.

Kontrollü sınıflandırma işleminin bileşenlerinden olan eğitim verisi ve test verisi kavramları bu bölümde kısaca açıklanacaktır.

Eğitim verisi, sınıflandırma işleminde bilinmeyen veri kümelerini tanımlayabilmek, bilinmeyen veriler ile ilgili bir tahminde, veriler arasındaki ilişkileri öngörebilmek adına bir veri modeli oluşturmak amacıyla mevcut verilerden toplanan veri setidir. Eğitim verileri yapay zeka (artificial intelligence), makine öğrenmesi (machine learning), genetik programlama (genetic programming), zeki sistemler (intelligent systems) ve istatistik gibi çeşitli bilim dallarında da ayrıca kullanılmaktadır. Sözkonusu tüm alanlarda eğitim verisi benzer amaçlarla ve test verisi ile bağlantılı olarak kullanılmaktadır.

Test verisi, programa girilen verinin fonksiyon ile beklenen sonuçları verip vermediğini denemek, tahmin edilebilirliği artırmak amacıyla kullanılan bir veri setidir. Test verisi birlikte kullanıldığı eğitim verisi gibi, yapay zeka, makine öğrenmesi, genetik programlama, zeki sistemler ve istatistik gibi çeşitli bilim dallarında da benzer amaçla kullanılmaktadır.

3.2.5.1 Kontrolsüz sınıflandırma uygulamaları

K-Means algoritması ile obje sayma çalışmaları

Bu bölümde yaygın olarak kullanılan kümeleme algoritmalarından olan k-means algoritması ile obje sayma çalışmaları gerçekleştirilmiştir. Çeşitli nitelikte uydu görüntüleri kullanılarak bazı uygulamalar yapılmış ve sonuçlarına yer verilmiştir.

En eski kümeleme algoritmalarından olan K-Means, 1967 yılında J.B. MacQueen tarafından geliştirilmiştir (MacQueen, 1967). En yaygın kullanılan kontrolsüz öğrenme yöntemlerinden birisi olan K-means’in atama mekanizması, her verinin sadece bir kümeye ait olabilmesine

izin verir. Bu nedenle, keskin bir kümeleme algoritmasıdır. Merkez noktanın kümeyi temsil etmesi ana fikrine dayalı bir metottur (Han ve Kamber, 2001). Eşit büyüklükte küresel kümeleri bulmaya eğilimlidir. K-means kümeleme yönteminin değerlendirilmesinde en yaygın olarak karesel hata ölçütü SSE kullanılır. En düşük SSE değerine sahip kümeleme sonucu en iyi sonucu verir. Nesnelerin bulundukları kümenin merkez noktalarına olan uzaklıklarının karelerinin toplamı 3.2 eşitliği ile hesaplanmaktadır (Pang-Ning vd., 2005).

$$SSE = \sum_{i=1}^K \sum_{x \in C_i} dist^2(m_i, x) \quad (3.2)$$

Bu ölçüt sonucu, k tane kümenin olabildiğince yoğun ve birbirinden ayrı sonuçlanması hedeflenmeye çalışılır. Algoritma, karesel-hata fonksiyonunu azaltacak k parçayı belirlemeye gayret eder. K-means algoritması, algoritmaya kullanıcı tarafından verilen k parametresi ile n tane veriden oluşan veri setini k adet kümeye böler. Küme benzerliği kümedeki nesnelerin ortalama değeri ile ölçülür, bu da kümenin ağırlık merkezidir (Xu ve Wunsch, 2005; Işık ve Çamurcu, 2007).

Bu bölümdeki çalışmada literatürde yapılmış çalışmalardan ve Matlab yazılımında bulunan hazır fonksiyonlardan yararlanılmıştır. K-ortalama değer algoritması çalışmalarında İTÜ Bilgisayar Mühendisliği Bölümü'nden Dr. Gülşen Taşkın KAYA ile birlikte çalışılmıştır. Kullanılan kodlar Ek A.1'de sunulmuştur.

İkonos 2004 uydu görüntüsü uygulaması

Orijinal görüntü 73x53 piksel büyüklüğünde pankromatik bir görüntüdür (şekil 3.16). Binalar aynı proje tipinde inşa edilmiştir. Bina alanları 11x11 piksel büyüklüğündedir. Görüntüde yarım görünen bir adet bina görüntüden silinmiştir.




Şekil 3.16 : 38 bina içeren düzenli bir alan örneği.

Görüntünün sınıflandırması için 7 adet sınıf belirlenmiştir. Bu sınıf sayısına göre görüntü matrisine 100 kez K-ortalama değer algoritması uygulanmıştır. Her bir uygulama için farklı sınıflardan oluşan 7 adet görüntü elde edilmiştir.

Ardından, her bir sınıf için ilgili sınıfa ait nesnelerin sınıf merkezine olan öklit uzaklıkları hesaplanmıştır. 100 uygulama arasından hesaplanan uzaklıklar, toplamının en küçük olduğu uygulama, en uygun uygulama olarak seçilmiş ve bu uygulamaya ait sınıflandırma görüntüleri üzerinde binalar tespit edilmeye çalışılmıştır.

Görüntü çözünürlüğü dikkate alınarak bir takım ayıklama ölçütleri belirlenmiştir. Bu ölçütlere göre bina görünümünde olmayan nesneler görüntüden çıkarılmıştır. Sözgelimi, binanın olabilecek en küçük ve en büyük yerleşim alan büyüklüğü metre kare olarak kaç piksele karşılık geleceği belirlenmiş ve bu ölçütlere uymayan nesneler görüntüden çıkarılmıştır.

Uygulama neticesinde en başarılı sonuç 1.sınıfta alınmıştır, 38 binadan 26 tanesi sayılmıştır (şekil 3.17). Başarı oranı %68 olarak gerçekleşmiştir.



Şekil 3.17 : K-means algoritması uygulama sonuçları.

Binaların belirlenmesi görüntü çözünürlüğüne bağlı olduğu kadar sınıflandırma kalitesine de bağlıdır. Nesneler özelliklerine göre ne kadar iyi sınıflandırılırsa başarı oranı da ona göre artacaktır. Bu nedenle, sınıflandırma algoritmasının geliştirilmesi veya daha farklı sınıflandırma algoritmaları ile uygulamalar yapılması gerekmektedir. Düzenli yerleşim alanlarının dışında düzensiz yerleşim alanları üzerinde de uygulama yapılmıştır.


Ancak, düzenli alanlara uygulanan algoritma düzensiz alanlara uygulandığında başarı oranı oldukça düşük çıkmıştır. Bu başarısızlıkta, görüntü çözünürlüğünün etkili olması ile birlikte geliştirilen algoritmanın bu alanlar, için yetersiz olduğu ve daha farklı algoritmalar geliştirilmesi ve uygulanması gerekmektedir.

Yerleşim alanı görüntüsü uygulaması

Uygulamada kullanılan görüntü 310x84 piksel büyüklüğünde pankromatik bir görüntüdür (şekil 3.18). Binalar aynı proje tipinde inşa edilmiştir. Bina alanları 45x55 piksel büyüklüğündedir. Bina şekline benzer olan yüzme havuzu ve resimde yarım görünen binalar görüntüden silinmiştir.



Şekil 3.18 : 34 bina içeren düzenli bir alan örneği.



Şekil 3.19 : K-means algoritması uygulama sonuçları.

Uygulama neticesinde en başarılı sonuç 5.sınıfta alınmıştır, 34 binadan 31 tanesi sayılmıştır. Başarı oranı %91 olarak gerçekleşmiştir. Program tarafından bina olarak kabul edilerek sayılan objeler ve sınıfları şekil 3.19’da gösterilmektedir.

Ikonos 1 m çözünürlüklü uydu görüntüsü uygulaması

Uygulamada kullanılan görüntü 164x268 piksel büyüklüğünde pankromatik bir görüntüdür. Düzensiz yapıdaki bir yerleşim alanına aittir. Binalar farklı proje tiplerinde inşa edilmiştir, bina alanları eşit büyüklükte değildir (şekil 3.20).




Şekil 3.20 : Ikonos 1 m çözünürlüklü orijinal uydu görüntüsü.

Görüntüde manuel olarak 64 adet bina sayılmıştır. Görüntüdeki en küçük bina dikkate alınarak programa girilen minimum bina alanı 25 m^2 , maksimum bina alanı 500 m^2 ‘dir.

Uygulama neticesinde en başarılı sonuç 2. sınıfta alınmıştır, 64 binadan 54 tanesi sayılmıştır. Başarı oranı %84 olarak gerçekleşmiştir. Program tarafından bina olarak kabul edilerek sayılan objeler ve sınıfları şekil 3.21’de gösterilmektedir.


Düzensiz yerleşim alanı uygulaması üzerinde genel bir değerlendirme yapıldığında ayırık nizam binaların sayımında daha başarılı olunduğu görülmektedir.



Şekil 3.21 : K-means algoritması uygulama sonuçları.


Ikonos 4 m çözünürlüklü uydu görüntüsü uygulaması

Uygulamada kullanılan görüntü Ikonos uydusuna ait ve 4 m çözünürlüklüdür. Multispektral banttan pankromatik olarak üretilen görüntü 150x167 piksel büyüklüğündedir (şekil 3.22).




Şekil 3.22 : Ikonos 4 m çözünürlüklü uydu görüntüsü.

Kullanılan görüntüde manuel olarak 20 adet bina sayılmıştır. Farklı proje tiplerinde inşa edilen binaların büyüklükleri $11 \times 11 = 121$ piksel ile $19 \times 19 = 361$ piksel aralığındadır. Program, bu alan ölçütleri ile çalıştırıldığında, yedi farklı sınıfta elde edilen bina sayıları şekil 3.23’de gösterilmiştir.



Şekil 3.23 : K-means algoritması uygulama sonuçları.

Uygulama neticesinde en başarılı sonuç 7.sınıfta alınmıştır, 20 binadan 15 tanesi sayılmıştır. Başarı oranı %75 olarak gerçekleşmiştir. Program tarafından bina olarak kabul edilerek sayılan objeler şekil 3.24’de gösterilmiştir.



Şekil 3.24 : Program tarafından bina olarak sayılan objeler.

Ikonos 4m çözünürlüklü uydu görüntüsü uygulaması (604x1158 piksel)


Uygulamada kullanılan Ikonos uydu görüntüsü 4 m çözünürlüklü, 604x1158 piksel büyüklüğünde, pankromatiktir (şekil 3.25).



Şekil 3.25 : Ikonos 4 m çözünürlüklü orijinal uydu görüntüsü.


Görüntüde manuel olarak 299 adet bina sayılmıştır. Farklı proje tiplerinde inşa edilen binaların büyüklükleri 9x9 piksel, yani $81 \times 4 = 324 \text{ m}^2$ ile 12x12 piksel, yani $144 \times 4 = 576 \text{ m}^2$ aralığındadır.

Program, en küçük bina alanı 320 m^2 , en büyük bina alanı 580 m^2 ölçütleri ile çalıştırıldığında şekil 3.26’da görülen sonuçlar elde edilmiştir.



Şekil 3.26 : K-means algoritması uygulama sonuçları.

Programın sonuç olarak sunduğu, en başarılı sınıfa ait görüntü ve bu görüntü içerisinde girilen ölçütler çerçevesinde bina olarak sayılan objeler, şekil 3.27’de gösterilmiştir.



Şekil 3.27 : En başarılı sınıf ve bina olarak sayılan objeler.

3.2.5.2 Kontrollü sınıflandırma uygulamaları


Bu bölümde uydu görüntülerinin sınıflandırılması çalışmaları yapılmıştır. Bu bağlamda iki farklı yazılım kullanılarak uygulamalar gerçekleştirilmiş ve sonuçlarına yer verilmiştir. Çalışmaların birinci kısmında MultiSpec yazılımı ile gerçekleştirilen uygulamalar yer almaktadır. İkinci kısmında ise Matlab yazılımı ile gerçekleştirilen uygulamalar yer almaktadır.

MultiSpec yazılımı ile gerçekleştirilen sınıflandırma uygulamaları

MultiSpec yazılımı, Purdue Üniversitesi Elektronik ve Bilgisayar Mühendisliği Bölümünden Profesör David Landgrebe ve ileri programlama merkezi sistem yöneticisi Larry Biehl tarafından, Uzaktan Algılama Uygulamaları Laboratuvarı (LARS–Laboratory for Applications of Remote Sensing), Purdue Bilgi Teknolojileri (ITaP – Information Technology at Purdue) ve NASA’nın (National Aeronautics and Space Administration) desteği ile geliştirilmiştir.

Washington DC Mall uygulaması



Uygulamada kullanılan uydu görüntü A.B.D. Washington DC Eyaletinde yer alan bir alışveriş merkezi ve yakın çevresine aittir. Görüntü Hydice uydusuna ait 3.2 m yersel çözünürlüklü ve 1280x307 piksel boyutundadır (şekil 3.28).



Şekil 3.28 : Washington DC Mall Hydice görüntüsü ve özellikleri.

Uygulamada kontrollü sınıflandırma işlemi kullanılmıştır. Kontrollü sınıflandırma işlemi için MultiSpec yazılımının işlemci (processor) menüsünden istatistikler (statistics) işlemi seçilmiştir. İstatistikler işlemi sonrasında açılan proje özellikleri penceresinde eğitim ve test verilerinin seçimi, sınıf isimlerinin belirlenmesi seçenekleri işaretlenmektedir (Landgrebe ve Biehly, 2001). Eğitim verisinin belirlenmesi sürecinde görüntüde yer alan sınıfların belirlenmesi için objelerin karakteristik özelliklerini içerecek şekilde pikseller seçilerek yazılıma tanıtılmaktadır (şekil 3.29).


En çok benzerlik yönteminin (maximum probability) kullanıldığı ve sınıflandırılan görüntünün *.gis uzantılı olarak kaydedildiği uygulamanın sonucu şekil 3.29'da görülmektedir. Orijinal ağaçlar, bina çatıları, yollar, su yapıları ve yeşil alan olarak 5 sınıfta başarı ile sınıflandırılmıştır.



Şekil 3.29 : Sınıf oluşturma ve eğitim verisi hazırlama işlemleri ve sınıflandırılmış Washington DC Mall görüntüsü.

İstanbul Levent bölgesi yerleşim alanı uygulaması

Uygulamada kullanılan uydu görüntüsü İstanbul Levent bölgesine aittir. Görüntüde düzenli bir yerleşim alanı ve manuel olarak sayılan 44 adet bina yer almaktadır. Binaların çatıları benzer malzemeden üretilmiş, benzer proje tiplerinde inşa edilmişlerdir. MultiSpec yazılımında görüntüleme özellikleri ile birlikte açılan uygulama görüntüsü şekil 3.30'da sunulmuştur.




Şekil 3.30 : MultiSpec ekranında uygulama görüntüsü ve özellikleri.

Bu uygulamada kontrolsüz (unsupervised) ve kontrollü (supervised) olmak üzere her iki tür sınıflandırma işlemi de çalışılmış ve sonuç görüntülerine yer verilmiştir.

Kontrolsüz sınıflandırma uygulaması

Kontrolsüz sınıflandırma işlemi için yazılımın işlemci (processor) menüsünden kontrolsüz sınıflandırma-kümeleme işlemi seçilir. İşlem sonrasında açılan sınıflandırma özellikleri penceresinde sınıflandırma algoritması olarak Isodata seçilerek oluşturulmak istenen sınıf sayısı belirlenir ve sınıflandırma işlemi başlatılır. Sınıflandırılmış görüntü alanının görüntülenmesi/raporlanması seçeneklerinden sınıflandırma raporunun görüntülenmesi, sınıflandırılan görüntünün ise farklı bir pencerede gösterimi seçenekleri işaretlenmektedir.


Gerçekleştirilen uygulamada orijinal görüntü 4 sınıf kullanılarak sınıflandırılmış ve şekil 3.31’de görülen görüntü elde edilmiştir. Görüntüde sırası ile görüntü zemini, bina çatıları, yol ve yeşil alan başarı ile sınıflandırılmıştır.



Şekil 3.31 : Kontrolsüz sınıflandırma uygulaması sonuç görüntüsü.

Kontrollü sınıflandırma uygulaması

Maksimum benzerlik yönteminin kullanıldığı ve sınıflandırılan görüntünün *.gis uzantılı olarak kaydedildiği kontrollü sınıflandırma uygulamasının sonucu şekil 3.32’de görülmektedir. Orijinal görüntü sırası ile görüntü zemini, bina çatıları, ağaçlar ve yol olmak üzere 4 sınıf kullanılarak başarı ile sınıflandırılmıştır.



Şekil 3.32 : Kontrollü sınıflandırma uygulaması sonuç görüntüsü.

Sınıflandırma çalışmalarının birinci kısmını oluşturan MultiSpec yazılımı ile yapılan uygulamalardan sonra ikinci kısımda Matlab yazılımı kullanılmıştır.

3.2.5.3 DVSA yöntemi

Uygulamalarda DVSA yöntemi ile sınıflandırma çalışmaları gerçekleştirilmiş, otomatik sınıflandırma neticesinde elde edilen pikseller merkez alınarak Voronoi diyagramları çizdirilmiştir. Elde edilen diyagramlar kullanılarak metrik bilginin ölçülmesi çalışmaları yapılmıştır.

Uygulama sürecinde DVSA algoritmasına eğitim ve test verisinin hazırlanması amacıyla, yazar tarafından tez kapsamında bir program hazırlanmıştır. Programın içerisinde sınıf sayısını manuel seçebilme amaçlı bir arayüz yer almaktadır. Sınıflandırma sonucunda sınıflara ayrılan piksellerin koordinatlarını merkez kabul ederek Voronoi diyagramları çizen bir program hazırlanmıştır. Söz konusu çalışmalar için Matlab yazılımı kullanılmıştır. Hazırlanan program için Matlab yazılımının mevcut görüntü işleme ve arayüz fonksiyonları modifiye edilmiş ve Voronoi diyagramlarını çizmek için Voronoi fonksiyonu söz konusu programa gömülmüştür.

ManualClass programı ile sınıflandırma çalışmaları

Sınıflandırma için Matlab yazılımında manuel olarak sınıflandırma yapan ve sınıflandırdığı piksellerin satır, sütun ve RGB değerlerini matris olarak oluşturan bir program hazırlanmıştır. Program, uydu görüntüsü için önce eğitim verisi (training data) hazırlamakta, sonrasında ise eğitim verileri ile karşılaştırmak için test verisi (testing data) hazırlamaktadır. Programın kodları Ek A. 2’de verilmiştir.

Manuel sınıflandırma programında Matlab yazılımının mevcut görüntü işleme araçlarına ait fonksiyonlardan “Questdlg”, “Manualclass” ve “Voronoi” fonksiyonları kullanılmıştır. Bu fonksiyonların kodları ve kullanılış amaçları bölümler halinde açıklanmıştır.

Questdlg fonksiyonu

“Questdlg” fonksiyonu kullanıcının tercihini belirlemek için Matlab kullanıcıları tarafından yazılmış bir fonksiyondur. Fonksiyon, kullanıcı ile etkileşim kurmak amacıyla ekranda bir soru penceresi açmaktadır. Söz konusu pencerede daha önceden tanımlanmış seçenekleri sunarak, kullanıcının isteğini belirlemektedir (Url-3).

Derlenen manuel sınıflandırma programı içerisinde questdlg fonksiyonunun görevi, “kullanıcıya manuel olarak kaç adet sınıf için eğitim ve test verisi belirlemek istediğini” sormaktır. Programda maksimum üç sınıf seçilebilmektedir. Daha fazla sayıda sınıf için de programa müdahale edilerek sınıf seçme sayısı artırılabilir.

Manualclass fonksiyonu

Yazılan programa manualclass fonksiyonu gömülerek yeni bir pencerede açılan uydu görüntüsünde kullanıcının obje sınıflarına göre piksel seçmesi sağlanmıştır. Programda “questdlg” fonksiyonu çalıştıktan sonra “manualclass” fonksiyonu çalışmaktadır. “Manualclass” fonksiyonu, “questdlg” fonksiyonu neticesinde seçilen sınıf sayısı (programda “numclass” değişkeni olarak atanmıştır) kadar döngü oluşturmakta ve her bir sınıf için kullanıcının ekrandaki uydu görüntüsünden piksel işaretlemesini beklemektedir. İlgili sınıfa ait piksel seçimi bitiminde bir sonraki sınıfa ait piksel seçimine geçmektedir. “Manualclass” fonksiyonu `cl=manualclass (x,numclass,method)` kodu ile programa gömülmüştür.

Kod içerisinde:

- x değişkeni uydu görüntüsünü,
- “numclass” kullanıcının belirlediği sınıf sayısını,
- “method” ise pikselleri işaretleme yöntemini ifade etmektedir.

Manualclass fonksiyonu “pixels” ve “rectangles” yöntemleri olmak üzere iki şekilde piksel işaretleyebilmektedir.

- Kod satırına “pixels” yöntemi yazıldığında sınıflara ait pikseller tek tek bağımsız pikseller şeklinde işaretlenmektedir.
- “rectangles” yöntemi yazıldığında ise sınıflara ait pikseller kapalı dörtgenler şeklinde, dolayısı ile daha geniş örnekler şeklinde işaretlenmektedir.


Manualclass fonksiyonu 2002 yılında İsveç Lund Üniversitesi Matematik Bilimleri Merkezi’nden Dr. Finn Lindgren tarafından yazılmış bir Matlab fonksiyonudur (Url-4).

Voronoi fonksiyonu

Voronoi fonksiyonu görüntüdeki piksellerin sınıflandırılması için tanımlanan piksellerin koordinatlarını merkez kabul ederek Voronoi diyagramları çizmektedir. Sınıflandırılan obje ile etrafındaki bölgenin ilişkilendirilmesinin sağlanması amacıyla programda Voronoi fonksiyonuna yer verilmiştir. Voronoi diyagramları çizilen objelerin etraflarındaki boşluk alan hesaplanarak metrik bilgi miktarının belirlenmesinde kullanılmıştır. Voronoi fonksiyonunun Matlab kodları Url-3 kaynağında yer almaktadır.


Manuel sınıflandırma programının çalışma detayları

Program çalıştırıldığında questdlg fonksiyonunun çıktısı olarak manuel olarak sınıf sayısı seçimi arayüzü çalışmaktadır (şekil 3.33).




Şekil 3.33 : Questdlg fonksiyonu ve manuel sınıf sayısı seçimi penceresi.

Sınıf sayısı seçildikten sonra bu değer “numclass” değişkeni olarak atanarak uydu görüntüsü okunmakta ve uydu görüntüsü ekrana getirilerek kullanıcının eğitim verisini hazırlaması için manuel sınıf seçmesi istenmektedir. Şekil 3.34’de üç adet sınıf seçilerek uygulama yapılmıştır.




Şekil 3.34 : Manuel olarak üç sınıf seçme işlemi.

Kullanıcının sınıf seçimi bittikten sonra işaretlenen pikseller lokal ekran koordinatları ile bir grafik üzerinde noktalar halinde gösterilmektedir (şekil 3.35).



Şekil 3.35 : Pksellerin lokal koordinatlar ile grafik üzerinde gösterimi.

Seçilen piksellerin RGB değerleri ile A matrisi, x ve y ekran koordinatları ile B matrisi oluşturulmaktadır. Sonrasında A matrisinin inversi yardımıyla seçilen piksellerin sınıf değerleri (label) ilk kolona yazılarak birleştirilmekte, böylece “A_{ilki}” matrisi elde edilmektedir. Bu aşamada “classvec” değişkeninin inversi alınmakta ve etiket değerleri bu şekilde elde edilmektedir.



Şekil 3.36 : B matrisindeki koordinatlarla çizilen Voronoi diyagramları ve parametreler.

Programın son işlemi olarak piksellerin x ve y ekran koordinatlarından oluşturulan B matrisinden koordinatlar çekilerek Voronoi diyagramları çizilmekte ve ayrı bir pencerede gösterilmektedir (şekil 3.36). Çizilen Voronoi diyagramlarını alanları hesaplanmakta ve çıktı

olarak sunulmaktadır. Ayrıca, programın çalışma alanı penceresinde şekil 3.36'da görülen parametreler de elde edilebilmektedir.

Bu parametrelerin kısa açıklamaları aşağıda verilmiştir.

A: Sınıflandırılan piksellerin RGB değerleri matrisi

A_{bir} : classvec matrisinin inversi

A_{iki} : Piksellerin RGB değerlerinin kolonlara, piksellerin ait oldukları sınıf değerinin de label olarak birinci kolona yerleştirilerek gösterildiği matris

B: Sınıflandırılan piksellerin koordinat değerleri matrisi

N: Manuel sınıflandırma işleminde son sınıfta seçilen piksel sayısı

N_x : Programa alınan uydu görüntüsü matrisinin satır sayısı

N_y : Programa alınan uydu görüntüsü matrisinin sütun sayısı

choice: Kullanıcının questdlg fonksiyonu ile seçtiği sınıf sayısı

classvec: Sınıflandırılan pikselin hangi sınıfa ait olduğunu belirten matris

cols: Son sınıfta seçilen piksellerin RGB değerlerinin 2. satırından oluşan matris

filePath: Verinin bulunduğu klasör

j: Döngüde 1'den kullanıcının son sınıfta seçtiği piksel sayısına kadar olan aralık

k: Döngüde 1'den kullanıcının belirlediği sınıf sayısına kadar olan aralık

numclass: Kullanıcının belirlediği sınıf sayısı


numelements: Sınıflandırılan piksellerinin hangi sınıfta kaç tane olduğunu belirten matris

rows: Son sınıfta seçilen piksellerin RGB değerlerinin 1. satırından oluşan matris

s: Manuel sınıflandırma için kullanılan uydu görüntüsü matrisi (satır ve sütun sayısı olarak ifade edilmektedir)

x: Programa alınan uydu görüntüsü ve matris olarak satır, sütun sayısı ve görüntünün kanal sayısı

Manuel sınıflandırma işleminden sonra şekil 3.37'de görülen $A_{iki}.dat$ isimli dosya elde edilmektedir. Elde edilen matris *.dat uzantılı olarak çalışmada belirlenen geçerli Matlab klasörü içerisine otomatik olarak kaydedilmektedir. Dosya, kullanıcının çeşitli sınıflar için işaretlediği piksellerin RGB değerlerini içeren bir matris formatındadır.



Şekil 3.37 : Manuel sınıflandırma işlemi sonrası RGB matrisi dosyası.

Eğitim ve test verilerinin DVSA programına aktarılması

Manuel sınıflandırma programında eğitim ve test veri setleri için iki farklı $A_{iki}.dat$ dosyası hazırlanmaktadır. Bu dosyalardan eğitim verisi için olanı $trn_xxx.dat$, test verisi için olanı $test_xxx.dat$ biçiminde isimlendirilerek DVSA programının çalıştığı klasör içerisindeki /data klasörüne kaydedilmektedir. Eğitim verisi matrisi trn değişkenine, test verisi matrisi tst değişkenine atanmaktadır.

Eğitim ve test verilerinin hazırlanmasında kullanılan sınıf sayıları ve her bir sınıf için seçilen piksel sayıları birbirinden bağımsızdır. Her iki matris de istenilen boyutta hazırlanıp DVSA programında çalıştırılabilmektedir. Ancak eğitim ve test verileri için hazırlanan dosyaların isimleri $trn_dosya86.dat$ ve $test_dosya86.dat$ gibi aynı olmalıdır.

Manuel sınıflandırma programı ile her iki veri seti de hazırlandıktan sonra dosyalar DVSA programına aktarılabilmesi için hazır olmaktadır.

3.2.5.4 Erdas imagine objective yazılımı ile obje belirleme ve saydırma uygulamaları

Bu bölümde yer alan uygulamaların amacı uydu görüntülerindeki objelerin bilgisayar tarafından otomatik algılanmasını ve sayılmasını sağlayabilmektir. Bu amaçla Erdas yazılımının Erdas imagine objective modülü kullanılmıştır. Bu modülün amacı görüntülerden obje çıkarma sürecini otomatikleştirmektir.

Uygulamalardaki sürecin işleyiş sırası;

- Obje için belirgin olan özelliklerin belirlenmesi,

- Yazılımın makine öğrenme teknikleri kullanılarak bu özelliklerle ilgili eğitilmesi,
- Devamında ise makine tarafından öğrenilen özellikler çerçevesinde görüntünün işlenmesi şeklindedir.

Her bir uygulamanın sonucunda, uydu görüntüsünde gerçekte var olan ve manuel olarak sayılan objelerin kaç tanesinin sayılabildiğine, yüzde olarak elde edilen başarıya yer verilmiştir. Uygulamalarda sırasıyla bina, yol ve ağaç obje türleri saydırılmıştır.

Bina saydırma uygulamalarında farklı tarihlerde yüksek çözünürlüklü uydular tarafından çekilmiş çeşitli özelliklerde uydu görüntüleri kullanılmıştır. Kullanılan uydu görüntüleri, binaların tespiti ve saydırılması için kullanılan ek yazılımlar ve parametreleri, sonuçta tespit edilen ve sayılan binalara ve başarıya ilişkin bilgilere yer verilmiştir.

Yerleşim alanı görüntüsü (Erdas residential.img) uygulaması


Erdas imagine objective yazılımın genel çalışma prensibinde önce yeni bir proje dosyasının oluşturulması yer almaktadır. Bu aşamada projenin ismi verilmekte ve genel bir tanımlamasının yapılması için seçenek yer almaktadır. Ayrıca projede kullanılacak olan görüntünün yer aldığı klasör seçilmektedir. Seçilen bu klasör içerisine yazılım tarafından sonuç olarak elde edilen tüm bilgilerin yer aldığı tabakalar ve tematik görüntüler kaydedilmektedir. Projenin oluşturulması ve tanımlanması aşamasından sonraki ekran kullanılarak projede kullanılacak olan raster formattaki uydu görüntüsünün yükleneceği klasör belirlenmektedir. Bu ekran değişken özellikleri olarak isimlendirilmektedir. Ekranda ayrıca yüklenecek olan verinin formatına ilişkin Raster, Vector, Terrain, Template seçenekleri de yer almaktadır. Kullanılan uydu görüntüsü şekil 3.38’de gösterilmektedir.



Şekil 3.38 : Orijinal uydu görüntüsü.

Uygulamada orijinal uydu görüntüsü üzerinde manuel olarak 62 adet bina sayılmıştır. Bu binaların çatı kaplama malzemeleri benzer özelliklere ve renklere sahiptir (şekil 3.39).

Binaların manuel olarak sayımı yapılırken binanın tamamının uydu görüntüsünde görünmesi esas alınmıştır. Bunun sebebi ise yazılımda objenin bina olarak sayılabilmesi için geometrik olarak dörtgen olması, alan olarak görüntüdeki binaların ortalama m^2 'lerini sağlaması gibi ölçütler kullanılmasıdır.




Şekil 3.39 : Uydu görüntüsünde manuel olarak sayılan 62 adet bina.

Gerçekleştirilen bina saydırma uygulamalarında Erdas imagine objective yazılımının altında çalışan,

- Raster piksel işlemcisi (Raster pixel processor-RPP),
- Raster obje yaratıcıları (Raster object creators-ROC),
- Raster obje operatörleri (Raster object operators-ROO),
- Raster vektör dönüşümü (Raster to vector conversion-RVC),
- Vektör obje operatörleri (Vector object operators-VOO),
- Vektör obje işlemcisi (Vector object processor-VOP),
- Vektör temizleme operatörü (Vector cleanup operator-VCO),


ek yazılımları sırasıyla kullanılmıştır. Söz konusu ek yazılımların parametreleri uydu görüntüsünün özelliklerine göre değiştirilmiştir. Ek yazılımlara gerektiğinde ilave parametreler eklenerek uygulamalar yürütülmüştür.

Uygulamada kullanılan raster piksel işlemci parametreleri şekil 3.40'da gösterilmektedir.



Şekil 3.40 : Raster piksel işlemci parametreleri ve kullanılan değerler.


Uygulamada kullanılan raster obje yaratıcıları parametreleri şekil 3.41’de gösterilmektedir.




Şekil 3.41 : Raster obje yaratıcıları parametreleri ve kullanılan değerler.

Uygulamada kullanılan raster obje operatörleri parametrelerinden;


- Olasılık (probability) parametresi şekil 3.42’de,
- Boyut filtresi (size filter) parametresi şekil 3.43’de,
- Kümeleme (reclump) parametresi şekil 3.44’de gösterilmektedir.



Şekil 3.42 : Olasılık parametresi ve kullanılan değerler.




Şekil 3.43 : Boyut filtresi parametresi ve kullanılan değerler.




Şekil 3.44 : Kümeleme parametresi ve kullanılan değerler.

Uygulamada kullanılan raster vektör dönüşümü parametreleri şekil 3.45’de gösterilmektedir.



Şekil 3.45 : Raster vektör dönüşümü parametreleri ve kullanılan değerler.


Uygulamada kullanılan vektör obje operatörleri parametrelerinden genelleştirme (generalize) parametresi şekil 3.46’da gösterilmektedir.




Şekil 3.46 : Genelleştirme parametresi ve kullanılan değerler.

Uygulamada kullanılan vektör obje işlemcisi parametrelerinden;


- Geometri (Geometry) örnek alanları şekil 3.47’de,
- Geometri: Alan şekil 3.48’de,
- Geometri: 2.eksen/1.eksen şekil 3.49’da,
- Geometri: Dörtgensellik şekil 3.50’de gösterilmektedir.




Şekil 3.47 : Geometri için kullanılan örnek alanlar.



Şekil 3.48 : Geometri: alan parametresi için kullanılan değerler.




Şekil 3.49 : Geometri: 2. eksen/1. eksen için kullanılan değerler.




Şekil 3.50 : Geometri: dörtgensellik için kullanılan değerler.

Uygulamada kullanılan vektör temizleme operatörü parametrelerinden;


- Olasılık filtresi (probability filter) şekil 3.51’de,
- Ada filtresi (island filter) şekil 3.52’de,
- Yumuşatma (smooth) şekil 3.53’de,
- Dikgenlik (orthogonality) şekil 3.54’de gösterilmektedir.




Şekil 3.51 : Olasılık filtresi ve kullanılan değerler.



Şekil 3.52 : Ada filtresi ve kullanılan değerler.




Şekil 3.53 : Yumuşatma ve kullanılan değerler.



Şekil 3.54 : Dikgenlik ve kullanılan değerler.


Uygulamanın sonucunda yazılım, verilen parametreler doğrultusunda görüntüde yer alan 62 adet binadan 61 tanesini bina olarak algılamış ve saymıştır (şekil 3.55). Ancak, yazılımın bina olarak algıladığı ve şekil üzerinde kırmızı daireler ile belirtilen iki adet obje yol objesidir. Geriye kalan bina sayısı ise 59'dur. Sonuç olarak bu durum %95 başarıya tekabül etmektedir.



Şekil 3.55 : Uygulama sonucu sayılan 59 adet bina ve 2 yol objesi.

İstanbul Kemer Country yerleşim alanı uygulaması

Uygulamada, şekil 3.56’da gösterilen İstanbul Kemer Country yerleşim bölgesine ait uydu görüntüsü kullanılmıştır.



Şekil 3.56 : İstanbul Kemer Country yerleşim alanı uydu görüntüsü.

Çizelge 3.3 : İstanbul Kemer Country uygulaması parametreleri.


Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 10 örnek veri	
Raster obje yaratıcısı					
	Eşik değeri ve kümeleme		% 90		
Raster obje operatörü					
	Boyut filtresi		Min:190 piksel	Maks:2500 piksel	
Raster vektör dönüşümü					
	Çoklu doğru				
Vektör obje yaratıcısı					
	Genelleştirme		Tolerans: 5 m		
	Olasılık filtresi		% 90		
Vektör obje işlemcisi					
	Geometri				
		Alan	Dağılım/Min:0 m ²	Dağılım/Maks:3 570.10 m ²	Piksel olasılığı: % 53
		2. eksen / 1. eksen	Min:0.24	Maks:1.00	Piksel olasılığı: % 53
		Köşegenlik	Min:0.00	Maks:1.00	Piksel olasılığı: % 53
Vektör temizleme operatörü					
	Doğru merkezi				

Çalışılan uydu görüntüsünde farklı çatı kaplama malzemelerine sahip farklı renkli binalar mevcuttur. Aynı zamanda binaların mimarileri de farklı olduğu için çeşitli geometrilere sahip farklı türden binalar bulunmaktadır. Bu nedenle uygulamada eğitim verileri belirlenirken her bir çatı kaplama türünden örnekler belirlenmiştir. Ayrıca objenin yazılım tarafından bina olarak belirlenebilmesi için geometrik ölçütler de farklı geometrideki binalar göz önünde bulundurularak belirlenmiştir. Uygulamada binaları belirlemek için uygulanan parametreler çizelge 3.3 ‘de gösterilmektedir.

Yazılım tarafından belirlenen binalar şekil üzerinde sarı renk ile gösterilmiştir. Orijinal uydu görüntüsündeki binalardan büyük çoğunluğu belirlenerek sayılmıştır. Yazılım tarafından sayılan bina sayısı 131’dir. Fakat site içi yürüyüş yollarından bazıları ve havuz kenarları da yazılım tarafından bina olarak algılandığı için bu rakamın içerisinde bu tür hatalı objeler de yer almaktadır.

Diğer yandan bitişik nizama sahip binaların sayılmasında çatılarının aralarında belirgin sınırlar olmaması nedeni ile başarılı olunamamış, yanyana inşa edilen binalar tek bir obje olarak algılanmıştır. Bazı durumlarda da binaların minimum ve maksimum alanları ölçüt olarak yazılıma girildiği için bitişik nizam binalar bu aralıkta alana sahip olmadıklarından yazılım tarafından bina olarak algılanmamıştır.

Ancak sonuç olarak şekil 3.57’de görüldüğü üzere binaların büyük kısmı başarılı olarak belirlenmiş ve sayılmıştır.



Şekil 3.57 : Uygulama sonucu belirlenen ve sayılan binalar.

Purdue Üniversitesi West Lafayette merkez kampüsü uygulaması

Bu uygulamada A.B.D. Indiana Eyaleti, West Lafayette şehrinde kurulu bulunan Purdue Üniversitesi merkez kampüsüne ait 1 m çözünürlüklü Ikonos uydu görüntüsü kullanılmıştır. Uydu görüntüsü Purdue Üniversitesinin Uzaktan Algılama Uygulamaları Laboratuvarına aittir ve uygulamada lisanslı kullanılmıştır. Uygulamada kullanılan uydu görüntüsü şekil 3.58’de gösterilmektedir.




Şekil 3.58 : Purdue West Lafayette merkez kampüsü uydu görüntüsü.

Çalışılan uydu görüntüsünde üniversitenin farklı çatı kaplama malzemelerine sahip, farklı geometrilerde inşaa edilmiş binaları mevcuttur. Bu nedenle uygulamada eğitim verileri belirlenirken her bir çatı kaplama türünden örnekler belirlenmiştir. Ayrıca objenin yazılım tarafından bina olarak belirlenebilmesi için geometrik ölçütler de farklı geometrideki binalar göz önünde bulundurularak belirlenmiştir. Ancak bu parametreler bina geometrilerinin tanımlanmasında yeterli olmamıştır. Özellikle U biçimindeki binalarda dörtgensellik, 2. eksen/1. eksen parametrelerinin kullanılmış olmasına rağmen sonuçlarda bu türden binalar başarılı olarak belirlenememiştir. Uygulamada binaları belirlemek için uygulanan parametreler çizelge 3.4’de gösterilmektedir.

Yazılım tarafından belirlenen binalar şekil üzerinde sarı renk ile gösterilmiştir. Yazılım tarafından sayılan bina sayısı 156’dır. Fakat kampüs içinde yer alan araç yollarından bazıları da yazılım tarafından bina olarak algılandığı için bu rakamın içerisinde bu tür hatalı objeler de yer almaktadır.

Çizelge 3.4 : Purdue West Lafayette uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 54 örnek veri	
Raster obje yaratıcısı					
	Eşik değeri ve kümeleme		% 66		
Raster obje operatörü					
	Boyut filtresi		Min:400 piksel	Maks:4500 piksel	
	Olasılık filtresi		Min. olasılık:%43		
	Tekrar kümeleme		Genişletme		
Raster vektör dönüşümü					
	Çoklu doğru				
Vektör obje yaratıcısı					
	Genelleştirme		Tolerans: 0.7 m		
	Yumuşatma		Faktör: 0.68		
Vektör obje işlemcisi					
	Geometri				
		Alan	Dağılım/Min: 400 m ²	Dağılım/Maks:35 4500 m ²	Piksel olasılığı: % 35
Vektör temizleme operatörü					
	Genelleştirme		Tolerans: 5 m		
	Boşluk filtresi		Tolerans: 0.0 m ²		
	Olasılık filtresi		Faktör: 0.45		
	Ortogonalite		Faktör: 0.50		
	Yumuşatma		Faktör: 0.60		



Şekil 3.59 : Uygulama sonucu belirlenen ve sayılan binalar.

Sonuç olarak geometrisi farklı olan binaların sayılmasında çok başarılı sonuçlar elde edilememiştir. Uygulamada %50'nin üzerinde bir başarı yakalanmıştır (şekil 3.59).

Purdue Üniversitesi öğrenci sitesi (Purdue Village) uygulaması

Bu uygulamada A.B.D. Indiana Eyaleti, West Lafayette şehrinde kurulu bulunan Purdue Üniversitesi'nin öğrenci sitelerine ait olan 1 m çözünürlüklü Ikonos uydu görüntüsü kullanılmıştır. Uydu görüntüsü Purdue Üniversitesinin Uzaktan Algılama Uygulamaları Laboratuvarına aittir ve uygulamada lisanslı olarak kullanılmıştır.

Uygulamada kullanılan uydu görüntüsü şekil 3.60'da gösterilmektedir. Uydu görüntüsünde üniversitenin öğrencilerinin konaklamaları için inşaa ettiği siteye ait binalar görülmektedir. Bina çatı kaplamaları aynı türdendir. Bina geometrileri de birbirine yakın şekillidir.




Şekil 3.60 : Ikonos 1 m çözünürlüklü Purdue öğrenci sitesi görüntüsü.

Uygulamada binaları belirlemek için uygulanan parametreler çizelge 3.5'de gösterilmektedir.

Yazılım tarafından belirlenen binalar şekil 3.61 üzerinde sarı renk ile gösterilmiştir. Yazılım tarafından sayılan bina sayısı 86'dır. Görüntüde gerçekte 89 adet bina yer almaktadır. Sonuç olarak bu durum %97 başarıya tekabül etmektedir.

Çizelge 3.5 : Purdue Üniversitesi öğrenci sitesi uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 10 örnek veri	
Raster obje yaratıcısı					
	Eşik değer ve kümeleme		% 90		
Raster obje operatörü					
	Boyut filtresi		Min:100 piksel	Maks:690 piksel	
	Olasılık filtresi		Min. olasılık:%40		
Raster vektör dönüşümü					
	Çoklu doğru				
Vektör obje yaratıcısı					
	Genelleştirme		Tolerans: 5.8 m		
	Boşluk filtresi		Tolerans: 22.8 m ²		
	Yumuşatma		Faktör: 0.52		
Vektör obje işlemcisi					
	Geometri				
		Alan	Dağılım/Min: 250 m ²	Dağılım/Maks:3 549.50 m ²	Piksel olasılığı: % 50
Vektör temizleme operatörü					
	Genelleştirme		Tolerans: 0.7 m		
	Boşluk filtresi		Tolerans: 0.2 m ²		
	Yumuşatma		Faktör: 0.30		



Şekil 3.61 : Uygulama sonucu belirlenen ve sayılan binalar.

Yol ağı uygulamaları

Erdaş imagine objective yazılımında yol belirleme ve saydırma uygulamalarında yazılımın altında çalışan,

- Raster piksel işlemcisi (Raster pixel processor-RPP),
- Raster obje yaratıcıları (Raster object creators-ROC),
- Raster obje operatörleri (Raster object operators-ROO),
- Raster vektör dönüşümü (Raster to vector conversion-RVC),
- Vektör obje operatörleri (Vector object operators-VOO),
- Vektör obje işlemcisi (Vector object processor-VOP),
- Vektör temizleme operatörü (Vector cleanup operator-VCO),

ek yazılımlar sırasıyla kullanılmıştır. Söz konusu ek yazılımların parametreleri uydu görüntüsünün özelliklerine göre değiştirilmiştir. Ek yazılımlara gerektiğinde ilave parametreler eklenerek uygulamalar tamamlanmıştır. Yol uygulamasında kullanılan ek yazılımların görevleri ve nitelikler kısaca açıklanmıştır. Ek yazılımlardan;

Raster piksel işlemcisi, orijinal görüntüden piksel örnekleme yolu ile alınan eğitim verisi yardımı ile yol ve yol olmayan objeleri sınıflandırmaktadır.

Raster obje yaratıcıları, sınıflandırma işleminden sonra eşiklendirme ve kümeleme ölçütlerini kullanarak olası yol objesini oluşturmak amacıyla yol piksellerini elde etmektedir.

Raster obje operatörleri, tüm olası yol objelerini kullanarak yol olmayan objelerin sayılarını bir kademe daha azaltmaktadır. Bu işlemde boyut filtresi kullanılarak boyut haricinde kalan objeler de elenmektedir. Yol uygulamaları için benzer şekilde yol genişliği ölçütünün kullanılması mümkündür.

Raster vektör dönüşümü, objelerin vektöre dönüştürülmesi için çizgi takibi yöntemi kullanılmaktadır. Bu işlemde bir shapefile (.shp) dosyası oluşturulmaktadır. Merkez doğrusunu tespit eden raster obje operatöründen sonra çoklu doğru formatındaki objeler, şerit genişliği bilgilerini içeren bir öznitelik dosyasına sahip olmaktadırlar. Vektör obje operatörleri, çizgi takibinden sonra çizgi üzerindeki düğüm noktalarının azaltılması için genelleştirme ölçütü kullanılmaktadır. Belirtilen ölçütlere uymayan uzunluktaki çizgiler de çizgi filtresi kullanılarak elenebilmektedir. Yazılım tarafından belirlenen yol merkez çizgilerinin aralarında olabilecek kesiklikleri ve boşlukları önlemek amacıyla bağlantı operatörü kullanılmaktadır. Yol ağı oluşturmak için de çizgi yakalama seçeneği kullanılmaktadır (Url-2).

Erdas subroad2 uydu görüntüsü uygulaması

Uygulamada farklı bir geometriye sahip yol ağının yer aldığı uydu görüntüsü kullanılmıştır. Kullanılan uydu görüntüsü şekil 3.62’de gösterilmektedir.




Şekil 3.62 : Yol uygulamasında kullanılan orijinal uydu görüntüsü.

Çalışılan uydu görüntüsünde yolları belirlemek için uygulanan parametreler çizelge 3.6’da gösterilmektedir.

Çizelge 3.6 : Erdas Subroad2 uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 6 örnek veri	
Raster obje yaratıcısı					
	Bölütleme				
Raster obje operatörü					
	Olasılık filtresi		Min. olasılık:%34		
	Boyut filtresi		Min:2002 m ²		
	Merkez doğrusu		Min uzunluk: 15 m	Maks uzunluk: 27 m	
Raster vektör dönüşümü					
	Doğru				
Vektör obje yaratıcısı					
	Genelleştirme		Tolerans: 1.5 m		
	Doğru bağlama		Tolerans: 1 m		
	Doğru iptali		Maks boşluk: 10 m	Min iptal: 48 m	
	Genelleştirme		Tolerans: 6 m		
	Yumuşatma		Faktör: 0.30		
	Doğru yakalama		Maks boşluk: 20 m	Maks mesafe: 20 m	
	Doğruyu şeride çevirme		Şerit genişliği: 10 m		

Elde edilen yol ağı şekil 3.63 üzerinde pembe renk ile gösterilmiştir. Orijinal uydu görüntüsündeki tüm yol ağı başarı ile belirlenmiştir.



Şekil 3.63 : Uygulanan parametreler neticesinde elde edilen yol ağı.

Purdue Üniversitesi öğrenci sitesi (Purdue Village) yol ağı uygulaması

Yol ağı uygulamasında kullanılan uydu görüntüsü şekil 3.60'da gösterilmektedir. Uygulamada yol ağını belirlemek için uygulanan parametreler çizelge 3.7'de sunulmuştur.

Çizelge 3.7 : Purdue öğrenci siteleri uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 6 örnek veri	
Raster obje yaratıcısı					
	Merkez doğrusu ve kümeleme				
Raster obje operatörü					
	Boyut filtresi		Min:9 m ²	Maks: 2060 m ²	
	Merkez doğrusu		Min uzunluk: 7 m	Maks uzunluk: 68 m	
	Olasılık filtresi		Min.olasılık:%43		
Raster vektör dönüşümü					
	Doğru				
Vektör obje operatörü					
	Doğru bağlama		Tolerans: 1 m		
	Doğru yakalama		Maks boşluk: 30 m		
	Yumuşatma		Faktör: 0.50		
	Genelleştirme		Tolerans: 1.5 m		
	Doğru iptali		Maks boşluk: 25 m	Min iptal: 53 m	
	Genelleştirme		Tolerans: 6 m		

Yazılım tarafından belirlenen yol ağı şekil 3.64’de gösterilmektedir.



Şekil 3.64 : Yazılım tarafından belirlenen Purdue öğrenci siteleri yol ağı.

Ağaç topluluklarının belirlenmesi uygulamaları

Bu bölümde uydu görüntülerindeki ağaç topluluklarının Erdas imagine objective yazılımı kullanılarak belirlenmesi konusunda uygulamalar gerçekleştirilmiş ve sonuçlarına yer verilmiştir.

Erdas trees.img görüntüsü uygulaması

Uygulamada, kullanılan uydu görüntüsünde yer alan ağaç topluluklarının yazılım tarafından otomatik olarak algılanması amaçlanmıştır. Uygulamada kullanılan uydu görüntüsü şekil 3.65’de yer almaktadır.




Şekil 3.65 : Uygulamada kullanılan uydu görüntüsü.

Çalışılan uydu görüntüsünde ağaç topluluklarının belirlenmesi için uygulanan parametreler çizelge 3.8’de gösterilmektedir.

Çizelge 3.8 : Erdas trees uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 5 örnek veri	
Raster obje yaratıcısı					
	Eşik değer ve kümeleme		%90		
Raster obje operatörü					
	Genişletme		Kernel boyutu:3		
	Boyut filtresi		Min:30 piksel Maks:∞		
Raster vektör dönüşümü					
	Kapalı alan				
Vektör obje yaratıcısı					
	Boşluk filtresi		Maks. Obje boyutu: ∞		
	Genelleştirme		Tolerans: 1 m		
	Ayırma		Olasılık:%41		
Vektör obje işlemcisi					
	Geometri				
		Alan	Dağılım/Min: 20 m ²	Dağılım/Maks: 140 m ²	Piksel olasılığı: % 50
		Yuvarlaklık	Min: 0.6	Maks:4	Piksel olasılığı: % 50
Vektör temizleme operatörü					
	Olasılık filtresi		Faktör: 0.90		
	Dışbükeylik				



Şekil 3.66 : Uygulama sonucu ve kullanılan parametreler.

Uygulama neticesinde söz konusu parametreler kullanılarak belirlenen ağaç toplulukları da şekil 3.66 üzerinde sarı renk ile gösterilmiştir. Ağaç topluluklarının tamamına yakını başarılı şekilde belirlenmiştir.


Purdue Üniversitesi öğrenci sitesi (Purdue Village) uygulaması

Uygulamada şekil 3.60’da gösterilen Purdue Üniversitesi öğrenci sitelerine ait olan 1 m çözünürlüklü Ikonos uydu görüntüsü kullanılmıştır. Uygulamada ağaç topluluklarının belirlenmesi için uygulanan parametreler çizelge 3.9’da gösterilmektedir.

Çizelge 3.9 : Purdue öğrenci siteleri uygulaması parametreleri.

Kullanılan ek yazılım	İşlem	Alt Ölçüt	1. Ölçüt Değeri	2. Ölçüt Değeri	3. Ölçüt Değeri
Raster piksel işlemci					
	SFP	SFP:Spectral	Sınıflandırıcı: Multi Bayesian Network	Eğitim verisi: 14 örnek veri	
Raster obje yaratıcısı					
	Eşik değeri ve kümeleme		%90		
Raster obje operatörü					
	Genişletme		Kernel boyutu:3		
	Boyut filtresi		Min:33 piksel Maks:855 piksel		
Raster vektör dönüşümü					
	Kapalı alan				
Vektör obje operatörü					
	Boşluk filtresi		Maks. obje boyutu: 0.7 m ²		
	Genelleştirme		Tolerans:0.5 m		
Vektör obje işlemcisi					
	Geometri				
		Alan	Dağılım/Min: 1 m ²	Dağılım/Maks: 600 m ²	Piksel olasılığı: % 50
		Yuvarlaklık	Min: 0.8	Maks:0.9	Piksel olasılığı: % 50
Vektör temizleme operatörü					
	Olasılık filtresi		Faktör: 0.60		
	Dışbükeylik				
	Skeleton ile ayırma				

Yazılım tarafından belirlenen ağaç toplulukları şekil 3.67 üzerinde sarı renk ile gösterilmiştir. Yazılım tarafından sayılan ağaç topluluğu sayısı, kapalı alan olarak 442 adettir. Görüntüde belirlenemeyen ağaç toplulukları yer almaktadır. Sonuç olarak yaklaşık %75 başarı elde edilmiştir.



Şekil 3.67 : Uygulama sonucu ve kullanılan parametreler.

3.3 Topolojik Yöntem Uygulamaları

Bu yöntem Neumann (1994) tarafından önerilen bir harita bilgi miktarı ölçme yöntemidir. Haritadan ölçülen bilgi miktarı topolojik bilgi olarak isimlendirilmiştir. İstatistiksel yöntemden farklı olarak iki aşamalı bir yöntemdir. Birinci aşamasında düğüm noktaları bağlantı ilişkileri bakımından sınıflandırılmakta, ikinci aşamasında ise bu sınıflar kullanılarak entropi hesabı yapılmaktadır.


Bu bölümde topolojik bilgi miktarının belirlenmesi konusunda gerçekleştirilen uygulamalara ve sonuçlarına yer verilecektir.

3.3.1 Eşit bağlantı sayılı topolojik ağların karşılaştırılması


Uygulamada Netcad yazılımında oluşturulan iki farklı yol ağı kullanılmıştır (şekil 3.68 ve 3.69). Bir bağlantılı düğüm noktaları kırmızı, iki bağlantılı düğüm noktaları mavi ve üç bağlantılı düğüm noktaları yeşil renk ile işaretlenmiştir.

Şekil 3.68’de gösterilen 1 numaralı topolojik ağda;

- 1 bağlantılı 7 düğüm noktası (●),
- 2 bağlantılı 2 düğüm noktası (●),
- 3 bağlantılı 5 düğüm noktası (●) vardır.



Şekil 3.68 : #1 yol ağı.



Şekil 3.69 : #2 yol ağı.

$N=14$, $M=3$ 'tür, böylece bu üç tür düğüm noktasının olasılıkları, eşitlik (2.2) kullanılarak $\frac{7}{14}$, $\frac{2}{14}$ ve $\frac{5}{14}$ olarak gerçekleşir. Bu yol ağının komşuluk entropisi eşitlik (2.3) kullanılarak hesaplandığında sonuç 0.99 olur.

Birtakım değişiklikler yapılarak şekil 3.69'da görüldüğü üzere yeni bir topolojik ağ oluşturulacak olursa 2 numaralı yeni ağda:

- 1 bağlantılı 7 düğüm noktası (●),
- 2 bağlantılı 2 düğüm noktası (●),
- 3 bağlantılı 5 düğüm noktası (●) vardır.

$N=14$, $M=3$ 'tür, böylece bu üç tür düğüm noktasının olasılıkları, eşitlik (2.2) kullanılarak $\frac{7}{14}$, $\frac{2}{14}$ ve $\frac{5}{14}$ olarak gerçekleşir. Bu yol ağının topolojik bilgisi eşitlik (2.3) kullanılarak hesaplandığında sonuç 0.99 olur. Uygulama sonuçları çizelge 3.10'da özetlenmiştir.

Çizelge 3.10 : Uygulama sonuçları.


	M			N	P ₁	P ₂	P ₃	H(X)
#1 yol ağı	7	2	5	14	0.500	0.143	0.357	0.99
#2 yol ağı	7	2	5	14	0.500	0.143	0.357	0.99

Sonuç olarak, her iki yol ağının topolojik bilgi miktarı aynıdır, yani 0.99'dur. Fakat 2 numaralı yol ağının 1 numaralı yol ağından daha karmaşık olduğu açıktır. Böylece bu

şekildeki bir topolojik bilginin, eşit bağlantı sayıları sözkonusu olduğunda, komşuluk ilişkilerinin gerçek karmaşıklığı yansıtmayabileceği görülmektedir.

3.3.2 Farklı ölçekli haritaların karşılaştırılması

Uygulamada şekil 3.70’de ve 3.71’de gösterilen haritalar kullanılmıştır. Şekil 3.71’de gösterilen 1:25000 ölçekli harita şekil 3.70’de gösterilen 1:5000 ölçekli haritanın genelleştirilmesi ile elde edilmiştir.




Şekil 3.70 : 1:5 000 ölçekli harita.



Şekil 3.71 : 1:25 000 ölçekli harita.

Uygulamada kullanılan her iki haritada yer alan objelerin düğüm noktalarının sayılması için Netcad yazılımı kullanılmıştır. 1:5 000 ölçekli haritada yer alan yol objesinin düğüm noktalarını bulmak amacı ile yol objesinin eksenini sayısallaştırılmıştır. Aynı şekilde bina objelerinin düğüm noktalarının bağlantı sayılarının bulunması için bina objeleri sayısallaştırılmıştır. Düğüm noktalarının bağlantı sayılarının daha hızlı bulunması için Netcad yazılımında her bir düğüm noktasına ardışık sayılar verilerek yol ve bina objeleri için şekil 3.72’de görülen bağlantı sayıları elde edilmiştir. Düğüm noktaları bağlantı sayılarına göre tabakalara ayrılmıştır. Bir bağlantılı düğüm noktaları kırmızı renk ile, iki bağlantılı düğüm noktaları mavi renk ile, üç bağlantılı düğüm noktaları yeşil renk ile, dört bağlantılı düğüm noktası sarı renk ile gösterilmiştir (şekil 3.72).



Şekil 3.72 : 1:5 000 ölçekli haritanın bağlantı noktalarının sayılması.

Haritadaki bağlantı sayıları çizelge 3.11’de özetlenmiştir.

Çizelge 3.11 : 1:5 000 ölçekli haritanın obje türüne göre bağlantı sayıları.


	Obje türü	1 bağlantılı	2 bağlantılı	3 bağlantılı	Nokta Sayısı
M=3	Yol	5 nokta	1 nokta	3 nokta	9
	Bina	-	209 nokta	-	209
	Ada-Parsel	25 nokta	60 nokta	5 nokta	90
	N	30 nokta	270 nokta	8 nokta	308

N=308, M=3’dür. Böylece söz konusu üç tür düğüm noktalarının olasılıkları eşitlik (2.2)

kullanılarak hesaplandığında sonuç $\frac{30}{308}$, $\frac{270}{308}$ ve $\frac{8}{308}$ olur. Bu haritanın topolojik bilgi

miktarı eşitlik (2.3) kullanılarak hesaplandığında sonuç 0.44 olur.

1:25 000 ölçekli haritada yer alan objelerin düğüm noktalarını bulmak amacı ile yol eksen, bina ve ada-parcel objeleri Netcad yazılımında sayısallaştırılarak şekil 3.73’de görülen bağlantı sayıları elde edilmiştir.



Şekil 3.73 : 1: 25 000 ölçekli haritanın düğüm noktalarının sayılması.

Haritadaki bağlantı sayıları çizelge 3.12’de özetlenmiştir.

Çizelge 3.12 : 1:25 000 ölçekli haritanın obje türüne göre bağlantı sayıları.

	Obje türü	1 bağlantılı	2 bağlantılı	3 bağlantılı	4 bağlantılı	Nokta Sayısı
M=3	Yol	5 nokta	1 nokta	1 nokta	1 nokta	8
	Bina	-	154 nokta	-	-	154
	Ada-Parsel	5 nokta	4 nokta	1 nokta	-	10
	N	10 nokta	159 nokta	2 nokta	1 nokta	172

N=172, M=4’dür. Sözkonusu dört tür düğüm noktalarının olasılıkları eşitlik (2.2) kullanılarak hesaplandığında sonuç $\frac{10}{172}$, $\frac{159}{172}$, $\frac{2}{172}$ ve $\frac{1}{172}$ olur. Bu haritanın topolojik bilgi miktarı eşitlik (2.3) kullanılarak hesaplandığında sonuç 0.32 olur. Uygulama sonuçları çizelge 3.13’de özetlenmiştir.

Çizelge 3.13 : Uygulama sonuçları.

Ölçek	M				N	P ₁	P ₂	P ₃	P ₄	H(X)
1:5 000	30	270	8	0	308	0.097	0.877	0.026	0.000	0.44
1:25 000	10	159	2	1	172	0.058	0.924	0.012	0.006	0.32


Uygulama sonucunda 1:5 000 ölçekli haritanın topolojik bilgi miktarı 0.44, 1:25 000 ölçekli haritanın topolojik bilgi miktarı 0.32 olarak elde edilmiştir. Genelleştirilen 1:5 000 ölçekli

haritanın 1:25 000 ölçekli haritadan daha sade ve okunaklı olduğu göz önüne alındığında, uygulama sonuçlarının haritaların karmaşıklıklarını belirleme noktasında anlamlı olduğu düşünülmektedir.

3.3.3 İstatistiksel ve topolojik yöntemin aynı örnek üzerinde karşılaştırılması

Bu uygulamada, 3.2.2 başlıklı uygulamada istatistiksel bilgileri ölçülen iki haritanın topolojik bilgilerinin ölçülmesine ve sonuçlarının istatistiksel bilgi ile karşılaştırılmasına yer verilmiştir. Söz konusu haritalar şekil 3.2 ve şekil 3.3’de gösterilmiştir.

Şekil 3.2’de yer alan haritanın bina, yol ve ada objelerinin düğüm noktalarının sayılması için Netcad yazılımı kullanılmış ve binalar sayısallaştırılmıştır (şekil 3.74). Sayısallaştırma işleminde tek bağlantılı düğüm noktaları için ayrılan tabaka kırmızı renk, iki bağlantılı düğüm noktaları için kullanılan tabaka mavi renk ile gösterilmiştir.



Şekil 3.74 : Bina, yol ve ada objelerinin düğüm noktalarının sayılması.


Şekil 3.2’de gösterilen haritanın bağlantı sayıları çizelge 3.14’de özetlenmiştir.

Çizelge 3.14 : Şekil 3.2’deki haritanın obje türüne göre bağlantı sayıları.

	Obje türü	1 bağlantılı	2 bağlantılı	3 bağlantılı	Nokta Sayısı
M=3	Bina	-	64 nokta		64
	Yol	5 nokta	3 nokta	1 nokta	9
	Ada	4 nokta	40 nokta	-	44
	N	9 nokta	107 nokta	1 nokta	117

Çizelge 3.14’de özetlendiği üzere N=117, M=3’dür. Söz konusu üç tür düğüm noktalarının olasılıkları eşitlik (2.2) kullanılarak hesaplandığında sonuç $\frac{9}{117}$, $\frac{107}{117}$ ve $\frac{1}{117}$ olur. Bu haritanın topolojik bilgi miktarı eşitlik (2.3) kullanılarak hesaplandığında sonuç 0.32 olur.

Şekil 3.3’de gösterilen haritada bir adet bina yer almaktadır. Bina, yol ve parsel objelerinin düğüm noktalarının bulunması için Netcad yazılımında sayısallaştırma yapılmıştır (şekil 3.75).



Şekil 3.75 : Bina, yol ve parsel objelerinin düğüm noktalarının sayılması.

Şekil 3.3’de gösterilen haritanın bağlantı sayıları çizelge 3.15’de özetlenmiştir.

Çizelge 3.15 : Şekil 3.2’deki haritanın obje türüne göre bağlantı sayıları.

	Obje türü	1 bağlantılı	2 bağlantılı	3 bağlantılı	Nokta Sayısı
M=3	Bina	-	2 nokta	2 nokta	4
	Yol	4 nokta	-	4 nokta	8
	Parsel	-	8 nokta	2 nokta	10
	N	4nokta	10 nokta	8 nokta	22

Dolayısı ile N=22, M=3’dür. Söz konusu üç tür düğüm noktasının olasılıkları eşitlik (2.2) kullanılarak hesaplandığında sonuç $\frac{4}{22}$, $\frac{10}{22}$ ve $\frac{8}{22}$ olur. Bu haritanın topolojik bilgi miktarı eşitlik (2.3) kullanılarak hesaplandığında sonuç 1.04 olur.

Şekil 3.2 ve 3.3’de yer alan haritaların topolojik bilgi uygulaması sonuçları çizelge 3.16’da özetlenmiştir.

Çizelge 3.16 : Uygulama sonuçları.

	M		N		P₁	P₂	P₃	H(X)
Şekil 3.2	9	107	1	117	0.077	0.915	0.009	0.32
Şekil 3.3	4	10	8	22	0.182	0.455	0.364	1.04

Uygulamada kullanılan haritaların istatistiksel bilgi miktarları şekil 3.2 için 1.40, şekil 3.3 için 1.59 olarak hesaplanmıştır. Topolojik bilgi uygulamasının sonucunda da istatistiksel bilgi ile benzer sıralamada sonuçlar elde edilmiştir.

3.4 Metrik Yöntem Uygulamaları


Haritadaki mekansal bilgi için yeni ölçmeler başlığı altında bölüm 2.4’de açıklanan konu üzerine bazı uygulamalar yapmanın yerinde olacağına karar verilerek metrik yöntem üzerine uygulamalar yapılmıştır. Söz konusu yeni yöntemin, istatistiksel ve topolojik yöntemlerden daha anlamlı olup olmadığı bu bölümde irdelenecektir

Bu bölümde sözü edilen metrik bilgi harita işaretlerinin kapladığı alan ile ilintili bir kavramdır. Entropi teoremine benzer bir söylem ile bir haritada yer alan harita işaretlerinin kapladığı alan ve etrafındaki boşluk miktarları birbirleri ile yaklaşık olarak eşit ise harita daha fazla bilgi içermektedir. Boşluk miktarlarının değişkenlik gösterdiği ölçüde haritadaki bilgi miktarı azalmaktadır (Li ve Huang, 2002).

3.4.1 Eşit ölçekli ve eşit obje sayılı haritaların karşılaştırılması

Bu durumu irdelemek için metrik bilgi üzerine bir uygulama yapılmıştır. Uygulamada bölüm 3.2.1’de istatistiksel bilgi miktarının ölçülmesi için kullanılan, Şekil 3.1(a) ve 3.1(b)’de gösterilen haritalar kullanılmıştır. Haritalar eşit sayıda harita işareti içermektedir. Şekil 3.76(a) ve 3.76(b)’de gösterilen Voronoi diyagramları sırası ile şekil 3.1(a) ve şekil 3.1(b) haritalarına aittir.

Eşitlik (2.4)’de verilen olasılığın hesaplanması amacıyla haritanın Voronoi bölgelerinin alanına ve tüm haritanın alanına ihtiyaç vardır. Söz konusu alanların belirlenebilmesi için Netcad yazılımı kullanılmıştır. Yazılımda haritalarda yer alan ağaç, bina ve yol obje türlerinin Voronoi bölgeleri sayısallaştırılarak alanlar hesaplanmıştır.




Şekil 3.76 : Farklı dağılımda objeler içeren haritaların Voronoi diyagramları.

Haritaların Voronoi bölgesi raster formatlı görüntüleri Netcad yazılımına yüklenirken iki noktalı dönüşüm uygulanmış sol alt köşe (Y,X) koordinatları (0.00,0.00) m, sağ üst köşe (Y,X) koordinatları (100.00,100.00) m alınmıştır.

Her bir obje türü için farklı tabakaların ve farklı renklerin (ağaç-yeşil, bina-mavi, yol-turuncu renk ile gösterilmiştir) kullanıldığı sayısallaştırma işleminin sonucunda şekil 3.76(a)'da gösterilen harita için;

- Ağaç obje türünün kapladığı Voronoi bölgelerinin alanı 1940.96 m²,
- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 2313.16 m²,
- Yol obje türünün kapladığı Voronoi bölgelerinin alanı 5745.88 m²

olarak elde edilmiştir (şekil 3.77).



Şekil 3.77 : Voronoi bölgelerinin sayısallaştırılması.

S, haritanın tüm alanı kabul edilerek Si, i=1,2,..N olarak mozaiklendirildiğinde eşitlik (2.5) kullanılarak Pi olasılıkları şöyle hesaplanır.

$$P_{ağaç} = \frac{1940.96}{10000}$$

$$P_{bina} = \frac{2313.16}{10000}$$

$$P_{yol} = \frac{5745.88}{10000}$$

Eşitlik (2.6) kullanılarak metrik bilgi miktarı $H(M)$ şöyle hesaplanır.

$$H(M) = H(P_1, P_2, \dots, P_n) = - \sum_{i=1}^n \frac{S_i}{S} (\ln S_i - \ln S)$$


$$= -(0.3182014476 - 0.338639809 - 0.3183803696)$$

$$= 0.9752216262 \approx 0.98$$

Şekil 3.76(b)'de gösterilen harita için de sayısallaştırma işlemi uygulanarak Voronoi bölgelerinin alanları hesaplanmıştır. Obje türlerinin Voronoi bölgeleri alanları:

- Ağaç obje türünün kapladığı Voronoi bölgelerinin alanı 2932.51 m²,
- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 3336.17 m²,
- Yol obje türünün kapladığı Voronoi bölgelerinin alanı 3731.32 m²

olarak elde edilmiştir (şekil 3.78).



Şekil 3.78 : Voronoi bölgelerinin sayısallaştırılması.

Eşitlik (2.5) kullanılarak obje türlerinin olasılıkları:

$$P_{ağaç} = \frac{2932.51}{10000}$$

$$P_{bina} = \frac{3336.17}{10000}$$

$$P_{yol} = \frac{3731.32}{10000}$$

olarak hesaplanmıştır.

Eşitlik (2.6) kullanılarak metrik bilgi miktarı:

$$= -(0.3597387381 - 0.3662319486 - 0.3678421205)$$

$$= 1.093812807 \approx 1.09 \text{ hesaplanmıştır.}$$

Uygulama sonuçları çizelge 3.17’de özetlenmiştir. Sonuçlara göre şekil 3.76(b) de gösterilen haritanın metrik bilgi miktarı şekil 3.76(a) gösterilen haritadan fazladır. Şekil 3.76(b)’de gösterilen haritada haritayı köşegen doğrultusunca kesen bir yol, yolun üst tarafında ağaçlar ve alt tarafında binalar yer almaktadır. Böylesi bir mekansal yerleşimin kullanıcı açısından daha akılda kalıcı olduğu düşünülebilir. Bu durum uygulama neticesinde elde edilen metrik bilgi miktarı ile de paralellik göstermektedir.

Çizelge 3.17 : Uygulama sonuçları.

		S_i		S_1/S	S_2/S	S_3/S	$H(M)$
Şekil 3.78(a)	1940.96	2313.16	5745.88	0.194	0.231	0.575	0.98
Şekil 3.78(b)	2932.51	3336.17	3731.32	0.293	0.334	0.373	1.09

Diğer yandan bölüm 3.2.1’de uygulaması yapılan istatistiksel bilgi miktarı değerlendirmesinin neticesinde, söz konusu iki haritanın da istatistiksel bilgisi eşit çıkmıştır. Ancak haritadaki işaret dağılımları dikkate alındığında, metrik bilgi miktarı değerlendirmesinin istatistiksel bilgi miktarı değerlendirmesinden daha uygun olduğu görülmektedir.

3.4.2 Farklı ölçekli haritaların karşılaştırılması

Bu bölümde, haritaların ölçeklerine göre metrik bilgi miktarlarının değişimi incelenecektir. Uygulamada farklı ölçeklerde dört harita kullanılmıştır.

Harita ölçekleri 1:25 000, 1:50 000, 1:100 000 ve 1:250 000’dir. Bu haritalar şekil 3.79, 3.81, 3.83 ve 3.85’de, Voronoi bölgeleri ise şekil 3.80, 3.82, 3.84 ve 3.86’da gösterilmiştir.



Şekil 3.79 : 1:25 000 ölçekli harita.



Şekil 3.80 : Haritanın Voronoi diyagramı.



Şekil 3.81 : 1:50 000 ölçekli harita.



Şekil 3.82 : Haritanın Voronoi diyagramı.



Şekil 3.83 : 1:100 000 ölçekli harita.



Şekil 3.84 : Haritanın Voronoi diyagramı.



Şekil 3.85 : 1:250 000 ölçekli harita.



Şekil 3.86 : Haritanın Voronoi diyagramı.

Haritaların metrik bilgi miktarlarının hesaplanabilmesi amacıyla obje türlerine ait Voronoi bölgelerinin alanına ve tüm haritanın alanına ihtiyaç vardır. Söz konusu alanların belirlenebilmesi için Netcad yazılımı kullanılmıştır. Yazılımda, haritalarda yer alan bina ve parsel obje türlerinin Voronoi bölgeleri sayısallaştırılarak alanları hesaplanmıştır.

Voronoi bölgeli raster formatlı haritalar Netcad yazılımına yüklenirken görüntülerin orijinal boyutları kullanılmıştır.

Her bir obje türü için farklı tabakaların ve farklı renklerin (bina-mavi, parsel-turuncu renk ile gösterilmiştir) kullanıldığı sayısallaştırma işleminin sonucunda 1:25 000 ölçekli harita için;

- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 13341.49 m²,
- Parsel obje türünün kapladığı Voronoi bölgelerinin alanı 41787.03 m²

olarak elde edilmiştir (şekil 3.87).



Şekil 3.87 : 1:25 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması.

S, haritanın tüm alanı kabul edilerek S_i, i=1,2,...N olarak mozaiklendirildiğinde eşitlik (2.5) kullanılarak P_i olasılıkları şöyle hesaplanır.

$$P_{bina} = \frac{13341.49}{55128.52}$$

$$P_{parsel} = \frac{41787.03}{55128.52}$$

Eşitlik (2.6) kullanılarak metrik bilgi miktarı H(M) şöyle hesaplanır.

$$H(M) = H(P_1, P_2, \dots, P_n) = - \sum_{i=1}^n \frac{S_i}{S} (\ln S_i - \ln S)$$

$$= 0.5533823819 \approx 0.55$$

1:50 000 ölçekli harita için;

- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 1352.57 m²,

- Parsel obje türünün kapladığı Voronoi bölgelerinin alanı 12429.43 m² olarak elde edilmiştir (şekil 3.88).



Şekil 3.88 : 1:50 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması.

Eşitlik (2.5) kullanılarak P_i olasılıkları:

$$P_{bina} = \frac{1352.57}{13782}$$

$$P_{parsel} = \frac{12429.43}{13782}$$

olarak hesaplanır.


Eşitlik (2.6) kullanılarak metrik bilgi miktarı $H(M)$:

$$= 0.3209775363 \approx 0.32 \text{ olarak hesaplanır.}$$

1:100 000 ölçekli harita için;

- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 363.81 m²,
- Parsel obje türünün kapladığı Voronoi bölgelerinin alanı 3081.69 m²

olarak elde edilmiştir (şekil 3.89).



Şekil 3.89 : 1: 100 000 ölçekli haritanın Voronoi bölgelerinin sayısallaştırılması.

Eşitlik (2.5) kullanılarak P_i olasılıkları:

$$P_{bina} = \frac{363.81}{3445.50}$$

$$P_{parsel} = \frac{3081.69}{3445.50}$$

olarak hesaplanır.

Eşitlik (2.6) kullanılarak metrik bilgi miktarı $H(M)$:

= 0.33719444 $\approx$ 0.34 olarak hesaplanır.

1:250 000 ölçekli harita için;

- Bina obje türünün kapladığı Voronoi bölgelerinin alanı 56.02 m²,
- Parsel obje türünün kapladığı Voronoi bölgelerinin alanı 495.29 m²

olarak elde edilmiştir (şekil 3.90).



Şekil 3.90 : 1 : 250 000 ölçekli harita.

Eşitlik (2.5) kullanılarak P_i olasılıkları:

$$P_{bina} = \frac{56.02}{551.31}$$

$$P_{parsel} = \frac{495.29}{551.31}$$

olarak hesaplanır.

Eşitlik (2.6) kullanılarak metrik bilgi miktarı $H(M)$:

= 0.3286116711 $\approx$ 0.33 olarak hesaplanır.

Metrik bilgi için elde edilen sonuçlar çizelge 3.18’de özetlenmiştir.

Çizelge 3.18 : Farklı ölçekteki haritaların metrik bilgi miktarları.

Ölçek	S_i	S_1	S_1/S	S_2/S	$H(M)$
1:25 000	13341.49	41787.03	0.242	0.758	0.55
1:50 000	1352.57	12429.43	0.098	0.902	0.32
1:100 000	363.81	3081.69	0.106	0.894	0.34
1:250 000	56.02	495.29	0.102	0.898	0.33

Genelleştirme sürecinde istatistiksel bilgi miktarının değişiminin incelenmesi konusuna da uygulama teşkil etmesi bakımından istatistiksel bilgi miktarlarının da hesabı yapılmış, böylece her iki yöntemin karşılaştırılması yapılmıştır.

Haritaların istatistiksel bilgi miktarlarının hesaplanması amacıyla her bir haritadaki obje türü sayısı ve bu obje türlerine ait obje sayıları belirlenmiştir.

Haritalardaki obje sayıları manuel olarak sayılmış ve aşağıdaki değerler elde edilmiştir.

- 1:25 000 ölçekli harita için 134 bina, 62 parsel,
- 1:50 000 ölçekli harita için 5 bina, 58 parsel,
- 1:100 000 ölçekli harita için 6 bina, 5 parsel,
- 1:250 000 ölçekli harita için 2 bina, 3 parsel

(2.2) ve (2.3) eşitlikleri kullanılarak haritaların istatistiksel bilgi miktarları hesaplanmış ve çizelge 3.19’da özetlenmiştir.

Çizelge 3.19 : Farklı ölçekteki haritaların istatistiksel bilgi miktarları.

Ölçek	M		N	P ₁	P ₂	H(X)
1:25 000	134	62	196	0.684	0.316	0.62
1:50 000	5	58	63	0.079	0.921	0.28
1:100 000	6	5	11	0.545	0.454	0.68
1:250 000	2	3	5	0.400	0.600	0.68

3.4.3 Aynı bölgeye ait haritanın farklı genelleştirme sonuçlarının karşılaştırılması

Uygulamada 1:10 000 ölçekli haritanın farklı kurumlar tarafından 1:25 000 ölçeğe genelleştirilmesi ile elde edilen sonuçları incelenmiştir (Spiess, 1983). Uygulamaya katılan kurumlar: National Geographic Institute of Belgium (IGN Brussels), Geographical Survey of Norway (NGO Oslo), National Board of Survey of Finland (NBS Helsinki), State Survey of Baden-Wurttemberg, FRG (LVA Stuttgart), Institute for Applied Geodesy, Frankfurt, FRG (IfAG), Topographic Service, Delft, the Netherlands (TD Delft) ve Federal Office for Topography, Wabern, Switzerland (LT Wabern)’dir. Kurumların kullandıkları 1:10 000 ölçekli topoğrafik harita şekil 3.91’de, genelleştirme sonucu ürettikleri 1:25 000 ölçekli harita örnekleri şekil 3.92’de gösterilmiştir. Şekildeki haritalar sıralı rakamlar ile adlandırılmıştır.


Uygulamada kullanılan ve şekil 3.92’de gösterilen haritalar farklı sayıda harita işareti içermektedir. Haritaların metrik bilgilerinin belirlenmesi amacıyla bina ve yol objelerinin Voronoi diyagramlarının çizdirilmesine ve Voronoi alanlarının belirlenmesine ihtiyaç vardır. Voronoi diyagramlarının çizdirilmesi ve söz konusu diyagramların alanlarının belirlenmesi için Netcad yazılımı kullanılmıştır. Yazılımda bina ve yol objeleri için Voronoi bölgeleri

oluşturulmuştur. Her bir Voronoi bölgesinin içerisinde bir adet obje yer almaktadır. Obje gösterimlerinde binalar için mavi, yollar için kırmızı, Voronoi bölgeleri için gri renk tercih edilmiştir. Bina obje türünün Voronoi bölgelerinin gösteriminde de pembe renk tercih edilmiştir.

Farklı kurumlar tarafından genelleştirilen sekiz farklı haritanın tüm objelerini içine alabilecek ortak bir çerçevenin belirlenmesi amacıyla detayları çizelge 3.20’de gösterilen hesap alanları belirlenmiştir. Bu durumda tüm haritaların Voronoi diyagramlarının çiziminde kullanılan ortak hesap alanı $234.998 \times 180.348 = 42381.419 \text{ m}^2$ olarak belirlenmiştir.

Çizelge 3.20 : Haritaların ortak hesap alanlarının belirlenmesi.

Harita Adı	Genişlik (m)	Yükseklik (m)	Harita Alanı (m ²)
1	230.668	175.782	40547.282
2	232.288	176.541	41008.356
3	232.093	179.088	41565.071
4	232.564	180.338	41940.127
5	230.579	179.579	41407.146
6	234.998	179.205	42112.817
7	232.495	179.193	41661.477
8	234.657	180.348	42319.921



Şekil 3.91 : 1 : 10 000 ölçekli topoğrafik harita.



Harita #1



Harita #2



Harita #3



Harita #4



Harita #5



Harita #6



Harita #7



Harita #8

Şekil 3.92 : Farklı kurumlar tarafından genelleştirilen haritalar.

1 Numaralı Harita



Şekil 3.93 : 1 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3661484246 - 0.3085060391)$$

$$= 0.6746544637 \approx 0.675$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

2 Numaralı Harita



Şekil 3.94 : 2 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3672326817 - 0.2778818851)$$

$$= 0.6451145668 \approx 0.645$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

3 Numaralı Harita



Şekil 3.95 : 3 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3677343909 - 0.2954706532)$$

$$= 0.6632050441 \approx 0.663$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

4 Numaralı Harita



Şekil 3.96 : 4 numaralı haritaya ait Voronoi bölgeli sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3676246808 - 0.2824274631)$$

$$= 0.6500521439 \approx 0.650$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

5 Numaralı Harita



Şekil 3.97 : 5 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3676426329 - 0.2969855012)$$

$$= 0.6646281341 \approx 0.665$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

6 Numaralı Harita



Şekil 3.98 : 6 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3658002247-0.3102025007)$$

$$= 0.6760027254 \approx 0.676$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

7 Numaralı Harita



Şekil 3.99 : 7 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3585181828-0.2418969197)$$

$$= 0.6004151025 \approx 0.600$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

8 Numaralı Harita



Şekil 3.100 : 8 numaralı haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

$$= -(-0.3647222406 - 0.3146223354)$$

$$= 0.679344576 \approx 0.679$$

Uygulama sonuçları çizelge 3.21’de özetlenmiştir.

Çizelge 3.21 : Farklı kurumlarca genelleştirilen haritaların metrik bilgileri (Harita alanı (S): 42381.419 m2).

Harita No	Bina Sayısı	Binaların Voronoi Alanı [m ²] S_1	Yolların Voronoi Alanı [m ²] S_2	$\frac{S_1}{S}$	$\frac{S_2}{S}$	Metrik Bilgi	Genelleştirilmiş Harita
1	28	17128.009	25253.41	0.404	0.596	0.675	
2	26	14675.919	27705.500	0.346	0.654	0.645	
3	28	16031.124	26350.295	0.378	0.622	0.663	
4	33	15014.621	27366.798	0.354	0.646	0.650	

Harita No	Bina Sayısı	Binaların Voronoi Alanı [m ²] S_1	Yolların Voronoi Alanı [m ²] S_2	$\frac{S_1}{S}$	$\frac{S_2}{S}$	Metrik Bilgi	Genelleştirilmiş Harita
5	28	16154.013	26227.406	0.381	0.619	0.665	
6	29	17278.024	25103.395	0.408	0.592	0.676	
7	26	12208.842	30172.577	0.288	0.712	0.600	
8	28	17678.036	24703.383	0.417	0.583	0.679	

Sonuç olarak, genelleştirilmiş haritaların metrik bilgi miktarları sıralamasında, metrik bilgisi en yüksek harita 8 numaralı harita olarak belirlenmiştir.

8 numaralı harita, göreceli olarak diğer örneklerle karşılaştırıldığında, haritanın oldukça sade ve okunaklı tasarlandığı düşünülmektedir. Kurumların ürettikleri sekiz haritada 26 ile 33 arasında bina yer almaktadır. Uygulamada kullanılan sekiz haritanın dördünde 28 adet bina yer almaktadır. 8 numaralı haritada da 28 adet bina yer almaktadır. Binaların arasında haritanın köşegeni boyunca uzanan bir yolun olmadığı, binaların birbirlerinden uzakta konumlandığı ve binalar arası uzaklıkların fazla olduğu görülmektedir.

8 numaralı haritadan sonra metrik bilgisi en yüksek ikinci harita 6 numaralı harita olmuştur. Bu harita incelendiğinde de 8 numaralı harita gibi sade ve objeler arası uzaklıkların göreceli olarak fazla olduğu görülmektedir. 6 numaralı haritada da 29 adet bina yer almaktadır.

Objelerin etrafında yer alan boşlukları hesaba kattığı için, metrik yöntemin, sadelik ve okunaklılık yönlerinden başarılı olarak çalıştığı düşünülmektedir.

Bir Kartograf ile gerçekleştirilen kişisel görüşmede ve Kartograf tarafından yapılan karşılaştırmada da 8 numaralı genelleştirme örneği başarılı seçilmiştir (Uluğtekin, kişisel görüşme, 5 Eylül 2011). Ancak bu haritalar arasındaki genelleştirmenin karşılaştırılması oldukça zordur. Çünkü üretilen genelleştirilmiş haritalar, uygulamanın başlangıç kısmında yer verilen, harita serileri üretmek konusunda oldukça başarılı ve deneyimli olan kurumlarca üretilmiştir. Ancak, bütün genelleştirme çözümlerinin aynı olmaması, aralarında farklılıklar bulunması durumu, genelleştirmenin objektif olmamasından, yapan kurum veya kişilere bağımlı olmasından kaynaklanmaktadır.


İşte tam da bu noktada, hangi çözümün ideal olduğu konusuna standart bir çözüm bulma aşamasında metrik yöntemin kullanılması önerilmektedir. Yazılımların ve kartografların farklı genelleştirme sonuçları ürettiği noktada metrik yöntem, üretilen haritaların genelleştirme sonuçlarının karşılaştırılmasında kullanılabilir.

3.4.4 Farklı yöntemler ile genelleştirilen haritaların karşılaştırılması


Uygulamada, Aslan (2011) tarafından çalışılan 1:25 000 ölçekli bir haritanın mesafe, Açık ve Ağ temelli basitleştirme yöntemleri ile 1:100 000 ölçeğe genelleştirilmesi ile

elde edilen sonuçları incelenmiştir. Metrik bilgi yöntemi ile bu uygulamanın yapılmasının amacı, yazar tarafından geliştirilen algoritmanın kartografik genelleştirme sonuçlarının değerlendirilmesi amacıyla kullanılabileceğini göstermektir. Yazar, bu çalışmada binaların kartografik genelleştirmesinin otomatik olarak yapılmasına katkı sağlamak amacıyla yukarıda sözü edilen üç yöntemi araştırmıştır. Tez çalışması sonucunda da mesafe yönteminin kullanımını önermiştir.

Uygulamada kullanılan 1:25 000 ölçekli harita şekil 3.101’de gösterilmiştir. Mesafe, açı ve ağ temelli basitleştirme yöntemleri kullanılarak Aslan (2011) tarafından üretilen genelleştirilmiş 1:100 000 ölçekli harita örnekleri şekil 3.102’de gösterilmiştir.



Şekil 3.101 : 1 : 25 000 ölçekli orijinal harita.



Şekil 3.102 : (a) Mesafe yöntemi, (b) Açı yöntemi, (c) Ağ temelli basitleştirme yöntemi ile genelleştirilen 1: 100 000 ölçekli haritalar (a₁, b₁, c₁: 1:100.000 ölçekli gösterim, a₂, b₂, c₂: 4 kat büyütülmüş 1:100.000 ölçekli gösterim) (Aslan, 2011).

Uygulamada kullanılan ve şekil 3.102’de gösterilen genelleştirilmiş haritalar farklı sayıda bina içermektedir. Haritaların metrik bilgilerinin belirlenmesi amacıyla sayısal ortamda bina ve yol objelerinin Voronoi diyagramları çizdirilmiş ve Voronoi alanları belirlenmiştir. Mesafe yöntemi ile genelleştirilmiş harita, haritanın Voronoi bölgesi sayısal çizimi ve Voronoi alanları gösterimi şekil 3.103’de, açı yöntemi için gösterimler şekil 3.104’de ve ağ temelli basitleştirme yöntemi için gösterimler şekil 3.105’de gösterilmiştir.

3.4.4.1 Mesafe yöntemi



Şekil 3.103 : Mesafe yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

= $4.102838717 \approx 4.103$ bulunmuştur. Hesaplamaya ilişkin tüm Voronoi bölgeleri alanları ve metrik bilgi miktarlarına ilişkin hesap detayları çizelge 3.22’de yer almaktadır.

Söz konusu üç yöntemin uygulama sonuçları çizelge 3.25’de özetlenmiştir.

Çizelge 3.22 : Uygulama hesap detayları.

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
1	6.667	0.0039474	0.021847750
2	7.565	0.0044791	0.024224504
3	40.334	0.0238811	0.089187927
4	7.400	0.0043814	0.023792765
5	9.108	0.0053927	0.028164475
6	54.618	0.0323384	0.110969209
7	28.042	0.0166032	0.068042553
8	35.234	0.0208615	0.080730752
9	12.717	0.0075295	0.036811256
10	9.474	0.0056094	0.029075249
11	24.068	0.0142503	0.060577562
12	17.785	0.0105302	0.047949345
13	12.905	0.0076408	0.037243320
14	16.424	0.0097244	0.045054187
15	33.757	0.019987	0.078202455
16	10.650	0.0063057	0.031946517
17	10.822	0.0064075	0.032359804
18	9.218	0.0054578	0.028439104
19	11.347	0.0067184	0.033611388
20	11.974	0.0070896	0.035087340
21	9.195	0.0054442	0.028381746
22	7.565	0.0044791	0.024224504
23	9.397	0.0055638	0.028884345
24	6.535	0.0038693	0.021492563
25	8.697	0.0051493	0.027131319
26	8.500	0.0050327	0.026632064
27	7.123	0.0042174	0.023063042
28	8.421	0.0049859	0.026431099
29	16.939	0.0100293	0.046157277
30	20.933	0.0123941	0.054416646

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
31	9.448	0.005594	0.029010830
32	12.816	0.0075881	0.037038982
33	36.383	0.0215418	0.082672148
34	46.784	0.0277	0.099341189
35	18.947	0.0112182	0.050372159
36	18.973	0.0112336	0.050425877
37	14.715	0.0087125	0.041323370
38	13.189	0.007809	0.037892944
39	16.669	0.0098694	0.045580132
40	11.406	0.0067533	0.033751131
41	16.038	0.0094958	0.044221152
42	12.166	0.0072033	0.035535370
43	11.836	0.0070079	0.034764194
44	15.776	0.0093407	0.043652598
45	13.048	0.0077255	0.037570877
46	15.576	0.0092223	0.043216856
47	14.918	0.0088327	0.041772426
48	13.828	0.0081873	0.039341475
49	15.746	0.0093229	0.043587333
50	18.387	0.0108866	0.049209970
51	62.750	0.0371532	0.12233458
52	25.303	0.0149815	0.062936305
53	12.553	0.0074324	0.036433006
54	16.201	0.0095923	0.044573590
55	11.284	0.0066811	0.033461971
56	10.250	0.0060689	0.030978977
57	11.199	0.0066307	0.033260046
58	16.378	0.0096971	0.044955198
59	11.921	0.0070582	0.034963345
60	35.629	0.0210953	0.081400626

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
61	21.950	0.0129962	0.056443857
62	37.399	0.0221433	0.084370900
63	58.418	0.0345883	0.116363366
64	63.265	0.0374581	0.123032430
65	32.101	0.0190065	0.075322154
66	52.044	0.0308144	0.107227060
67	84.452	0.0500026	0.149791813
68	126.930	0.0751531	0.194513371
69	15.493	0.0091731	0.043035578
70	7.376	0.0043672	0.023729786
71	12.967	0.0076775	0.037385452
72	6.104	0.0036141	0.020321654
73	8.091	0.0047905	0.025586832
74	8.507	0.0050369	0.026649850
75	13.523	0.0080067	0.038652311
76	11.228	0.0066479	0.033328981
77	8.278	0.0049013	0.026066208
78	9.460	0.0056011	0.029040567
79	7.105	0.0042068	0.023015405
80	8.185	0.0048462	0.025828118
81	35.263	0.0208786	0.080780021
82	27.282	0.0161532	0.066642279
Σ 1688.952		4.102838717	
		≈ 4.103	

3.4.4.2 Açı yöntemi



Şekil 3.104 : Açı yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgesi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

= $3.944090197 \approx 3.944$ bulunmuştur. Hesaplamaya ilişkin tüm Voronoi bölgeleri alanları ve metrik bilgi miktarlarına ilişkin hesap detayları çizelge 3.23’de yer almaktadır.

Söz konusu üç yöntemin uygulama sonuçları çizelge 3.25’de özetlenmiştir.

Çizelge 3.23 : Uygulama hesap detayları.

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
1	8.099	0.0048657	0.025912575
2	10.755	0.0064614	0.032577745
3	7.202	0.0043268	0.023550533
4	9.519	0.0057188	0.029531963
5	7.670	0.004608	0.024790783
6	6.266	0.0037645	0.021013908
7	10.415	0.0062571	0.031748860
8	10.371	0.0062307	0.031641109
9	10.059	0.0060432	0.030873817
10	13.241	0.0079549	0.038453829
11	11.826	0.0071048	0.035147429
12	13.098	0.007869	0.038123982
13	14.732	0.0088507	0.041839511
14	12.251	0.0073602	0.036150684
15	69.958	0.0420294	0.133207307
16	31.129	0.0187017	0.074416634
17	26.232	0.0157597	0.065407342
18	28.352	0.0170333	0.069369601
19	37.804	0.0227119	0.085961461
20	15.543	0.0093379	0.043642382
21	9.015	0.005416	0.028262973
22	9.107	0.0054713	0.028495850
23	7.119	0.004277	0.023328699
24	6.375	0.00383	0.021313403
25	8.514	0.005115	0.026984753
26	75.971	0.0456419	0.140893211
27	31.157	0.0187185	0.074466742
28	29.690	0.0178372	0.071820802
29	11.782	0.0070784	0.035043044
30	18.732	0.0112538	0.050496391

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
31	10.440	0.0062721	0.031810032
32	7.430	0.0044638	0.024156969
33	14.078	0.0084578	0.040366180
34	157.258	0.0944775	0.222909539
35	27.615	0.0165905	0.068003333
36	22.800	0.0136978	0.058770628
37	46.718	0.0280672	0.100288513
38	70.078	0.0421015	0.133363644
39	16.266	0.0097723	0.045228143
40	10.221	0.0061406	0.031272933
41	14.832	0.0089108	0.042063234
42	16.261	0.0097693	0.045217244
43	17.723	0.0106476	0.048365960
44	8.647	0.0051949	0.027325766
45	11.019	0.00662	0.033216885
46	13.593	0.0081664	0.039261829
47	12.365	0.0074286	0.036418273
48	68.192	0.0409684	0.130892131
49	27.561	0.0165581	0.067902766
50	24.253	0.0145707	0.061615791
51	16.057	0.0096467	0.044771764
52	15.398	0.0092508	0.043321950
53	12.541	0.0075344	0.036830154
54	13.830	0.0083088	0.039802757
55	8.698	0.0052256	0.027456204
56	14.058	0.0084458	0.040320841
57	13.652	0.0082018	0.039396721
58	17.001	0.0102139	0.046820432
59	18.416	0.011064	0.049832776
60	79.592	0.0478173	0.145382130

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
61	56.349	0.0338533	0.114617870
62	36.059	0.0216635	0.083017338
63	14.736	0.0088531	0.041848468
64	13.224	0.0079447	0.038414666
65	11.439	0.0068723	0.034225902
66	6.904	0.0041478	0.022751349
67	7.634	0.0045864	0.024696002
68	25.421	0.0152724	0.063864802
69	14.261	0.0085677	0.040780246
70	38.133	0.0229095	0.086511051
71	31.708	0.0190495	0.075449719
72	32.823	0.0197194	0.077421368
73	7.235	0.0043466	0.023638571
Σ 1664.503			3.944090197
			≈ 3.944

3.4.4.3 Ağ temelli basitleştirme yöntemi



Şekil 3.105 : Ağ temelli basitleştirme yöntemi ile genelleştirilmiş haritaya ait Voronoi bölgeyi sayısal çizimler ve alan gösterimleri.

Eşitlik 2.6 kullanılarak hesaplanan metrik bilgi miktarı:

= 4.082217965 $\approx$ 4.082 bulunmuştur. Hesaplamaya ilişkin tüm Voronoi bölgeleri alanları ve metrik bilgi miktarlarına ilişkin hesap detayları çizelge 3.24’de yer almaktadır.

Söz konusu üç yöntemin uygulama sonuçları çizelge 3.25’de özetlenmiştir.




Çizelge 3.24 : Uygulama hesap detayları.

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
1	65.782	0.0393503	0.127308157
2	10.397	0.0062194	0.031595101
3	12.109	0.0072435	0.035693501
4	35.433	0.0211958	0.081687496
5	11.248	0.0067285	0.033651828
6	8.983	0.0053736	0.028083669
7	11.104	0.0066423	0.033306594
8	8.381	0.0050135	0.026549396
9	6.474	0.0038727	0.021508213
10	11.075	0.006625	0.033236933
11	10.102	0.0060429	0.030872575
12	17.023	0.010183	0.046709909
13	9.564	0.0057211	0.029541503
14	7.776	0.0046515	0.024981390
15	9.935	0.005943	0.030461277
16	35.032	0.0209559	0.081001541
17	10.163	0.0060794	0.031022397
18	10.129	0.0060591	0.030938917
19	10.649	0.0063702	0.032208339
20	10.110	0.0060477	0.030892236
21	6.539	0.0039116	0.021685082
22	12.065	0.0072172	0.035590075
23	7.091	0.0042418	0.023171899
24	7.559	0.0045217	0.024412229
25	8.733	0.005224	0.027449539
26	6.077	0.0036352	0.020419330
27	7.668	0.0045869	0.024698580
28	6.469	0.0038697	0.021494592
29	92.387	0.0552652	0.160026631
30	14.235	0.0085153	0.040582890

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
31	34.584	0.0206879	0.080231937
32	114.614	0.0685613	0.183746075
33	12.739	0.0076204	0.037164042
34	7.943	0.0047514	0.025416935
35	14.479	0.0086612	0.041131313
36	19.303	0.0115469	0.051514677
37	15.681	0.0093803	0.043797822
38	12.193	0.0072938	0.035890684
39	7.452	0.0044577	0.024130218
40	6.255	0.0037417	0.020909405
41	10.643	0.0063666	0.032193780
42	5.348	0.0031991	0.018378629
43	6.331	0.0037872	0.021117722
44	8.133	0.0048651	0.025909914
45	8.709	0.0052097	0.027388439
46	12.869	0.0076981	0.037465136
47	11.493	0.006875	0.034236679
48	19.053	0.0113974	0.050996068
49	27.262	0.0163079	0.067125134
50	52.173	0.0312095	0.108204383
51	82.836	0.0495519	0.148890300
52	52.921	0.031657	0.109305060
53	42.348	0.0253323	0.093113212
54	13.620	0.0081474	0.039189397
55	11.018	0.0065909	0.033099881
56	11.437	0.0068415	0.034103276
57	13.839	0.0082784	0.039687483
58	11.484	0.0068696	0.034215250
59	10.223	0.0061153	0.031169548
60	11.384	0.0068098	0.033976870

Vor. Alan No	Vor. Alanı [m ²]	$\frac{S_i}{S}$	Metrik Bilgi
61	72.556	0.0434025	0.136163924
62	11.803	0.0070605	0.034972224
63	7.052	0.0042185	0.023067721
64	14.148	0.0084632	0.040386743
65	8.667	0.0051845	0.027281419
66	10.542	0.0063061	0.031948397
67	9.893	0.0059179	0.030357573
68	11.047	0.0066082	0.033169631
69	14.948	0.0089418	0.042178579
70	12.672	0.0075803	0.037008553
71	12.701	0.0075976	0.037075880
72	10.326	0.0061769	0.031421668
73	23.153	0.01385	0.059270518
74	13.167	0.0078764	0.038152385
75	12.017	0.0071885	0.035477138
76	14.081	0.0084232	0.040235470
77	11.912	0.0071257	0.035229687
78	14.057	0.0084088	0.040181236
79	41.730	0.0249626	0.092121349
80	40.672	0.0243297	0.090410550
81	22.107	0.0132242	0.057204168
82	53.866	0.0322223	0.110686589
83	41.172	0.0246288	0.091221082
84	14.250	0.0085242	0.040616676
85	24.504	0.0146581	0.061897719
Σ 1671.702		4.082217965	
		≈ 4.082	

Çizelge 3.25 : Üç farklı yöntem ile geliştirilen haritaların metrik bilgileri.

Genelleştirme Yöntemi	Bina Sayısı	Binaların Voronoi Alanı (S_i) [m ²]	Metrik Bilgi	Genelleştirilmiş Harita
Mesafe yöntemi	82	1688.952	4.103	
Açı yöntemi	74	1664.503	3.944	
Ağ temelli basitleştirme yöntemi	85	1671.702	4.082	

Sonuç olarak, geliştirilmiş haritaların metrik bilgi miktarları sıralamasında, metrik bilgisi en yüksek harita mesafe yöntemi ile geliştirilen harita olarak belirlenmiştir. Uygulamada kullanılan yöntemler arasından, yazar Aslan (2011)'in tez çalışması sonucunda da mesafe yönteminin kullanımı önerilmiştir.

Mesafe yöntemi ile geliştirilen haritada 82 adet bina yer almaktadır. Açı ve ağ temelli basitleştirme yöntemleri ile geliştirilen haritalarda sırasıyla 74 ve 85 adet bina yer almaktadır. Metrik yöntemde bilgi miktarının artmasındaki önemli faktör, Voronoi bölgelerinin alanlarının birbirleri ile yaklaşık olarak eşit olmasıdır. Bu

durum Voronoi bölgelerini oluşturan ve içlerinde yer alan binaların aralarındaki mesafelerin yaklaşık eşit olmasını, homojen dağılmasını gerektirir. Uygulamada kullanılan haritalara bakıldığında binalar arasındaki mesafe farklılıklarının ve homojen dağılımın göz ile ayırt edilmesinin oldukça zor olduğu da bir gerçektir. Ancak sayısal ortamda çizdirilen Voronoi bölgeleri ve metrik yöntem eşitliği ile bu durumu kesin olarak sağlamaktadır.

Mesafe yöntemi ile genelleştirilen haritadan sonra metrik bilgisi en yüksek ikinci harita ağ temelli basitleştirme yöntemi ile genelleştirilen harita olmuştur. Her iki harita da incelendiğinde bina sayılarının yaklaşık olarak eşit olduğu görülmektedir. Metrik yöntemde bina sayıları doğrudan hesaba girmese de binalara ait Voronoi diyagramlarının alanlarında etkilidir.

Objeleri ve etrafında yer alan boşlukları hesaba kattığı için, metrik yöntemin, sadelik ve okunaklılık yönlerinden bu uygulamada da başarılı olarak çalıştığı düşünülmektedir.

Metrik yöntemin sonuçları, Töpfer (1974)'ün seçme kuralı, $(N_f = N_i \sqrt{M_i / M_f})$ ile de irdelenmiştir. Burada, N_i , kaynak haritadaki obje sayısını, N_f , türetme haritadaki obje sayısını, M_i , kaynak haritanın ölçek modülünü, M_f türetme haritanın ölçek modülünü göstermektedir.

Uygulamada kullanılan 1:25 000 ölçekli orijinal haritada 340 adet bina yer almaktadır. 1:25 000 ölçekli orijinal haritadan, mesafe yöntemi ile genelleştirilen 1:100 000 ölçekli haritada 82, açı yöntemi ile genelleştirilen 1:100 000 ölçekli haritada 74 ve ağ temelli basitleştirme yöntemi ile genelleştirilen 1:100 000 ölçekli haritada 85 adet bina yer almaktadır.

Genelleştirmede hedef ölçekte olması gereken obje sayısının belirlenmesinde genellikle Töpfer ve Pillewizer tarafından geliştirilen formül kullanılmaktadır (Aslan, 2011). Töpfer (1974)'ün seçme kuralına göre 1:25 000 ölçekten 1:100 000 ölçeğe genelleştirilen bir haritada 85 adet bina yer almalıdır. Kullanılan yöntemler arasında, Töpfer kuralında hedef ölçekte olması gereken obje sayısını tam olarak sağlayan yöntem ağ temelli basitleştirme yöntemidir. Bunun sebebi, ağ temelli basitleştirme yönteminin iş akışında Töpfer kuralını bir kriter olarak ele alması ve işlemlerinde sürekli olarak hedef ölçekte olması gereken nesne sayısını hesaplaması ve işlem

adımları bu sayıya ulaşana kadar tekrarlamasıdır (Aslan, 2011). Mesafe yöntemindeki obje sayısı da Töpfer kuralı ile hesaplanan obje sayısına yakındır.

Töpfer yasasının yalnız obje sayısı ile sonuç vermesi, obje niteliği ve dağılımı konusunda bilgi vermemesi nedeniyle günümüzde başka kartografik genelleştirme değerlendirme algoritmalarının geliştirilmesi gerekmektedir. Doktora çalışmasında önerilen yöntem bu tür bir eksikliği gidermek yolunda yapılan bir çalışma olarak da değerlendirilmelidir.

Otomatik genelleştirme çalışmaları ümit verici sonuçlar doğurmuştur (Mackaness ve diğ., 2007). Bununla beraber, otomatik genelleştirme çözümleri konusunda ticari yazılımlar geliştiren kurumlar birkaç nedenden dolayı zorluklarla karşılaşmaktadırlar (Stoter, 2005). İlk olarak harita özelliklerinin yapısal tanımı eksiktir. Genel olarak tatmin edici, örneğin detayları azaltan, bölgesel yapıyı ayırt eden, belirli bir konuda kullanıcıları ile başarılı iletişim sağlayan, estetik açıdan güzel görünen bir genelleştirme çözümü elde edilebilmektedir (Mackaness ve Ruas, 2007).

Yazılımların ve kartografların farklı genelleştirme sonuçları ürettiği noktada metrik yöntem, üretilen haritaların genelleştirme sonuçlarının karşılaştırılmasında kullanılabilir.

4. SONUÇ ve ÖNERİLER

İstatistiksel yöntem üzerine gerçekleştirilen uygulamalarda, bu yöntemin haritada yer alan objelerin mekansal dağılımlarını dikkate almadığı, sadece obje sayıları ile ilişkili nicel değerler sunduğu tespit edilmiştir. İstatistiksel yöntemin hesap algoritmasını oluşturan entropi teoreminde obje sayıları temel bileşendir. Bu nedenle çalışma verisi olarak seçilen analog haritalar ve uydu görüntü haritaları üzerinde obje sayılarının gerçekçi olarak belirlenmesine yönelik olarak kullanılabilir. Bu bağlamda ilk olarak Matlab yazılımı görüntü işleme modülünde kenar belirleme yöntemleri araştırılmıştır. Kenar belirleme yöntemlerinin araştırılması, görüntü üzerinde obje kenarlarının tam olarak belirlenerek vektör formatlı kapalı bir alan objesi (polygon) elde edilmesi ve bu objelerin yazılıma kolaylıkla saydırılması varsayımından ve literatürde incelenen benzer çalışmalardan kaynaklanmaktadır. Önceki bölümlerde kenar belirleme yöntemlerinden Sobel, Prewitt, Roberts, Laplacian of Gaussian, Zero-Cross ve Canny yöntemleri tanıtılmıştır. Söz konusu yöntemler farklı spektral özelliklere sahip görüntüler ve yüksekliğe oranlı renklendirilmiş Orbview uydusu görüntüsü üzerinde test edilmiştir. Sonuçlarda, söz konusu altı yöntem içerisinde en başarılı yöntemin Canny yöntemi olduğu görülmüştür. Canny yöntemi neticesinde üretilen görüntüde, binaların kenarları belirgin bir şekilde algılanmıştır. Ancak kenarlar poligonlar biçiminde belirlenememiş ve binalar kapalı alanlı objeler biçiminde elde edilememiştir.

Kenar belirleme yöntemlerinin test edilmesi ve sonuçlarının eldesinden sonra eşik değer (thresholding) yöntemleri araştırılmış ve uygulamalarla test edilmiştir. Eşik değer yöntemlerinin araştırılması, binaların çatı renklerinin doğadaki diğer renklerden ayrılabilceği ve obje olarak saydırılabileceği varsayımından kaynaklanmaktadır. Eşik değer yöntemi uygulamaları için Matlab yazılımının görüntü işleme modülü kullanılmıştır. Temel, bant ve yüzde eşik değer yöntemleri ile farklı spektral özelliklerdeki görüntüler üzerinde testler gerçekleştirilmiştir. Eşik değer yöntemi uygulamalarının ilk bölümünde, görüntüdeki piksellerin gri ton değerlerinin belirlenen tek bir gri tonu eşik değerinden büyük olup olmaması koşulu

ile pankromatik ve multispektral görüntüler üzerinde testler uygulanmıştır. Eşik değeri yöntemi uygulamalarının ikinci bölümünde ise görüntüde yer alan piksellerin gri tonu değerlerinin belirlenen bir gri tonu aralığının dışına çıkıp çıkmadığı koşulu ile uygulamalar yapılmıştır.

Eşik değeri yönteminin uygulama sonuçlarında Gri tonu aralığının, tek bir gri tonu koşulundan daha başarılı olduğu tespit edilmiştir. Ayrıca eşik değeri yönteminin multispektral görüntüler üzerinde pankromatik görüntülerden daha başarılı çalıştığı kanaatine varılmıştır.

Kenar belirleme ve eşik değeri yöntemlerinin test edilmesinden ve sonuçlarının eldesinden sonra sınıflandırma yöntemleri test edilmiştir. Bu bağlamda farklı görüntüler üzerinde kontrollü ve kontrolsüz sınıflandırma yöntemleri uygulanmıştır. Kontrolsüz sınıflandırma yöntemi'nde, görüntü üzerinde yer alan ve yazılım tarafından bina olarak algılanan objelere daha net ölçütler getirerek uygulama başarısını artırmak amacıyla K-ortalama değeri algoritmaları (K-Means) ile çalışılmıştır. Bu kapsamda görüntüler sınıflara ayrılarak bina olabilecek objelere alan ölçütü getirilmiş ve uygulamalar yapılmıştır. K-ortalama değeri uygulamaları neticesinde binalar sınıf bazında saydırılmıştır. Ancak farklı ölçütler ilave edilerek daha başarılı sonuçlarla bina saydırabilmek için kontrollü sınıflandırma yöntemi uygulamalarına geçilmiştir. Bu uygulamalarda sınıflandırma öncesi görüntü üzerinde eğitim verileri belirlenmiş ve yazılıma yüklenerek test verileri elde edilmiştir. Uygulamalarda iki yazılım kullanılmıştır. Yazılımlardan ilki Purdue Üniversitesi Elektronik ve Bilgisayar Mühendisliği Bölümünden Profesör David Landgrebe ve ileri programlama merkezi sistem yöneticisi Larry Biehl tarafından, Uzaktan Algılama Uygulamaları Laboratuvarı, Purdue Bilgi Teknolojileri ve NASA'nın desteğiyle yazılan MultiSpec yazılımıdır. MultiSpec yazılımında gerçekleştirilen sınıflandırma uygulamalarında başarılı sonuçlara ulaşılmıştır.

MultiSpec yazılımından sonra, son yıllarda obje tanıma uygulamalarında daha yaygın olarak kullanılmaya başlanan, yine eğitimci bir sınıflandırma algoritması olan destek vektör makineleri (DVM) yöntemi ve lineer olmayan verinin sınıflandırılması için geliştirilen bir yöntem olan destek vektör seçme ve adaptasyon (DVSA) yöntemi araştırılmıştır. Bu amaçla DVSA algoritmasına eğitim ve test verisi hazırlayan, DVSA yöntemi ile sınıflandırılan görüntüdeki piksellerin koordinatlarını merkez kabul ederek Voronoi diyagramları çizen bir program derlenmiş ve sınıflandırma

uygulamalarında kullanılmıştır. Söz konusu programın amacı, elde edilen diyagramlar kullanılarak görüntü üzerindeki metrik bilginin ölçülmesidir. Programın içerisinde sınıf sayısını manuel seçebilme amaçlı bir arayüz yer almaktadır. Söz konusu çalışmalar için Matlab yazılımı kullanılmıştır. Hazırlanan program için Matlab yazılımının mevcut görüntü işleme ve arayüz fonksiyonları yazar tarafından modifiye edilmiş ve Voronoi diyagramlarını çizmek için de programa Voronoi fonksiyonu gömülmüştür.

MultiSpec ve DVSA uygulamalarından sonra obje belirleme ve saydırma amacıyla profesyonel bir yazılım olan Erdas yazılımının imagine objective modülü kullanılmıştır. Erdas imagine objective uygulamalarında çalışılan her bir görüntüdeki obje özelliklerine göre obje alanı, dokusu, objenin şekline ilişkin köşegenliği, yuvarlaklığı, vb. geometrik özellikleri konusunda yazılım eğitilerek belirlenen objelerin istenen obje olması olasılığı, yumuşatılması, obje içerisindeki boşlukların doldurulması, genelleştirilmesi gibi parametrelerle obje belirleme ve saydırma uygulamaları gerçekleştirilmiştir. Erdas imagine objective modülü ile farklı uydulara ait yüksek çözünürlüklü görüntüler üzerinde bina, yol ve ağaç objelerinin belirlenmesi ve saydırılması uygulamaları yapılmış ve başarılı sonuçlar elde edilmiştir.

İstatistiksel yöntemin söz konusu uygulamalarından sonra bir diğer mekansal bilgi ölçme yöntemi olan topolojik yöntem üzerine araştırmalar ve uygulamalar yapılmıştır. İstatistiksel yöntemden farklı olarak iki aşamalı bir uygulaması olan topolojik yöntemin birinci aşamasında düğüm noktaları bağlantı ilişkileri bakımından sınıflandırılmakta, ikinci aşamasında ise bu sınıflar kullanılarak entropi hesabı yapılmaktadır. Bu konuda gerçekleştirilen uygulamalarda eşit ölçekli, eşit bağlantı sayılı, farklı ölçekli ve farklı bağlantı sayılı genelleştirilmiş haritalar karşılaştırılmış ve sonuçlarına yer verilmiştir. Topolojik yöntem ile gerçekleştirilen uygulamalarda hesaplanan mekansal bilgi miktarı sonuçları ile haritaların görselleri tutarlıdır. Aynı bölgeye ait büyük ölçekli bir harita ve bu haritanın genelleştirilmesi ile elde edilen küçük ölçekli haritanın mekansal bilgi miktarlarının karşılaştırılmasında doğru sonuçlar elde edilmiştir. Ancak bağlantı sayıları eşit fakat geometrik olarak farklı yapıda olan objelerde aynı mekansal bilgi miktarları elde edilmiştir. Böylesi durumlar topolojik yöntem için elverişsiz bir durumdur. Bölümde (3.3.3) ayrıca, aynı örnek üzerinde topolojik yöntem ve istatistiksel yöntem ile hesaplanan mekansal

bilgi miktarları karşılaştırılmıştır. Karşılaştırma sonucunda genelleştirme haritaları üzerinde söz konusu iki yöntemin birbiri ile tutarlı mekansal bilgi miktarı sonuçları verdiği tespit edilmiştir.

Topolojik yöntemden sonra Entropi teoremine benzer bir söylem ile haritada yer alan harita işaretlerinin kapladığı alan ve etrafındaki boşluk miktarları ile ilintili yeni bir kavram olan metrik yöntem araştırılmış ve farklı örnek haritalar üzerinde testleri ve karşılaştırmaları yapılmıştır. Metrik yöntemde eşit sayıda fakat farklı dağılımda objeler içeren haritalar karşılaştırılmış ve haritaların görselleri ile ilgili tutarlı sonuçlar elde edilmiştir. Sonrasında 1:25 000, 1:50 000, 1:100 000 ve 1:250 000 ölçekli haritalar arasındaki mekansal bilgi miktarı değişimi hesaplanmıştır. Uygulama sonuçları, metrik yöntemin önceki iki yöntemden daha anlamlı sonuçlar verdiğini ve söz konusu yöntemin objelerin mekansal konumlarını ve harita işaretlerinin dağılımlarını başarılı şekilde hesaba kattığını göstermiştir. Metrik yöntem konusundaki bir diğer uygulamada ise harita serileri üretmek konusunda oldukça başarılı ve deneyimli olan farklı kurumlar tarafından 1:10 000 ölçekten 1:25 000 ölçeğe genelleştirilmiş sekiz farklı harita kullanılarak karşılaştırma yapılmıştır. Uygulama sonucunda, mekansal bilgi miktarı metrik yöntem ile hesaplanan haritalar arasında en çok bilgi içeren harita ile bir kartograf tarafından en çok bilgi içererek en “iyi” genelleştirilmiş harita seçilen harita aynı olmuştur. Ancak, harita serileri üretmek konusunda oldukça başarılı ve deneyimli olan kurumlarca üretilen bütün genelleştirme çözümlerinin aynı olmaması, aralarında farklılıklar bulunması durumu, genelleştirmenin objektif olmamasından, yapan kurum veya kişilere bağımlı olmasından kaynaklanmaktadır. Bu noktada, hangi çözümün ideal olduğu konusuna standart bir çözüm bulma aşamasında metrik yöntemin kullanılması önerilmektedir.

Çalışmanın bir sonucu olarak; farklı kartograflar veya otomatik genelleştirme yazılımları ile üretilen farklı genelleştirme çözümleri arasında metrik yöntem ile bir karşılaştırma yapılabileceği düşünülmektedir.

Aslan (2011) tarafından çalışılan 1:25 000 ölçekli bir haritanın mesafe, açı ve ağ temelli basitleştirme yöntemleri ile 1:100 000 ölçeğe genelleştirilmesi ile elde edilen sonuçları, yazar tarafından geliştirilen algoritmanın kartografik genelleştirme sonuçlarının değerlendirilmesi için kullanılabileceğini göstermek amacıyla metrik bilgi yöntemi ile incelenmiştir. Diğer uygulamalara benzer şekilde öncelikle sayısal ortamda bina ve yol objelerinin Voronoi diyagramları çizdirilmiş ve Voronoi alanları

belirlenmiştir. Uygulamanın sonucunda, mesafe, açı ve ağ temelli basitleştirme yöntemleri kullanılarak genelleştirilmiş haritaların metrik bilgi miktarları sıralamasında, metrik bilgisi en yüksek harita mesafe yöntemi ile genelleştirilen harita olarak belirlenmiştir. Metrik yöntem sonucuna paralel olarak algoritmayı geliştiren yazarın (Aslan, 2011) tez çalışmasında da mesafe yöntemi önerilmiştir.

Metrik yöntemde, bilgi miktarının artmasındaki önemli faktör Voronoi bölgelerinin alanlarının birbirleri ile yaklaşık olarak eşit olmasıdır. Bu durum Voronoi bölgelerini oluşturan ve içlerinde yer alan binaların aralarındaki mesafelerin yaklaşık eşit olmasını, homojen dağılmasını gerektirir. Objeleri ve etrafında yer alan boşlukları hesaba kattığı için, metrik yöntemin, sadelik ve okunaklılık yönlerinden bu uygulamada da başarılı olarak çalıştığı düşünülmektedir.

Metrik yöntemin sonuçları, Töpfer (1974)'ün seçme kuralı ile de irdelendiğinde, kullanılan yöntemler arasında, Töpfer kuralında hedef ölçekte olması gereken obje sayısını tam olarak sağlayan yöntemin ağ temelli basitleştirme yöntemi olduğu ancak, bunun sebebinin, Töpfer kuralını bir kriter olarak ele alması ve işlemlerinde sürekli olarak hedef ölçekte olması gereken nesne sayısını hesaplaması ve işlem adımları bu sayıya ulaşana kadar tekrarlaması olduğu bilinmektedir. Bununla birlikte, Mesafe yöntemi ile genelleştirilen haritadaki obje sayısı da Töpfer kuralı ile hesaplanan obje sayısına yakındır.

Töpfer yasasının yalnız obje sayısı ile sonuç vermesi, obje niteliği ve dağılımı konusunda bilgi vermemesi nedeniyle günümüzde başka kartografik genelleştirme değerlendirme algoritmalarının geliştirilmesi gerekmektedir. Bu çalışmada önerilen Metrik yöntem bu eksikliği gidermek yolunda yapılan bir çalışma olarak da değerlendirilmelidir.

Otomatik genelleştirme yazılımlarının ve kartografların farklı genelleştirme sonuçları ürettiği noktada metrik yöntemin, üretilen haritaların genelleştirme sonuçlarının karşılaştırılmasında kullanılabileceği düşünülmektedir.

Otomatik genelleştirme alanında yazılımların geliştirilmesi çalışmaları devam etmektedir. Bu konuda ağırlıklı olarak çalışan kurumlardan bir tanesi de Hannover Üniversitesi Kartografya Enstitüsü'dür. Kurumun 70'li yılların başında geliştirdiği CHANGE yazılımı ile üretilen genelleştirilmiş haritalar ile manuel olarak genelleştirilmiş haritalar arasında yapılan karşılaştırmalarda kullanılan ölçütler;

Binaların sayısı,

Yolların sayısı,

- Yol ağının oluşturduğu kapalı alan sayısı,
- Bina alanlarının toplamının tüm alana oranı,
- Yol alanlarının toplamının tüm alana oranı,
- Boş alanların toplamının tüm alana oranıdır (Bildirici ve Uçar, 1997; Powitz, 1993).

Karşılaştırmada binalar ve yollardaki değişim üzerinde durulmuştur. Burada anılan ölçütler, bu çalışmada kullanılan istatistiksel, topolojik ve metrik yöntem ölçütleri ile benzerdir.

Heisser ve diğ. (1995) çalışmasında da mekansal bilgi üzerinde durulmuş ve “haritadaki bağımsız objeler arasındaki etkileşim” konusunda sıklık, topolojik ve geometrik ilişkiler incelenmiştir. Haritada objeler arasındaki söz konusu ilişkilerin ifade edilmesinde de yine doktora çalışmasında kullanılan istatistiksel, topolojik ve metrik yöntemlerin kullanılabileceği görülmektedir.

Literatürde yapılan genelleştirme çalışmalarında ifade edilen objeler arasındaki ilişkilerin nicel olarak belirlenmesinde istatistiksel, topolojik ve metrik yöntemler kullanılabilir.

Bu çalışmaya paralel olarak, gelecekte araştırılması öngörülen konular arasında;

- Erdas imagine objective modülünden elde edilen objeler kullanılarak özellikle kentsel yerleşim bölgelerinin entropi yöntemi kullanılarak “düzenliliğinin” ölçülmesi,
- Kenar belirleme yöntemlerinden Canny ile yol ağı ve eşyükseklik eğrilerinin geometrisinin otomatik belirlenmesi,
- Obje belirlemede başarılı sonuçlar elde edilen Erdas imagine objective modülü ile SVSA yönteminin karşılaştırılması,
- Farklı genelleştirme çözümlerinin metrik yöntem ile değerlendirilmesi ve metrik yöntemin farklı kullanım alanlarının araştırılması,

sayılmaktadır.

KAYNAKLAR

- Abutaleb, A. S.** (1989). Automatic Thresholding of Gray-Level Pictures Using Two Dimensional Entropy, *Computer Vision, Graphics, and Image Processing*, **47**, 22-32.
- Anders, K. H. ve Bobrich, J.** (2004). MRDB Approach for Automatic Incremental Update. ICA Workshop on Generalisation and Multiple Representation, United Kingdom, 20th-21st August.
- Aslan, S.** (2011). *Orta Ölçek Aralığında Binaların Kartografik Genelleştirmesi*, (doktora tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Bank, E.** (1997). *1:25000 Ölçekli Haritalardan Otomatik Genelleştirme ile 1:50000 Ölçekli Haritaların Üretimi*, (doktora tezi), Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Basu, M.** (2002). Gaussian-Based Edge-Detection Methods: A Survey. *IEEE Transactions on Systems Man and Cybernetics, Part C: Applications and Reviews*, **32(3)**, 252-260.
- Başaraner, A. M.** (2005). *Nesne Yönelimli Coğrafi Bilgi Sistemi Ortamında Orta Ölçekli Topografik Haritalar İçin Bina Ve Yerleşim Alanlarının Otomatik Genelleştirilmesi*, (doktora tezi), Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Bedard, Y. ve Bernier, E.** (2002). Supporting Multiple Representation with Spatial Databases, Views Management and Concept of VUEL, ISPRS/ICA Joint Workshop on Multi-Scale Representations of Spatial Data, Ottawa, Canada.
- Bildirici, İ. Ö.** (2003). Coğrafi Bilgi Sistemlerinde Ağ Topolojisi ve Genelleştirme. 9. Harita Kurultayı Kitabı, HKMO. Ankara, 31 Mart-4 Nisan, 337-346.
- Bildirici, İ. Ö.** (2000). *1:1000-1:25000 Ölçek Aralığında Bina ve Yol Objelerinin Sayısal Ortamda Kartografik Genelleştirmesi*, (doktora tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Bildirici, İ. Ö. ve Uçar, D.** (1997). Coğrafi Bilgi Sistemleri ve Genelleştirme. 6. Harita Kurultayı. Ankara, 3-7 Mart, 75-83.
- Bjorke, J. T.** (1996). Framework for entropy-based map evaluation, *Cartography and Geographical Information Systems*, **23(2)**, 78-95.
- Brassel, K. ve Weibel, R.** (2002). Generalization, In: Anson, R.W. ve Ormeling, F.J. (eds.) *Basic Cartography for Students and Technicians*, 2(2nd edition), Sf. 85-122, London: Butterworth-Heinemann.

- Bundy, G. L., Jones, C. B., Furse, E.** (1995). Holistic Generalization of Large-Scale Cartographic Data, In: *Muller, J.-C Lagrange, J.-P., Weibel, R. (eds.). GIS and Generalization: Methodology and Practice*, Sf. 106-119, London, UK: Taylor&Francis.
- Burges, J. C.** (1998). A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, **2**, 121-167.
- Canny, J. F.** (1986). A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **8(6)**, 679-698.
- Chen, J., Li, C. M., Gold, C.** (2001). A Voronoi-based 9-Intersection Model for Spatial Relations, *International Journal of Geographical Information Science*, **15(3)**, 201-220.
- Clark, J. J.** (1989). Authenticating Edges Produced by Zero-Crossing Algorithms, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **2(1)**, 43-57.
- Devogele, T., Trevisan, J. ve Raynal, L.** (1996). Building a Multiscale Database with Scale-Transition Relationships. In *Proceedings of the 7th International Symposium on Spatial Data Handling, Advances in GIS Research II*, Delft, Sf. 6.19-6.33.
- Dhaliwal, J. S.** (1990). *A Comparative Study of Edge Detection Techniques*, (MSc thesis), New Jersey Institute of Technology, New Jersey, USA.
- Doğru, A. Ö.** (2009). *Çoklu Gösterim Veritabanı Kullanılarak Araç Navigasyon Haritası Tasarımı İçin Kartografik Yaklaşımlar*, (doktora tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Dong, Q. Y., Song, C. C., Ben, C. S., Quan, L. J.** (2005). A Fast Subpixel Edge Detection Method Using Sobel–Zernike Moments Operator, *Image and Vision Computing Journal-Elsevier*, **23**, 11-17.
- Dunkars, M.** (2004). *Multiple Representation Databases for Topographic Information*, (PhD thesis), KTH Royal Institute of Technology, Sweden.
- Garcia-Silvente, M., Garcia, J. A., Fdez-Valdivia, J., Garrido, A.** (1997). A New Edge Detector Integrating Scale-Spectrum Information, *Image and Vision Computing*, **15(12)**, 913-923.
- Gold, C. M.** (1992). The Meaning of “Neighbour”, In: *Theories and Methods of Spatial Temporal Reasoning in Geographical Space* (Sf. 220-235). Berlin: Springer-Verlag.
- Hampe, M., Anders, K.-H., Sester, M.** (2003). MRDB Applications for Data Revision and Real-Time Generalisation. *Proceedings of 21st ICA International Cartographic Conference*, South Africa.
- Hampe, M. ve Sester, M.** (2002). Real-Time Integration and Generalization of Spatial Data for Mobile Applications, In: *Maps and the Internet 2002*, **60**, Schriftenreihe der Studienrichtung Vermessungswesen und Geoinformation, Technische Universität Wien.

- Han, J. ve Kamber, M.** (2006). Data Mining Concepts and Techniques. ISBN 1-55860-901-6, *Morgan Kauffmann Publishers Inc.*
- Hardy, P., Hayles, M., Revell, P.** (2003). A New Environment For Generalisation Using Agents, Java, XML and Topology. In Proceedings of the ICA Generalization Workshop, France, 28-30 April.
- Heijden, F.** (1995). Edge and Line Feature Extraction Based on Covariance Models, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **17(1)**, 16-33.
- Heisser, M., Vickus, G., Schoppmeyer, J.** (1995). Rule-Oriented Definition of Small Area Selection and Combination Steps of the Generalization Procedure. In: *Muller, J.-C, Lagrange, J.-R, Weibel. R. (eds.)- GIS and Generalization: Methodology and Practice* (Sf. 47-55). London, UK: Taylor&Francis.
- Henden, P. C.** (2004). Exercise in Computer Vision A Comparison of Thresholding Methods, NTNU –Norwegian University of Science and Technology, Faculty of Information Technology.
- Işık, M. ve Çamurcu, A. Y.** (2007). K-means, K-medoids ve Bulanık C-means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, **6(11)**, 31-45.
- Joao, E. M.** (1995). The Importance of Quantifying the Effects of Generalization. In *Muller. J.-C Lagrange. J.-P.. Weibel. R. (eds.). GIS and Generalization: Methodology and Practice* (Sf. 183-193). London, UK: Taylor&Francis.
- Kaya, T. G., Ersoy O. K., Kamaşak M.** (2011). Support Vector Selection and Adaptation for Remote Sensing Classification, *Geoscience and Remote Sensing*, **99**, ISSN: 0196-2892, 1-12.
- Kilpelainen, T.** (1997). *Multiple representation and generalization of geo-databases for topographic maps*, (PhD thesis), Finnish Geodetic Institute, Finland.
- Kittler, J. ve Illingworth, J.** (1986). Minimum Error Thresholding, *Pattern Recognition*, **19(1)**, 41-47.
- Knopfli, R.** (1983). Communication Theory and Generalization, In: *Graphic Communication and Design in Contemporary Cartography* (Sf. 177-218). John Wiley & Sons Ltd.
- Kolácný, A.** (1977). Cartographic Information - A Fundamental Concept and Term in Modern Cartography, In: *L. Guelke (ed.), The Nature of Cartographic Communication, Cartographica, Monograph*, **19**, 39-45.
- Konishi, S., Yuille, A. L., Coughlan, J. M., Zhu, S. C.** (2003). Statistical Edge Detection: Learning and Evaluating Edge Cues, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **25(1)**, 57-74.
- Landgrebe, D. ve Biehl L.** (2001). An Introduction to MultiSpec Version 5.2001 Program Concept and Introduction Notes, School of Electrical and Computer Engineering, Purdue University, US.

- Liang, K. H. ve Mao, J. J. W.** (1995). Image Thresholding by Minimizing the Measures of Fuzziness, *Pattern Recognition*, **28(1)**, 41-51.
- Lee, Y. C. ve Li, Z. L.** (2000). Taxonomy of Space Tessellation, *ISPRS Journal of Photogrammetry and Remote Sensing*, **55(4)**, 139-149.
- Li, Z. ve Huang P.** (2002). Quantitative Measures for Spatial Information of Maps, *International Journal of Geographical Information Science*, **16**, 699-709.
- Lu, Y. ve Jain, R. C.** (1992). Reasoning About Edges in Scale Space, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **14(4)**, 337- 356.
- Mallat, S. ve Zhong, S.** (1992). Characterization of Signals from Multiscale Edges, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **14(7)**, 710-732.
- Marr, D. ve Hildreth, E.** (1980). Theory of Edge Detection, *Proceedings of the Royal Society London, A. Math. Phys. Sci.*, **B**, 187-217.
- McAndrew, A.** (2004). An Introduction to Digital Image Processing with Matlab Notes, School of Computer Science and Mathematics, Victoria University of Technology.
- Mackaness, W. A. ve Ruas, A.** (2007). Evaluation in Map Generalisation Process. In *Generalisation of Geographic Information: Cartographic Modelling and Applications* (Sf. 89-112), ISBN 978-0-08-045374-3, Elsevier.
- Mackaness, W. A., Ruas, A. ve Sarjakoski, L. T.** (2007). Generalisation of Geographic Information: *Cartographic Modelling and Applications*, Series of International Cartographic Association, ISBN 97 8-0-08-045 374-3, Elsevier.
- MacQueen, J. B.** (1967). Some Methods for Classification and Analysis of Multivariate Observations, *Proc. Symp. Math. Statist. and Probability*, **5**, 281– 297.
- Michell, E. D., Caprile, B., Ottonello, P., Torre, V.** (1989). Localization and Noise in Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **11(10)**, 1106-1117.
- Müller, J. C.** (1991). Generalization of spatial databases. *Geographical Information Systems Principles and Applications*, Maguire, Goodchild and Rhind Eds (Sf.457-475). Publisher Longman Scientific & Technical.
- Nadernejad, E., Sharifzadeh, S., Hassanpour, H.** (2008). Edge Detection Techniques: Evaluations and Comparisons, *Applied Mathematical Sciences*, **2(31)**, 1507-1520.
- Neumann J.** (1987). Gneseological Aspects of Improving Content of the Space Time Model in Cartography. *Proceedings, 13th International Cartographic Conference ICA*, Mexico, 569-584.
- Neumann, J.** (1994). The topological Information Content of a Map: an Attempt at a Rehabilitation of Information Theory in Cartography, *Cartographica*, **31(1)**, 26-34.

- Paiva, J. A. C.** (1998). *Topological Equivalence And Similarity In Multi Representation Geographic Databases*, (PhD thesis), The Graduate School University of Maine, US.
- Perona, P. ve Malik, J.** (1990). Scale-Space and Edge Detection Using Anisotropic Diffusion, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **12(6)**, 629-639.
- Platt, J.** (1999). *Using Analytic QP and Sparseness to Speed Training of Support Vector Machines* (Sf. 557-563). Cambridge, Massachusetts, MIT Press, US.
- Powitz, B.** (1993). *Zur Automatisierung der Kartographischen Generalisierung Topographischer Daten in Geo-Informationssystemen*, (dissertation), Wissenschaftliche Arbeiten der Fachrichtung Vermessungswesen der Universität Hannover, Nr.185, Hannover.
- Roberts, L. G.** (1965). Machine perception of three-dimensional solids. In *J. T. Tippett (Ed.), Optical and electro-optical information processing* (Ch. 9, Sf. 159-197). Cambridge, Massachusetts: MIT Press, US.
- Ruas, A.** (2002). *Generalisation et Representation Multiple*, Hermes Science Publications, Paris, France.
- Samopa, F., Asano, A.** (2009). Hybrid Image Thresholding Method using Edge Detection, *International Journal of Computer Sciences and Network Security*, **9(4)**, 292-299.
- Sarjakoski, L. T.** (2007). Conceptual models of generalisation and multiple representation. In: *Generalisation of Geographic Information: Cartographic Modelling and Applications* (Sf. 11-35). Elsevier.
- Selçuk, M., Uçar, D., Uluğtekin, N., Bildirici, İ. Ö., Gökgöz, T., Başaraner, M., Yücel, M. A., Gülgen, F., Bilgi, S., Doğru, A. Ö.** (2006). Sayısal Kartografya ve Mekansal Bilişim, *Türkiye Bilişim Ansiklopedisi* (Sf. 689-693). ISBN 975-6796-3, Türkiye Bilişim Vakfı-Papatya Yayıncılık Eğitim, Ankara.
- Shannon, C. ve Weaver, W.** (1949). *The mathematical theory of communication*, University of Illinois Press, Urbana, Illinois, US.
- Shannon, C. E.** (1948). *A Mathematical Theory of Communication*, University of Illinois Press, Urbana, Illinois, US.
- Sobel, I. ve Feldman, G.** (1968). *A 3x3 Isotropic Gradient Operator For Image Processing*, John Wiley and Sons, New York, US.
- Sonka, M. ve Fitzpatrick, J.M.** (2004). Handbook of Medical Imaging, *Medical Image Processing and Analysis*, **2**. SPIE-The International society for Optical Engineering, Bellingham-Washington/USA, ISBN-0-8194-3622-4, 447-513.
- Spiess, E.** (1983). Revision of Topographic Maps, Photogrammetric and Cartographic Methods of The Fribourg Test, *The Photogrammetric Record*, **11(61)**, 29-42.

- Stoter, J. E.** (2005). Generalisation: The Gap between Research and Practice, Proceedings of the 8th ICA Workshop on Generalisation and Multiple Representation, Spain.
- Sukhov, V. I.** (1967). Information Capacity of a Map Entropy, *Geodesy and Aerophotography*, **10(4)**, 212-215.
- Sukhov, V. I.** (1970). Application of Information Theory in Generalization of Map Contents, *International Yearbook of Cartography*, 41-47.
- Sukumar, N., Moran, B., Semenov, A., Belikov, V. V.** (2001). Natural Neighbour Galerkin Methods, *International Journal for Numerical Methods in Engineering*, **50**, 1-27.
- Şenel, H. G.** (2007). Kenar Bulma için Topolojik Gradyan İşleçleri, *Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi Dergisi*, **20(2)**, 135-157.
- Tan, P. N., Steinbach, M., Kumar, V.** (2005). *Introduction to Data Mining*, ISBN:0-321-32136-7, Addison Wesley.
- The MurMur Consortium** (2000). Supporting Multiple Representations in Spatio-Temporal Databases, 6th EC-GI & GIS Workshop, Lyon, France.
- Timpf, S. ve Devogele, T.** (1997). New tools for multiple representations, *International Cartographic Commission 97*, Stockholm, 1381-1386.
- Töpfer, F.** (1974). *Kartographische Generalisierung*, Geographisch-Kartographische Anstalt Gotha/Leipzig.
- Tsai, W. H.** (1985). Moment-Preserving Thresholding: A New Approach, *Computer Vision, Graphics and Image Processing*, **29**, 377-393.
- Timur, E. ve Sarı, C.** (2010). Agora (Magnesia/Aydın) Manyetik Verilerinin Kenar Belirleme İşleçleri ve 3-Boyutlu Ters Çözümle Modellenmesi, *Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Dergisi*, **31(2)**, 67-82.
- Turker, M.** (1999). Uzaktan Algılama Görüntülerinin Sınıflandırılması İşleminde Yardımcı Verilerin Kullanılması Teknikleri, *Harita Dergisi*, **122**, 1-10.
- Uçar, D.** (1992). Semantics of the Map, *The Cartographic Journal*, **29**, 151-153.
- Uluğtekin, N.** (2011). Kişisel görüşme, İTÜ Geomatik Mühendisliği Bölümü Öğretim Üyesi, 5 Eylül 2011, İstanbul.
- Uluğtekin, N. ve Doğru A. Ö.** (2005). Coğrafi Bilgi Sistemi ve Harita: Kartografya, Ege Üniversitesi CBS Sempozyumu, İzmir, 209-215.
- Vapnik, V.** (1995). *The Nature of Statistical Learning Theory*, ISBN 0-387-94559-8, Springer-Verlag, New York, US.
- Watson, D. F. ve Philip, G. M.** (1984). Triangle Based Enterpolation, *Mathematical Geology*, **16(8)**, 779-795.
- Weibel, R., ve Dutton, G.** (1999). Generalising spatial data and dealing with multiple representations. In *Geographic Information Systems - Principles and Technical Issues* (cilt 1, baskı 2, Sf. 125-155).

- Worboys, M. F.** (1995). *GIS: A Computing Perspective*, ISBN 0 7484 0064 8, Taylor & Francis Ltd.
- Xu, R. ve Wunsch, D.** (2005). Survey of Clustering Algorithms, *IEEE Transactions On Neural Networks*, **16(3)**, 645-678.
- Yanalak, M., Musaoglu, N., Ormeci, C., Kaya, S., Alkan, R. M., Tarı, E.** (2008). Investigation of the Accuracy and Enginnering Applications of Orbview-3 Images, *TUBITAK Project Report*, **No: 105Y124**.
- Yanalak, M.** (2001). Yüzey Modellemede Üçgenleme Yöntemleri, *Harita Dergisi*, **126**, 58-69.
- Yanalak, M.** (1997). *Sayısal Arazi Modellerinden Hacim Hesaplarında En Uygun Enterpolasyon Yönteminin Araştırılması*, (doktora tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Url-1** <<http://www.csrcs.itu.edu.tr>>, alındığı tarih: 13.04.2010.
- Url-2** <<http://www.erdas.com>>, alındığı tarih: 26.05.2010.
- Url-3** <<http://www.mathworks.com>>, alındığı tarih: 02.07.2010.
- Url-4** <<http://www.maths.lth.se>>, alındığı tarih: 02.07.2010.

EKLER

EK A : Program Kodları

EK A.1 K-Means Algoritması Matlab Kodları

```
close all;
clear all;
% PARAMETRELER
maxClass      = 4;
CCN            = 4;
minHouseArea   = 10;
maxHouseArea   = 80;
LineSegment    = 0.9;      %0-1 Araligi%
EulerNum       = 1;        %0 ya da 1 %
ExtentNum      = 0.4;      %0-1 Araligi%
%
% DUZENLI ALAN UZERINDE CALISMA
f              = imread('IKONOS_2004.tif');
gorg           = f(280:end,110:end,:);
[rows, cols, channel] = size(gorg);
g              = double(gorg);
features       = reshape(g,rows*cols,channel);
groups         =
kmeans(features,maxClass,'Distance','sqEuclidean','start','cluster',
'display','iter');
for classNum=1:maxClass
    class       = (groups==classNum);
    class       = reshape(class,rows,cols);
    houseCand   = bwlabeled(class,CCN);
    house(:, :, classNum) = houseCand;
    stats       =
regionprops(houseCand,'Area','Eccentricity','EulerNumber','Extent');
    allAreas    = [stats.Area];
    allEccent   = [stats.Eccentricity];
    allEuler    = [stats.EulerNumber];
    allExtent   = [stats.Extent];
    idx         = find(allAreas > minHouseArea);
    idx         = idx(find(allAreas (idx) <
maxHouseArea));
    idx         = idx(find(allEccent (idx) <
LineSegment));
    idx         = idx(find(allEuler (idx) ==
EulerNum));
    idx         = idx(find(allExtent (idx) >
ExtentNum));
    newHouseCand = ismember(houseCand,idx);
    %subplot(window,window,classNum+1);%[a,b] = size(idx);
    house(:, :, classNum) = newHouseCand;
    %imshow(newHouseCand);
    %title(sprintf('%d. Sinifa Ait Yeni Ev Adaylari',classNum));
end
son = sum(house,3);
subplot(2,2,1);
imshow(son);
subplot(2,2,2);
imshow(gorg(:, :, 3));
```

EK A.2 Matlab ManualClass Fonksiyonu Kodları

```
% Serdar_versiyon24, 23 Mayıs 2010, Purdue EE Faculty, Office 348F

% Bu program uydu görüntüsü üzerinden manuel sınıflandırma
% yapmaktadır.
% Manuel sınıflandırma arayuzu max 3 sınıf olarak belirlenmiştir.

clear all
clc

filePath          = 'egitim/';      % Verinin bulunduğu klasör
x = imread ('Levent_44.tif');        % Görüntünün
%imtool (x);                      % Görüntünün Matlab Image
                                   % Processing Tool'a alınması

% Bu switch dongusu manuel sınıf sayısı arayuzu içindir.
% Construct a questdlg with three options
choice = questdlg('Please choose the class number:', ...
    'Class Number Menu', ...
    '1','2','3');
% Handle response
switch choice
case '1'
    numclass=1;
case '2'
    numclass=2;
case '3'
    numclass=3;
end

% Sınıflandırma işlemi (Manuel Class algoritması)
s = manualclass(x,numclass,'pixels');

figure; imagesc(s);                % Sınıflandırılan piksellerin lokal
                                   % koordinat sisteminde gösterilmesi

Nx=size(s,1)                      % Uydu görüntüsü matrisinin satır sayısı
Ny=size(s,2)                      % Uydu görüntüsü matrisinin sütun sayısı

A=[];                             % A-Sınıflandırılan piksellerin RGB değeri matrisi
B=[];                             % B-Sınıflandırılan piksellerin koordinat matrisi

classvec=[];                      % Sınıflandırılan pikselin hangi sınıfa ait
                                   % olduğunu belirten matris, 1-2-3...

numelements=[];                  % Training piksellerinin hangi sınıfta
                                   % kaç tane olduğunu belirten matrisi

for k=1:numclass

    [rows cols]=find(s==k);
```

```

N=length(rows); % Manuel siniflandirma isleminde son
% siniftaki training pikseli sayisi
numelements=[numelements N];
for j=1:N

    rgb=squeeze(x(rows(j), cols(j),:));

    A=[A rgb];
    B=[B [rows(j) cols(j)]];
    classvec=[classvec k];
end
end

% Bu kisimda elde edilen tum veriler(matrisler) ekrana basiliyor.
A(:,classvec==3)
A
B
classvec
numelements

% Bu kisim, siniflandirma matrisini (piksellerin RGB degerlerini)
% DVSA algoritmasinin alabilecegi formata sokmak icin eklendi.

Abir = [classvec]'

Aiki= [Abir A'] % Aiki ==> Piksellerin RGB degerleri
% kolonlara,piksellerin ait olduklari
% sinif degerleri de label olarak
% birinci kolona yerlestirildi.

% Bu kisim, bu programin sonunda elde ettigimiz ve DVSA programina
% aktarilacak olan Aiki matrisini text editorunde duzenleyip *.dat
% olarak kaydetmek yerine Matlab ortaminda direkt Aiki.dat olarak
% elde etmek icin eklendi.

Serdardosya=fopen('Aiki.dat','wt');
fprintf (Serdardosya,'%4.0f %4.0f %4.0f %4.0f\n',Aiki);
fclose(Serdardosya);

% Bu kisim, B matrisindeki siniflandirilan piksellerin x, y lokal
% koordinatlar merkez alinarak Voronoi Diyagramlari cizdirmek icin
% eklendi. Voronoi diyagramlari ayri bir pencerede cizilmektedir.

voronoi( B(1,:) , B(2,:) );

```

ÖZGEÇMİŞ



Ad Soyad: Serdar BİLGİ
Doğum Yeri ve Tarihi: NEVŞEHİR, 27.02.1979
Adres: İTÜ Ayazağa Kampüsü, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, Oda No: 406 Maslak/İSTANBUL
E-Posta: bilgis@itu.edu.tr
Lisans: Jeodezi ve Fotogrametri Mühendisliği, İstanbul Teknik Üniversitesi
Yüksek Lisans: Geomatik Mühendisliği, İstanbul Teknik Üniversitesi
Mesleki Deneyim:

Kurum	Ülke	Bölüm/Birim	Görev Türü	Dönemi
İstanbul Teknik Üniversitesi	Türkiye	Geomatik Mühendisliği	Araştırma Görevlisi	2001-
Purdue University	ABD	Elektrik ve Bilgisayar Mühendisliği	Visiting Scholar	03.2010-09.2010

Ödüller: TÜBİTAK Yurt Dışı Araştırma Bursu-6 ay, 2009.

Yayın Listesi:

Makale

- **Bilgi, S.**, İpbüker, C., Ucar D., Sahin M., Map Entropy Analysis of Topographic Data Used in *Disaster Information Systems*, Journal of Earthquake Engineering (Volume: 12), pages: 23-36, 2008 (2).
- Erdogan S, Sahin M, Yavasoglu H, Tiryakioglu I, Erden T, Karaman H, Tari E, **Bilgi S**, Tuysuz O, Baybura T, Taktak F, Telli A. K, Gullu M, Yilmaz I, Gokalp E, Boz Y, Monitoring of Deformations Along Burdur Fethiye fault Zone with GPS", *Journal of Earthquake Engineering* (Volume: 12), pages: 109-118, published 2008, supplement 2.
- **Bilgi, S.** Fotogrametri ve Uzaktan Algılamada Veri Elde Etme Yöntemlerinin Gelişimi ve Kısa Tarihçeleri, *HKMO Dergisi*, Sayı 96, s. 48-55, Ocak 2007.
- **Bilgi, S.** 8000 Yıllık Geçmişi ile Harita ve Haritacılık, *Popüler Bilim Dergisi*, Sayı:144, s.38-42, Şubat 2006.
- **Bilgi, S.**, İpbüker, C. ; Kesikli Dünya Haritaları, *Harita Dergisi*, Sayı:129, s.64-73, Ocak 2003.

Kitap İçerisinde Bölüm

Selçuk, M., Uçar, D., Uluğtekin, N., Bildirici, İ.Ö., Gökgöz, T., Başaraner, M., Yücel, M.A., Gülgen, F., **Bilgi, S.**, Doğru, A.Ö., Sayısal Kartografya ve Mekansal Bilişim, *Türkiye Bilişim Ansiklopedisi*, ISBN 975-6796-3, s:689-693. Türkiye Bilişim Vakfı-Papatya Yayıncılık Eğitim, 2006, Ankara.

Bildiri (Ulusal & Uluslararası)

- Kalkan Y., **Bilgi S.**, "Latest Results of Landslide Deformation Project in Harbor of Ambarlı Region", FIG Working Week, 18-22 May 2011, Marrakech Morocco (Oral presentation).
- Kalkan Y., Alkan R.M., **Bilgi S.**, "Deformation Monitoring Studies at Atatürk Dam", FIG Congress 2010, 11-16 April 2010, Sydney, Australia (Oral presentation).
- Kalkan Y., Alkan R.M., **Bilgi S.**, "Ambarlı Liman Bölgesinde Heyelan İzleme Çalışmalarında Son Durum", TMMOB Harita ve Kadastro Mühendisleri Odası 4. Mühendislik Ölçmeleri Sempozyumu, s 353-364, 14-16 Ekim 2009, Trabzon.
- **Bilgi S.**, İpbüker C. "Entropy Analysis of Images Used In Disaster Information Systems", TIEMS 16th Annual Conference, 9th-11th June, 2009, Istanbul (Poster Presentation).
- Kalkan Y., Alkan R.M., **Bilgi S.**, "Deformation Monitoring of Atatürk Dam", TIEMS 16th Annual Conference, 9th-11th June, 2009, Istanbul (Oral Presentation).
- Selçuk, M., Başaraner, M., Uluğtekin, N., Gökgöz, T., Gülgen, F., Yücel, M.A., Doğru, A.Ö., **Bilgi S.**, Çetinkaya, S., ve Uçar, D. (2008). 'GIS and Cartography for Mountain Activities and Natural Resources', Proceedings of 2nd International Conference on Cartography and GIS, January 21-24, 2008, Borovets, Bulgaria.

- **Bilgi S.**, İpbuker C., Sahin M., “An Entropic Evaluation of Topographic Data Used in Disaster Information Systems”, International Symposium on Earthquake Loss Estimation for Turkey, September 2007, ITU, Istanbul, Turkey.
- Selçuk, M., Başaraner, M., Uluğtekin, N., Gökgöz, T., Gülgen, F., Yücel, M.A., Doğru, A.Ö., **Bilgi S.**, Çetinkaya, S., ve Uçar, D. (2007). 'Dağcılık Faaliyetlerine Yönelik Coğrafi Bilgi Sistemi Oluşturulması ve Tematik Harita Üretimi', TMMOB Coğrafi Bilgi Sistemleri Kongresi, 30 Ekim - 02 Kasım 2007, KTÜ, Trabzon.
- **Bilgi S.**, Kalkan Y., Yalın S.D., Erden T, Yavaşoğlu H. “Geodetic monitoring in the biggest dam of Turkey: Atatürk Dam”, International Symposium on Modern Technologies, Education and Professional Practice in Geodesy and Related Disciplines", November 9-10, 2006, Sofia-Bulgaria, pp. 94-102, (Poster Presentation).
- Gokgoz, T., Uluğtekin, N., Basaraner, M., Gulgen, F., Dogru, A.O., **Bilgi S.**, Yucel, M.A., Cetinkaya, S., Selcuk, M., Ucar, D.: Watershed Delineation from grid DEMs in GIS: Effects of Drainage Lines and Resolution. IWA DipCon 2006, 10th International Specialized Conference on Diffuse Pollution and Sustainable Basin Management. 18- 22 September, 2006, Istanbul. Turkey (CD) (Oral Presentation).
- **Bilgi S.**, İpbuker C. "Creating Basic Spatial-Topographic Object Model for ITU-ACDIS", International Conference on Cartography and GIS, CD ISBN 10:954-724-028-5, January 25-28.2006,Borovets-Bulgaria, (Oral Presentation).
- Alkan R. M, Kalkan Y., **Bilgi S.**,”Forming the Geodetic Infrastructures of Engineering Projects by GPS and Different Leveling Methods”,International Symposium on Modern Technologies, Education and Professional Practice in Geodesy and Related Disciplines", November 3-4, 2005, Sofia-Bulgaria, pp. 168-178, (Oral Presentation).
- **Bilgi S.**, İpbuker C., "CBS Etiği", TMMOB Harita ve Kadastro Müh. Odası 10.Sürekli ve Bilimsel Teknik Kurultayı, Ankara, 29 Mart 2005.
- **Bilgi S.**, İpbuker C., "Küresel Rotaların Uygun Kartografik Gösterimi", TMMOB Harita ve Kadastro Müh. Odası 10.Sürekli ve Bilimsel Teknik Kurultayı, Ankara, 29 Mart 2005.
- Yavaşoğlu H., Rüzgar G., Baykal O., **Bilgi S.**, Çakmak R., Erden T., Ergintav S., İnce C.D, Karaman H., Tari E., Tari U. & Tüysüz O., “GPS measurements along the North Anatolian Fault Zone on the Mid-Anatolia segment”, 5th International Symposium on Eastern Mediterranean Geology, 14-20 April 2004,V2 s904-907,Thessaloniki, Greece
- Yavaşoğlu H., Baykal O., **Bilgi S.**, Çakmak R., Erden T., Ergintav S., İnce C.D., Karaman H., Tari E., Tari U., Tüysüz O., Kuzey Anadolu Fayının Orta Anadolu Bölümünün GPS Ölçmeleri ile Güncel Tektonik Özelliklerinin Belirlenmesi, Aktif Tektonik Araştırma Grubu Altıncı Toplantısı, 21-22 Kasım 2003, s79-83, Ankara.
- Baykal,O., **Bilgi,S.**, Coşkun,Z., Erden,T., Göksel,Ç., İpbüker, C., Karaman,H., Kaya,Ş., Musaoğlu,N., Şahin,M., Tari,E., Türkoğlu,H., Uçar,D., Üstün,B., Yavaşoğlu,H.,Yiğiter,R. ; *GIS Standards of Turkey based on Emergency Management*, International Symposium on Geographic Information Systems, GIS2002, Istanbul, September 23-26, 2002.

Tez

- **Bilgi, S.;** *İTÜ Kampüsü Temel Topografik Obje Modelinin Oluşturulması ve İlişkisel Sorgulamalarının Yapılandırılması*, İTÜ Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Mayıs (2003).
- **Bilgi S.,** Demirci E., Taşkın G., Özyurt A., *Uydu Görüntülerinin GPS Verileri ile Geometrik Dönüşümü*, İTÜ Jeodezi ve Fotogrametri Mühendisliği Bölümü Bitirme Tezi, (2001).

Proje

- Rize Afet Bilgi Sistemi ve Meteorolojik Erken Uyarı Sistemi Projesi - RABİS, (Yönetici: Prof. Dr. Muhammed ŞAHİN, TÜBİTAK-İTÜ), 2007.
- İstanbul Afet Yönetim Bilgi Sistemi Projesi - İSTABİS, (Yönetici: Prof. Dr. Muhammed ŞAHİN, Devlet Planlama Teşkilatı-İTÜ), 2007.
- Türkiye Deprem Hasar Analizi Programı Geliştirme Projesi - HAZTURK, (Yönetici: Prof. Dr. Muhammed ŞAHİN, TÜBİTAK-İTÜ), 2007.
- Atatürk Barajı Deformasyon İzleme Projesi (Yönetici: Doç. Dr. Yunus KALKAN, İTÜ), 2007.
- Altaş Ambarlı Liman Tesisleri Sahasında Heyelanların İzlenmesi (Yönetici: Doç. Dr. Yunus KALKAN, İTÜ), 2005
- Kuzey Anadolu Fayının Ladik-Ilgaz Arasında Kalan Orta Bölümünün GPS Ölçmeleri İle Kinematığının Belirlenmesi Projesi- ORTA-KAF (Yönetici: Prof. Dr. Ergin Tarı, TÜBİTAK-İTÜ) 2001-2002-2003-2004.
- İTÜ Kampüsü Yönlendirme Projesi, Yönetici: Prof. Dr. Nuran Zeren GÜLERSOY (Mimarlık Fak.), Prof. Dr. Necla ULUĞTEKİN (İnşaat Fak), 2004.
- İTÜ Kampüsü Temel Topografik Obje Modelinin Oluşturulması ve İlişkisel Sorgulamalarının Yapılandırılması (Yönetici: Prof. Dr. Cengizhan İPBÜKER), 2003.
- Uydu Görüntülerinin GPS Verileri ile Geometrik Dönüşümü ve İstanbul Avrupa Yakası Yerleşim Bölgelerinin Zamansal Analizi (Yönetici: Doç. Dr. Şinasi Kaya) İTÜ Araştırma Fonu, 2002.
- Ulusal UAS-CBS Bazlı Veri Tabanı ve Afet Yönetimi Odaklı Karar Destek Sistemi Standardının Oluşturulması Projesi (Yönetici: Prof. Dr. Muhammed ŞAHİN, TC İçişleri Bakanlığı Strateji Planlama Merkezi) 2001