



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

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**FARKLI GÖRÜNTÜ SINIFLANDIRMA VE İYİLEŞTİRME
METOTLARININ ARAZİ KULLANIM/ARAZİ ÖRTÜSÜ
HARİTALAMASINA ETKİLERİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

Hoshmand Ahmed Azeez

DANIŞMAN

Yrd. Doç. Dr. Müge AĞCA YILDIRIM

AKSARAY, 2016



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

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**FARKLI GÖRÜNTÜ SINIFLANDIRMA VE İYİLEŞTİRME
METOTLARININ ARAZİ KULLANIM/ARAZİ ÖRTÜSÜ
HARİTALAMASINA ETKİLERİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

Hoshmand Ahmed Azeez

DANIŞMAN

Yrd. Doç. Dr. Müge AĞCA YILDIRIM

AKSARAY, 2016

AKSARAY ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ONAY BELGESİ

Aksaray Üniversitesi, Fen Bilimleri Enstitüsü'nün 132306801 numaralı Yüksek Lisans öğrencisi, Hoshmand Ahmed Azeez, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı FARKLI GÖRÜNTÜ SINIFLANDIRMA VE İYİLEŞTİRME METOTLARININ ARAZİ KULLANIM/ARAZİ ÖRTÜSÜ HARİTALAMASINA ETKİLERİNİN İNCELENMESİ başlıklı tezini, aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : Yrd. Doç. Dr. Müge AĞCA YILDIRIM.....
Aksaray Üniversitesi

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

Jüri Üyeleri : Yrd. Doç. Dr. Abdurrahman GEYMEN
Erciyes Üniversitesi

Teslim Tarihi: 24.11.2016

Savunma Tarihi: 26.12.2016

ÖNSÖZ

Uzaktan algılama yeryüzü ile herhangi bir temas olmadan bilgi elde eden bilim, sanat ve teknoloji dalıdır. Bu işlem yansıyan ve yayılan enerjinin algılanıp kayıt edilmesi ve bu bilginin işlenmesi ve analizi ile gerçekleşmektedir. Tarım, zemin haritalama, orman, şehir planlama, arkeolojik araştırmalar, askeri gözlemler, jeomorfolojik gözlemler, Arazi Kullanımı/Arazi Örtüsü (Land Use/Land Cover-LU/LC) haritalama gibi uzaktan algılama teknolojisinin birçok uygulama alanı bulunmaktadır. Uzaktan algılamanın en basit formu, görülebilir veya kızılötesi dalga boylarında bilgi kaydeden fotogrametrik kameraları kullanmaktadır. 19. yüzyılın sonlarında, arazinin eğik hava fotoğraflarını çekmek için kameralar, balonlara veya uçurtmalara yerleştirilirdi. I. Dünya Savaşı boyunca, hava fotoğrafları düşman askerlerinin hareket ve konum bilgilerini toplayarak yeni stratejilerin geliştirilmesinde ve savunmada önemli bir rol oynamıştır. Uzaktan algılama görüntüleriyle ilgili önemli konulardan birisi karasal yüzey materyallerinin analizi ve izlenmesi ile ilgili olan LU/LC analiz sürecidir. Arazi Örtüsü (Land Cover-LC); ekoloji, toprak, topografya, yüzey ve yeraltı suyu, insan yapıları gibi yeryüzünün doğal ve insan yapımı örtüsünü tanımlar. Arazi Kullanım (Land Use-LU), arazinin biyofiziksel özelliklerini ve arazinin kullanım amacını göstermektedir.

DOĞRULUK BEYANI

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

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

HOSHMAND AHMED AZEEZ

İMZA

TEŞEKKÜR

Her şeyden önce çalışmamı tamamlamak için bana güç ve sabır verdiği ve bilgi hediyesi ile beni ilhamlandığı için Allah’a teşekkür etmek istiyorum. Çalışma süresince çeşitli kişi ve bölümlerden yardım ve destek aldım. Değerli zamanını bana ayırdığı, gelişmem için çaba harcadığı ve tez çalışmam boyunca beni desteklediği için derinden minnettar olduğum danışman hocam Yrd. Doç. Dr. Müge AĞCA YILDIRIM’a teşekkür ederim. Nazik yardımları için bütün hocalarım ve sayın Ekrem Saleh HEME beye kalpten teşekkürlerimi ifade etmek istiyorum. Uzaktan algılama konusunda bana birçok önemli ders anlatan Efdal KAYA’ya özel teşekkürlerimi sunarım. Bu çalışma boyunca beni destekleyen ve cesaretlendiren annem, babam ve kardeşlerime en kıymetli teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	ii
DOĞRULUK BEYANI.....	iii
TEŞEKKÜR	iv
İÇİNDEKİLER	iii
ÖZET.....	v
ABSTRACT	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
KISALTMALAR DİZİNİ	ix
1. GİRİŞ	1
2. ÇALIŞMA ALANI VE METODOLOJİ.....	5
2.1 Çalışma Alanı.....	5
2.2 Metodoloji.....	6
2.2.1 Veri analizi	7
2.2.2 RapidEye uydu görüntüsü	7
2.3 Görüntü İyileştirme ve Dönüşüm Yöntemleri	8
2.3.1 Ana bileşenler analizi (Principal Component Analysis-PCA).....	9
2.3.1.1 Özvektörler çıkarımı	10
2.3.1.2 Özdeğer	10
2.3.2 Minimum gürültü bölümlemesi (Minimum Noise Fraction – MNF).....	11
2.4 Görüntü Sınıflandırma	12
2.4.1 Piksel tabanlı görüntü sınıflandırma	13
2.4.1.1 Kontrollü sınıflandırma.....	14
2.4.1.2 Kontrolsüz sınıflandırma.....	18
2.4.2 Obje tabanlı görüntü sınıflandırma	19
2.5 Doğruluk Analizi.....	20
2.5.1 Hata matrisi	21
2.5.2 Genel doğruluk.....	21
2.5.3 Kappa katsayısı	22
3. ARAŞTIRMA BULGULARI.....	23
4. SONUÇ VE ÖNERİLER.....	28

KAYNAKLAR	30
ÖZGEÇMİŞ.....	34

ÖZET

FARKLI GÖRÜNTÜ SINIFLANDIRMA VE İYİLEŞTİRME METOTLARININ ARAZİ KULLANIM/ARAZİ ÖRTÜSÜ HARİTALAMASINA ETKİLERİNİN İNCELENMESİ

Uzaktan algılama teknolojileri ile Arazi kullanımı/Arazi örtüsü (Land Use/Land Cover-LU/LC) bilgileri çok kısa sürede, daha düşük maliyetlerle ve klasik yöntemlere göre daha objektif ölçütlerle elde edilebilmektedir. Uzaktan algılama verileri LU/LC çalışmalarının önemli bir bileşenidir. Çalışmanın genel amacı, çalışma bölgesi olan Hatay ilinin Samandağ ilçesinin LU/LC'nin mevcut durumunu uzaktan algılama görüntüleri ve farklı sınıflandırma tekniklerini kullanarak analiz etmek ve modellemektir. Çalışmanın ana amacına ulaşmak için; (a) Farklı sınıflandırma tekniklerinin (kontrollü, kontrolsüz ve obje tabanlı sınıflandırma) yüksek çözünürlüklü uydu görüntüsü üzerinde kullanımı ve sınıflandırma sonuçlarının kıyaslanması ve analizi ve (b) Farklı görüntü iyileştirme ve zenginleştirme tekniklerinin kullanımı, çok bantlı yeni görüntülerin oluşturulması ve bu tekniklerin doğruluk analizi sonuçlarına etkilerinin analizi ve çalışma alanının LU/LC haritalaması gerçekleştirilmiştir. Çalışmada, Ana Bileşenler Analizi (Principal Component Analysis-PCA) ve Minimum Gürültü Bölümlemesi (Minimum NoiseFraction- MNF) görüntü iyileştirme teknikleri kullanılarak bu uygulamaların doğruluk analizine olan etkileri incelenmiştir. Çalışmadan elde edilen sonuçlara göre bu çalışmada obje tabanlı sınıflandırma yöntemi %80.45 ve 0.74 kappa istatistiği ile en yüksek doğruluğu vermiştir.

Anahtar Kelimeler: Uzaktan Algılama, Ana Bileşenler Analizi, Minimum Gürültü Bölümlemesi, Piksel Tabanlı Sınıflandırma, Obje Tabanlı Sınıflandırma

ABSTRACT

INVESTIGATION OF THE EFFECTS OF DIFFERENT IMAGE CLASSIFICATION AND ENHANCEMENT METHODS ON LAND USE/LAND COVER MAPPING

With Remote Sensing technologies, land use/land cover information can be obtained in a very short time, at lower costs and with more objective measures than classical methods. Remote sensing data is an important component of LU / LC studies. The general aim of the study is to analyze and model the current state of the LU / LC of Samandağ district of Hatay province, which is the study area, using remotely sensed images and different classification techniques. To achieve the main goal of the study: (a) Use of different classification techniques (supervised, unsupervised, and object-based classification) on high resolution satellite images and comparison and analysis of classification results; (b) Use of different image enhancement and enrichment techniques and analysis of effects on accuracy analysis results, and (c) Modeling, monitoring and mapping LU / LC of study area. Using the principal component analysis and minimum noise partition image enhancement techniques in the study, the effects of these applications on the accuracy analysis were investigated. According to results obtained in this study, the object-based classification method gave the highest accuracy with 80.45% and 0.74 kappa statistic.

Keywords: Remote Sensing, Principal Component Analysis, Minimum Noise Fraction , Pixel Based Classification, Object Based Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1: Çalışma alanı.....	5
Şekil 2.2: Araştırma iş akışı şeması.....	6
Şekil 2.3: ENVI de MNF kullanım şeması.....	12
Şekil 2.4: Kontrollü sınıflandırma adımları.....	14
Şekil 2.5: Paralel kenar sınıflandırıcı.....	16
Şekil 2.6: En kısa uzaklık sınıflandırıcı.....	16
Şekil 2.7: Maksimum olabirlik sınıflandırıcı.....	17
Şekil 2.8: Kontrolsüz sınıflandırma adımları.....	18
Şekil 2.9: Obje tabanlı özellik çıkarımı adımları.....	20
Şekil 2.10: ENVI klasikde hata matrisi.....	21
Şekil 3.1: MNF sonuçları.....	23
Şekil 3.2: PCA sonuçları.....	24
Şekil 3.3: Sınıflandırılmış görüntü sonuçları.....	26

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1: RapidEye uydu görüntüsünün teknik özellikleri.....	9
Çizelge 3.1: Kontrollü Sınıflandırma yöntemi sonucuna ait hata matrisi	24
Çizelge 3.2: Kontrolsüz Sınıflandırma yöntemi sonucuna ait hata matrisi.....	25
Çizelge 3.3: Obje tabanlı sınıflandırma yöntemi SVM sınıflandırıcının özgün veri çıktısına dayanan sonuçlara ait hata matrisi	25
Çizelge 3.4: Tüm sınıflandırma yöntemlerinden elde edilen doğruluk analizi sonuçları.....	25

KISALTMALAR DİZİNİ

ROI	İlgi Bölgesi
LU/LC	Arazi Kullanımı /Arazi Örtüsü (Land Use/Land Cover-LU/LC)
ENVI	Görüntüleme İmajı Ortamı
ISODATA	Yenilenen Kendinden Düzenlemeli Veri Analiz Tekniği
TM	Tematik Haritalama
UTM	Evrensel Transversal Merkator
SVM	Destek Vektör Makinesi
PCA	Ana Bileşen Analizi
MNF	Minimum Gürültü Bölümlemesi
WRS	Dünya Referans Sistemi
Km	Kilometre
Km²	Kilometrekare
WGS84	Dünya Jeodezik Sistemi 1984
KG	Kilogram
NIR	Yakın Kızılötesi
SVD	Tekil Değer Ayrışması

1. GİRİŞ

Uzaktan algılama yeryüzü ile herhangi bir temas olmadan bilgi elde eden bilim, sanat ve teknoloji dalıdır. Bu işlem yansıyan ve yayılan enerjinin algılanıp kayıt edilmesi ve bu bilginin işlenmesi ve analizi ile gerçekleşmektedir. Tarım, zemin haritalama, orman, şehir planlama, arkeolojik araştırmalar, askeri gözlemler, jeomorfolojik gözlemler, Arazi Kullanımı/Arazi Örtüsü (Land Use/Land Cover-LU/LC) haritalama gibi uzaktan algılama teknolojisinin birçok uygulama alanı bulunmaktadır. Uzaktan algılamanın en basit formu, görülebilir veya kızılötesi dalga boylarında bilgi kaydeden fotogrametrik kameraları kullanmaktadır. 19. yüzyılın sonlarında, arazinin eğik hava fotoğraflarını çekmek için kameralar, balonlara veya uçurtmalara yerleştirilirdi. I. Dünya Savaşı boyunca, hava fotoğrafları düşman askerlerinin hareket ve konum bilgilerini toplayarak yeni stratejilerin geliştirilmesinde ve savunmada önemli bir rol oynamıştır. Uzaktan algılama görüntüleriyle ilgili önemli konulardan birisi karasal yüzey materyallerinin analizi ve izlenmesi ile ilgili olan LU/LC analiz sürecidir. Arazi Örtüsü (Land Cover-LC); ekoloji, toprak, topografya, yüzey ve yeraltı suyu, insan yapıları gibi yeryüzünün doğal ve insan yapımı örtüsünü tanımlar. Arazi Kullanım (Land Use-LU), arazinin biyofiziksel özelliklerini ve arazinin kullanım amacını göstermektedir.

Arazi kaynaklarını izleme ve yönetme için uzaktan algılama ile LU/LC haritalarının üretimi maliyetli bir teknolojidir. Ayrıca, LC karakterizasyonu, haritalanması ve izlenmesi uzaktan algılanmış verinin en önemli ve tipik uygulamaları olarak bilinmektedir. Hassas ve güncel LC verilerinin bulunabilirliği ve ulaşılabilirliği global değişim çalışmalarında önemli rol oynamaktadır.

Uzaktan algılamada sistemlerinde kullanılan sensörler, aktif ve pasif sensörler olarak iki gruba ayrılmaktadır. Pasif sensör, uzaktan algılamanın çift sensörüdür. Sensör, elektromanyetik enerjiyi ölçen ve kaydeden cihazdır. Pasif sensörler dışardan bir enerji kaynağına bağlıdır ve genellikle bu enerji kaynağı güneştir. En bilinen pasif sensörler fotogrametrik kameralardır. Aktif sensörlerin kendi enerji kaynağı bulunmaktadır. Radar (Radio Detection And Ranging) ve Lidar (Light Detection And Ranging) aktif sensörlere örnektir. LU/LC haritalama, değişim belirleme ve diğer

uzaktan algılama prosesleri için mevcut birçok uydu sensörü bulunmaktadır. Rapid Eye, IKONOS, World View, Quick Bird Advanced Very High Resolution Radiometer (AVHRR), Advanced Space Borne Thermal Emission and Reflection Radiometer (ASTER), Satellite Pour l' Observation de la Terre (SPOT), Landsat Thematic Mapper (Landsat TM) ve Moderate Resolution Imaging Spectrometer (MODIS) pasif uzaktan algılama sensörlerine örnektir. Her uydu sensörü farklı konumsal, zamansal, radyometrik ve spektral çözünürlüklere sahiptir. Son bir kaç yıl içinde, konumsal bilgi talebinde önemli bir artış gözlenmektedir.

LU/LC veritabanları arazi yönetimi, kentsel planlama, tarım, çevre koruma ve birçok amaç için gereklidir. Yeni sensörler çok yüksek mekansal, spektral ve zaman çözünürlüğü sağlamaktadır. Uydu uzaktan algılama sistemi iklim, atmosferik radyasyon, kimya, okyanus dinamikleri, verimlilik özellikleri, coğrafi ve topografik konumlar ve arazi biyosfer özellikleri gibi çevresel değişkenler hakkında bilgi toplamak için kullanışlıdır.

Bu çalışmada, yüksek çözünürlüklü RapidEye uzaktan algılama verisi kullanılmıştır. RapidEye görüntüsü, 5 spektral bant ve 5m mekansal çözünürlüğü olan pasif sensör verisidir. RapidEye yüksek çözünürlük ve multispektral kapasitesiyle görüntüleme kabiliyeti ile tarım, ormancılık, petrol ve gaz arama, enerji, mühendislik, inşaat, devletler, harita mühendisliği, madencilik, gibi birçok endüstride uygulanabilir.

Bu çalışmanın temel amacı, yüksek çözünürlüklü uzaktan algılama uydu görüntüsü ile farklı görüntü iyileştirme, analiz ve sınıflandırma teknikleri kullanarak yüksek doğrulukta LU/LC haritası üretmektir.

Görüntüyü sınıflandırmak için birçok yaygın yaklaşım bulunmaktadır. Bu çalışmada iki ana sınıflandırma tekniği olan piksel tabanlı görüntü sınıflandırma ve obje tabanlı görüntü sınıflandırma yöntemleri kullanılmıştır. Piksel tabanlı sınıflandırma yönteminde kontrollü ve kontrolsüz sınıflandırma tekniği olarak iki yöntem kullanılmaktadır. Kontrollü sınıflandırmada, analist belirli bir alanı veya çalışma alanını bulmak için bilinen LU/LC türlerinin homojen örnekleri sunduğu önceden edinilmiş bilgiyi kullanır. Bu çalışma alanlarının istatistiklerine dayanarak, görüntüdeki her bir piksel kullanıcı tanımlı LU tipi (kentsel alan, su, tarım vb.) veya LC tipi (orman, asfalt yüzey, vb.) olarak atanır. LC'nin iyi bilinmediği veya tanımlanmadığı yerlerde kontrolsüz sınıflandırma yöntemi oldukça yaygın bir şekilde kullanılmaktadır.

Bilgisayar algoritmaları, analistin tanımlaması ve birleştirmesi gerektiği bilgi sınıflarında küçük pikselleri çeşitli spektral sınıflara gruplandırır (Jensen 2005, Thomson vd. 1998). Bununla beraber obje tabanlı sınıflandırma yönteminde görüntüyü sınıflandırmak için objenin (segment) benzer spektral, konumsal ve/veya doku nitelikleri olduğu yerde segment tarafından gerçekleştirilen ve ölçek seviyesi ve birleşme seviyesi gibi niteliklerin hesaplandığı obje-tabanlı yaklaşımı kullanır.

Bu tez çalışmasında, iki önemli dönüşüm ve iyileştirme yöntemi olan Ana Bileşenler Analizi (Principal Component Analyzsis-PCA) ve Minimum Gürültü Bölümlemesi (MNF) kullanılmıştır. Görüntü iyileştirme gürültü gidermek, görüntüyü keskinleştirmek veya parlatmak, önemli özelliklerini tanımlamayı kolaylaştırmak gibi görüntü analizi ile daha fazla sonuç elde etmek için dijital görüntüleri düzeltme işlemidir. Görüntü iyileştirme, görüntü sınıflandırma ve değişim analizi ile beraber yaygın olan üç uzaktan algılama görüntü işleme yöntemlerinin başında gelmektedir. Uzaktan algılama uygulamalarında, ana kriter veri boyutunu azaltarak (PCA) ve gürültüyü gidererek (MNF) görüntü kalitesini arttırmaktır (Leonidas 2004).

Araştırmacılar tarafından farklı sınıflandırma teknikleri ve iyileştirme yöntemlerinin kullanılarak uzaktan algılama görüntüsüyle LU/LC analizinin yapıldığı birçok çalışma bulunmaktadır. Gao Yan (2003) çalışmasında çalışma alanının LC haritalamasında piksel tabanlı ve obje tabanlı görüntü analizini kullanmıştır. Çalışmada iki ayrı uydu görüntüsüne kontrollü sınıflandırma, kontrolsüz sınıflandırma ve obje tabanlı görüntü analizi uygulanmıştır. LC sınıflarının çoğu için obje tabanlı görüntü analizi yaklaşımında, piksel tabanlı görüntü analizi yaklaşımından daha yüksek genel doğruluk, yüksek üretici ve kullanıcı doğruluğu elde edilmiştir. Doğruluk değerlendirmesi için bağımsız kesin referans kullanarak, piksel tabanlı görüntü analizi yaklaşımından elde edilen genel doğruluk %70'in üzerindeyken obje tabanlı görüntü analizi yaklaşımında %80'in üzerindedir (Gao Yan, 2003). Piksel tabanlı sınıflandırma ile obje tabanlı öznitelik çıkarımı yaklaşımlarının çok yüksek çözünürlüklü data için karşılaştırıldığı diğer bir çalışma Bokhary ve arkadaşları (2007) tarafından gerçekleştirilmiştir. Bu çalışmada, ENVI öznitelik çıkarımı modeli olan obje tabanlı sınıflandırma ile geleneksel yöntemler karşılaştırılmıştır. Çalışmada Hiperspektral yeri kullanılmıştır. Çalışma yüksek çözünürlüklü verinin yorumlanmasında obje tabanlı öznitelik çıkarımının güçlü çözümler verebileceğini göstermiştir. Çalışmada görüntü sınıflandırma için obje tabanlı yaklaşımın piksel-tabanlı yaklaşım gibi geleneksel uzaktan algılama

sınıflandırma tekniklerinden çok daha iyi olduğu kanıtlanmıştır. Doğruluk değerlendirmesi sonuçlarının karşılaştırılması ile obje yönelimli görüntü analizinde %94 genel doğruluk elde edilirken piksel tabanlı sınıflandırma yaklaşımında %82 genel doğruluk elde edilmiştir. Ayrıca her bir sınıflandırılmış sınıf için yüksek üretici ve kullanıcı doğruluğu obje tabanlı öznitelik çıkarımında gösterilmiştir. F.S. Ahmadi ve arkadaşları (2008) kurak alanların ham uydu görüntüsünden LU/LC çıkarmak için dört sınıflandırma yöntemini karşılaştırmışlardır. Çalışma sonucuna göre en iyi sonuçlar, kontrollü sınıflandırma tekniklerinden olan en kısa uzaklık yöntemi, Mahalanobis uzaklığı yöntemi ve ISODATA sınıflandırma yönteminden ziyade Maksimum olabilirlik yöntemi için tespit edilmiştir. Çalışmalar doğruluk oranı yüksek haritaların oluşturulmasında çoklu sınıflandırma tekniklerinin kullanılmasının gerekli olduğunu göstermektedir.

Ayrıca araştırmacılar ön işleme ve iyileştirme yöntemleri olan PCA ve MNF'yi çalışmalarını desteklemek için kullanmaktadır. Mutlu (2010) çalışmasında Quikbird uydu verisine PCA uygulamıştır. Çalışmada özdeğerler, varyans ve özvektörler her bir temel bileşen (PC) için elde edilmiştir. PCA'yı kullanan diğer bir çalışma da Estornell ve arkadaşlarının (2013) çalışmasıdır. Javier iki alandan seçilen üç Landsat görüntüsü uydu görüntüsü kullanarak LC ile bilgi elde etmek için özellikle PCA analizi kullanmıştır. Federico Frassy'nin havadan hiperspektral verisinin sınıflandırmasını geliştirmek için MNF'yi kullandığı çalışması, iki farklı havadan hiperspektral veri grubundan MNF ile ön işleme yaparak bilgi çıkarmayı geliştirdiğini göstermiştir.

Bu tez çalışmasında piksel ve obje tabanlı görüntü sınıflandırma teknikleri yüksek çözünürlüklü RapidEye uydu görüntüsü üzerinde uygulanmış, görüntü zenginleştirme ve iyileştirme metotlarından olan PCA ve MNF analizleri gerçekleştirilmiş ve bu analizlerden elde edilen sonuçlardan yararlanılarak yeni çok bantlı uydu görüntüleri oluşturulmuş ve bu uygulamaların sınıflandırma sonuçlarına etkileri detaylı olarak analiz edilmiştir.


2. ÇALIŞMA ALANI VE METODOLOJİ

2.1 Çalışma Alanı

Çalışma alanı Türkiye’de Hatay ilinin Samandağ ilçesidir. Samandağ, Antakya şehir merkezine 25 km (16 dk) uzaklıkta, Suriye sınırına yakın, Akdeniz kıyısında Asi Nehrinin ağzında Türkiye’nin güneyinde bulunan Hatay ilinin bir ilçesidir. Şehir 36°05'13.17" Kuzey Enlemi ile 35°58'06.73" Doğu Boylamı arasında konumlanmış ve deniz seviyesinden yüksekliği 15 m’dir (URL-3). Akdeniz Bölgesi’nde bulunan Samandağ’ın batısında Akdeniz, kuzeyinde İskenderun, güneydoğusunda Yalayağ Dağı ve güneyinde Antakya bulunmaktadır. Bölge alanı yaklaşık 446 km²’dir. Şehir su kaynakları, tarım, ağaç, yerleşim alanı ve yol gibi değişik LU/LC gruplarını kapsamaktadır. Topraklarının büyük bir kısmı tarım ve ağaçla kaplanmıştır.

Ayrıca, Samandağ ilçesi Akdeniz’de önemli bir stratejik ve jeopolitik konuma sahiptir. Bölge üç dağ arasında bulunmaktadır: kuzey doğuda Samandağ, doğuda Dağdüzü ve güneyde Yaladağ. Nüfusu 117 770 olan Samandağ, çok kültürlü ve çok dinli bir şehirdir (URL-1). Etnik olarak nüfusunun çoğu Arapça konuşan Şii İslam’ın Alevi Mezhebine uyan insanlardan oluşur. Ayrıca Sünni Araplar, Türkmenler ve Kürtler vardır. İlçede yaklaşık 2000 kişiden oluşan üç Ermeni Antik Rum Hristiyan topluluğu bulunmaktadır. Vakıflı köyü Türkiye’nin tek kırsal Ermeni topluluğudur (URL-1).


Ek olarak Samandağ, Antakya’ya yakın küçük bir ilçedir. Yerel ekonomi balıkçılık ve tarım, özellikle de turuncgillere bağlıdır. Şekil 2.1’de çalışma alanı gösterilmiştir.



Şekil 2.1: Çalışma alanı.

2.2 Metodoloji

Bu bölüm, veri işleme, görüntü iyileştirme, dönüşüm yöntemleri ve görüntü sınıflandırma analizlerinden oluşmaktadır. Şekil 2.2 çalışmanın iş akışını göstermektedir.



Şekil 2.2: Araştırma iş akışı şeması.

2.2.1 Veri analizi

Uzaktan algılama verileri genellikle dijital görüntü verileridir. Dijital görüntü işlemede genellikle dört temel işlem uygulanır ve bu işlemler: görüntü restorasyonu, görüntü iyileştirme, görüntü sınıflandırma ve görüntü dönüşümüdür.

Uzaktan algılama görüntülerinin yorumlanması ve mümkün olduğu kadar daha fazla bilgi çıkarabilmek amacıyla birçok görüntü işleme ve analiz tekniği geliştirilmiştir. Görüntü iyileştirme ve görüntü sınıflandırma analizleri uzaktan algılama uygulamalarında yaygın olarak kullanılan veri işleme yöntemleridir. Çalışmada veri iyileştirme ve birçok sınıflandırma tekniği uygulanmıştır. Kullanılan özel teknik ve algoritmalar projenin amaçlarına bağlıdır. Veri işleme; konumsal alt küme verisi, görüntü iyileştirme, görüntü sınıflandırma ve doğruluk değerlendirmesi işlem adımlarından oluşmaktadır. Bu çalışmada, kontrollü sınıflandırma, kontrolsüz sınıflandırma ve obje tabanlı sınıflandırma teknikleri RapidEye uydu görüntüsüne uygulanmıştır. Bununla birlikte görüntü sınıflandırma işleminden önce bilinen iki görüntü iyileştirme ve dönüşüm yöntemi olan PCA ve MNF uygulanmıştır.

2.2.2 RapidEye uydu görüntüsü

Bu çalışmada 14 Eylül 2015 tarihine ait RapidEye ticari uydu görüntüsü kullanılmıştır. RapidEye uydusu 12 bit dinamik kapasite ile 5 m konumsal çözünürlüğü olan ticari bir uydudur. İlgili görüntü, uyduların sensör takım yıldızından elde edilmiştir ve yörüngesi güneş senkron yörüngede ve yaklaşık 630 km'dir. Bu çalışma için ilgi alanı Dünya Referans Sistemi (WRS) veri kümesi içinde yer alır, Coğrafi Koordinat Sistemi WGS-1984 ve projeksiyon koordinatları UTM Zone-37 Kuzey'dir.

Bu çalışmada RapidEye uydu görüntüleri ENVI v5.0 (Environment for Visualizing Images) programı ile başarılı bir şekilde incelenmiş ve kullanılmıştır. Uydu görüntüsü radyometrik ve geometrik düzeltmeleri yapılmış olarak temin edilmiştir. RapidEye uydu takımı Dünya gözlem endüstrisinde önemli bir milattır. 5 uydu ile benzersiz performans sergileyen ilk ticari Dünya gözlem sistemidir. RapidEye uydusunun kullanım alanları: tarım, çevre, ormancılık, haritalama, istihbarat ve savunma, güvenlik ve acil hizmetler ve görsel simülasyondur. Uydu üzerinde bulunan Black Bridge uyduları klorofil içindeki değişimlere karşı hassas olan RedEdge bandı, ticari olarak ilk kez bir uydu üzerinde bulunan bir bant aralığıdır. Bu bant aralığı, klorofil içeriği içindeki değişimlere karşı hassastır. Yapılan çalışmalar

bu bandın özellikle vejetasyon sağığının izlenmesi, biokütle içindeki protein ve nitrojen içeriğinin ölçülmesi ve ürün ayırımının daha rahat yapılabilmesine olanak sağlamaktadır. Ayrıca RapidEye görüntüleme yetenekleri petrol ve gaz arama, enerji, mühendislik, inşaat, yönetim, haritalama ve madencilik gibi birçok endüstride kullanılabilir. RapidEye MacDonald Dettwiler Ltd. tarafından tasarlanmıştır. MDA görüntü kullanıcılarına geniş alan kapsamlı, sık tekrarı olan, yüksek çözünürlüklü ve çoklu spektral özellikleriyle görüntü verisi sunmaktadır. Bu sistemi, 6.5 m nominal zemin çözünürlükte günde 4 Milyon km² gibi olağanüstü bir miktarda görüntü tarayarak toplamaktadır. Her bir uydunun hacmi 1 m³'den daha az, ağırlığı 150 kg, ve ömrü en az 7 yıl olacak şekilde tasarlanmıştır. Beş uydunun hepsi de aynı sensörle donatılmış ve aynı yörünge düzlemine yerleştirilmiştir Çizelge 2.1'de RapidEye uydusunun teknik özellikleri gösterilmiştir (URL-6).

2.3 Görüntü İyileştirme ve Dönüşüm Yöntemleri

Görüntü yorumlamayı daha üst seviyelere taşımak için bir objenin görünümü görüntü iyileştirme teknikleri ile geliştirilebilir. Görüntü iyileştirme, sonuçları göstermek için daha uygun olması ve ileri görüntü analizleri için dijital görüntüleri ayarlama işlemidir. Örnek olarak gürültü çıkarma, görüntüyü keskinleştirme veya aydınlatma işlemleri temel özellikleri tanımlamayı kolaylaştırmaktadır. Morfoloji operatörleri ile filtreleme, histogram eşitleme, gürültü giderme, doğrusal kontrast ayarı ve dekorelasyon germe gibi birçok görüntü zenginleştirme örnek ve yöntemi bulunmaktadır.

PCA ve MNF dönüşümleri, boyut küçültme, veri sıkıştırma ve gürültü azaltma gibi çeşitli uygulamalarda yaygın olarak kullanılan iki yöntemdir. Çoklu spektral ve hiperspektral uzaktan algılama görüntüsü görüntü oluşturmak için düzenlenmiş vektör bileşenlerinden oluşmaktadır. Bu vektör bileşenleri veya spektral bantları tamamen bağımsız bilgi içermemektedir. Ancak sensörlerin spektral örtüşmesi ve farklı dalga boylarındaki materyallerin yansıtımındaki ilişkilerden dolayı genellikle bir ölçüde ilişkilidir (Rao vd., 1996). Uzaktan algılama uygulamalarında, ana kriter görüntü kalitesini arttırmak için verinin boyutunu azaltmak ve gürültü çıkarmaktır (PCA ve MNF) (Leonidas, 2004). Bu çalışmada tüm veri analizleri için ENVI v.5.0 yazılımı kullanılmıştır.

Çizelge 2. 1: RapidEye uydu görüntüsünün teknik özellikler.

Görev Özellikleri	Bilgi												
Uydu Sayısı	5												
Uzay Aracı Ömrü	7 yıldan fazla												
Yörünge Yüksekliği	630 km sabit konumlu yörüngede												
Ekvator Geçiş Zamanı	11:00 am												
Sensör Tipi	Çok spektrumlu push broom görüntüleyici												
Spektral Bandlar	Spektral bantların hepsi												
	<table><tr><th>Band adı</th><th>Spektral aralık (nm)</th></tr><tr><td>Mavi</td><td>440-510</td></tr><tr><td>Yeşil</td><td>520-590</td></tr><tr><td>Kırmızı</td><td>630-685</td></tr><tr><td>Kızıl Kenar</td><td>690-730</td></tr><tr><td>Yakın Kızılöte</td><td>660-850</td></tr></table>	Band adı	Spektral aralık (nm)	Mavi	440-510	Yeşil	520-590	Kırmızı	630-685	Kızıl Kenar	690-730	Yakın Kızılöte	660-850
Band adı	Spektral aralık (nm)												
Mavi	440-510												
Yeşil	520-590												
Kırmızı	630-685												
Kızıl Kenar	690-730												
Yakın Kızılöte	660-850												
Yersel Çözünürlüğü	6.5 m												
Piksel Boyutu	5 m												
Şerit Çekim Genişliği	77 km												
Uydu Üzerindeki Veri Saklama Kapasitesi	Her yörünge geçişi için 1500 km'lik veri toplama kapasitesi												
Yeniden Geçiş Zamanı	Günlük(nadirdışı)-5.5 gün(nadirde)												
Görüntü Çekme Kapasitesi	4 milyon km ² /gün												
Dinamik Aralığı	12 bit												

2.3.1 Ana bileşenler analizi (Principal Component Analysis-PCA)

Ana Bileşenler Analizi (Principal Component Analysis-PCA) ikinci derece istatistiğe dayalı yaygın olarak kullanılan lineer boyut yöntemidir. Ayrıca, PCA Karhunen-Loeve dönüşümü, tekil değer ayrışımı (SVD), deneysel ortogonal fonksiyonu (EOF) ve Hotelling dönüşümü olarak da bilinir. PCA, belirli bir sayıda korelasyonlu değişkenleri ana bileşenler olarak adlandırılan daha az sayıda korelasyonsuz değişkenlere dönüştürerek büyük veri gruplarının basitleştirilmesini kolaylaştıran matematiksel bir yöntemdir. Veri sıkıştırma, veri boyutu azaltma ve gürültü bileşenlerinin ayrılması ile bilgi zenginleştirme uzaktan algılamada kullanılan temel PCA uygulamalarıdır. Bir biriyle ilişkili koordinat eksenleri olan orijinal koordinat sistemini döndürerek bağımsız yeni koordinat sisteminin oluşturulmasını amaçlamaktır. Bu sayede spektral değişkenlik maksimize edilmektedir. Elde edilen

PC bantları orijinal spektral bantların lineer kombinasyonu olup bağımsızdır (Leonidas, 2004).

Birinci PC bandı verinin en büyük varyans yüzdesini içerir, ikinci PC bandı verinin ikinci en büyük varyans yüzdesini içerir ve bu şekilde devam eder. Çok düşük varyans içerdiğinden dolayı son bant gürültülü görünmektedir. Ana bileşenler bantları, veri ilişkili olmadığı için spektral renkli kompozit görüntülerden daha renkli kompozit görüntüler üretir (Richard, 1999).

2.3.1.1 Özvektörler çıkarımı

Ana bileşenler $X_1, \dots, X_k, \dots, X_m$ değişkenlerinin doğrusal kombinasyonlarıdır. Çıkarılan özvektörler aşağıda verilen denklemler için katsayıları sağlar. Özvektörler ana bileşenler için satır ve sütun bant katkılarıdır (Exiles, 2012).

$$Y_k = C_{k1} + C_{k2} + \dots + C_{km}X_m \quad (2.1)$$

Y_k , k-ıncı temel bileşen, C's tablodaki katsayılarıdır. kayışat arsa uygun sayıda temel bileşen belirlemek için faydalı bir görsel yardımdır. kayışat arsa bileşen numarasına karşılık gelen özdeğeri çizer. Uygun sayıda bileşen belirlemek için scree plot'ta elbow'a bakılır. Bileşen sayısı özdeğerler küçük ve aynı boyutta olduğunda nokta olarak alınır.

2.3.1.2 Özdeğer

Korelasyon/kovaryans matrisinin özdeğeri her bir temel bileşen için toplam varyasyonun bir bölümünü vermektedir.

PCA uygulama alanları:


- Veri görselleştirme
- Veri sıkıştırma
- Gürültü azaltma
- Veri sınıflandırma
- Trend analizi
- Faktör analizi
- Veriyi ileri analizler için hazırlama

2.3.2 Minimum gürültü bölümlemesi (Minimum Noise Fraction – MNF)

MNF, görüntü iyileştirme ve zenginleştirme teknikleri ailesinden ikinci önemli algoritmadır. Yöntem sensör gürültüsünü hesaplayan yöntem olarak Green, Berman, Switzer ve Graig tarafından 1998’de geliştirilmiştir. Temel PCA yöntemi sadece her bir bileşenin varyansını ve gürültünün izotropik olduğunu varsayarak gerçekleştirilir. Ancak gerçek sensör gürültüsü genellikle izotropik veya beyaz değildir. Ayrıca gürültü bileşenlerinin varyansı görüntünün yerel bilgisini veren bileşenlerin varyansından büyük olabilir. Bu yüzden varyansın temel bileşen sayısı ile azalmasına rağmen PCA her zaman görüntü kalitesi azalmış görüntüler üretmez (Leonidas, 2004).

MNF dönüşümü analiz edilecek spektral boyutların sayısını azaltmak için kullanılır. MNF dönüşümü, sinyal gürültü oranına göre uygulanan temel bileşenlerle ilgili lineer bir dönüşümdür (Green vd., 1998). Verinin asıl boyutunu belirlemek, verideki gürültüyü çıkarmak, sonraki işlemler için hesaplama yükünü azaltmak için kullanılır (Green vd. 1998, Boardman ve Kruse 1994).

MNF dönüşümü veri alanını iki kısma ayırmak için kullanılabilir: birincisi büyük özdeğerler ve koherent Eigen görüntüler, ikincisi near-unity özdeğerler ve gürültü-baskın görüntülerdir. Gürültü sonraki işlemde koherent kısımları kullanarak ayrıştırılır ve bu sayede spektral işleme sonuçları iyileştirilir. Bu dönüşüm uygulaması sinyal ve gürültü kovaryans matrislerinin kestirim bilgisini gerektirir. İlk dönüşüm sensör gürültüsü için kovaryans matrisinden elde edilmiştir ve ilişkiye göre dekor tasarlanmış ve gürültüye göre detay beyazlatılmıştır. Bu işlemde ana zorluk sensör gürültüsünün uygun bir kestirimini elde etmektir. MNF dönüşümü iki PC dönüşümünü içerir. Gürültü kovaryans matrisi tahminine dayalı birinci dönüşüm, birim varyans ile ilişkisiz gürültü için dönüştürülmüş data ile sonuçlanır. İkinci dönüşüm beyaz gürültülü veride temel PCA’dır. Daha sonra özdeğerler ve ilgili görüntüler Eigen gürültüler olarak isimlendirilir. MNF dönüşümü, uzaktan algılama ve görüntü işleme toplulukları tarafından yaygın olarak kullanılmaktadır, çünkü bu yöntem görüntü kalitesi açısından multispektral ve hiperspektral görüntülerin sıkıştırılması ve düzenlenmesinde PCA’dan genellikle daha iyidir. Şekil 2.3’te ENVI de MNF kullanım şeması verilmiştir.



Şekil 2.3: ENVI’de MNF kullanım şeması.

2.4 Görüntü Sınıflandırma

Görüntü sınıflandırma bir alan içindeki piksel grubunun sınıflandırılmasından sonra nesneler ve pikselleri tanımlama işlemidir. Görüntüdeki özellikleri sınıflandırmak için çalışan bir analist çeşitli özellikler veya ilgili LC sınıflarını temsil eden pikselin homojen gruplarını tanımlamak için görsel yorumlama elemanlarını kullanmaktadır. Görüntüdeki farklı LC türleri, her pikselde bulunan parlaklık ve renk bilgisi gibi spektral özellikleri kullanan bazı görüntü sınıflandırma algoritmalarını kullanarak ayırt edilebilmektedir. Sınıflandırma işlemi piksel tabanlı veya obje tabanlı olabilmektedir.

Sınıflandırma işleminin amacı bir dijital görüntüdeki bütün pikselleri bir ya da birkaç LC sınıfına veya “temaları”na kategorize etmektir. Bu sınıflandırılmış data daha sonra bir görüntüde mevcut arazi örtüsünün tematik haritalarını üretmek için kullanılabilir. Normalde, çok bantlı data sınıflandırma yapmak için kullanılmaktadır (Lillesand vd., 2004). Görüntü sınıflandırma belki de dijital görüntü analizinin en önemli parçasıdır. Tematik harita, tanımlanabilir yeryüzü özelliklerinin mekansal dağılımını göstermektedir ve data tanımlaması yerine belirli bir alan üzerinde bir bilgi açıklaması sağlamaktadır (Schowengerdt, 2007).

Sınıflandırma algoritmaları parametrik ve parametrik olmayan olmak üzere iki gruba ayrılmaktadır. Parametrik algoritmalar genellikle normal dağılım olmak üzere

istatistiksel dağılımın belirli bir sınıfını varsaymaktadır. Parametrik olmayan algoritmalar istatistiksel dağılım hakkında varsayım yapmamaktadır, parametrik olmayan algoritmalar genellikle robust olarak kabul edilmektedir. Bu bölümde uzaktan algılama sınıflandırma tekniklerinden seçilen metotlar tanımlanmıştır.

Bu çalışmada piksel ve obje tabanlı sınıflandırma yöntemleri kullanılmıştır. Uzaktan algılama görüntülerinin sınıflandırılmasında yaygın olarak kullanılan birçok yöntem görüntü bantlarında bulunan radyometrik bilgilere dayanmaktadır. İdeal olarak, piksellerin bir dereceye kadar farklı arazi örtüsüne karşılık gelen kümelerde multispektral uzayda daha fazla veya daha az gruplandırılması beklenmektedir (Price, 1994). Geleneksel olarak kullanılan sınıflandırma tekniği olan piksel tabanlı yaklaşım geleneksel istatistiksel tekniklere dayalı olan bu işlemlerden birisidir. Bu yaklaşım iyi bir performans sergilemekte, fakat sınıflar arası karışıklığı çözmek için yeteneği sınırlıdır, sonuç olarak son yıllarda bilgisayar teknolojisindeki gelişmelerle birlikte özellikle yapay sinir ağlarının kullanımı, karar ağaçları, bulanık küme teorisinden türetilen yöntemler ve arazi özellikleri, bağlam ve doku gibi ikincil bilgilerin eklenmesi gibi alternatif stratejiler önerilmiştir (Mather vd., 2001).

Bu tez çalışmasında iki sınıflandırma yaklaşımı çalışılmıştır. Bu yöntemler piksel tabanlı görüntü analizi yaklaşımı ve yeni geliştirilen nesne yönelimli görüntü analizi olan özellik çıkarma yaklaşımıdır. Piksel tabanlı paralel kenar yöntemi, en kısa uzaklık yöntemi, Mahalanobis uzaklığı yöntemi ve maksimum olasılık yöntemi gibi geleneksel istatistiksel tekniklere dayanmaktadır. Bu teknikler aşağıda daha ayrıntılı olarak anlatılacaktır. Piksel tabanlı sınıflandırma yaklaşımı görüntüyü her bir pikseli tek tek kullanarak piksel sınıflandırır.

Obje tabanlı görüntü analizi yaklaşımı ile sınıflandırma bilgisi olarak sadece görüntüdeki spektral bilgi değil, görüntüdeki doku ve bağlam bilgileri de sınıflandırmada kombine bir şekilde kullanılacaktır. Görüntü sınıflandırma birimleri oluşturulan objelere bölünecek ve sınıflandırma işleminde bütün olarak işlenecektir. Objeye tabanlı görüntü sınıflandırma yaklaşımı fuzzy teorisine dayalıdır ve farklı üyelik değerleri ile bir objede birden fazla sınıf oluşturarak sınıflandırma yapmaktadır. Bu iki yaklaşım aşağıda detaylı olarak anlatılacaktır.


2.4.1 Piksel tabanlı görüntü sınıflandırma

Piksel tabanlı görüntü analizi, görüntüdeki spektral bilgiye göre uzaktan algılama görüntülerini sınıflandıran klasik görüntü sınıflandırma yöntemi anlamına gelir.

Piksel tabanlı sınıflandırma görüntüdeki her bir pikseli tek tek kullanarak görüntüyü sınıflandırır yani bir piksel sadece bir sınıfa ait olabilir. Piksel tabanlı sınıflandırmada, kontrollü sınıflandırma ve kontrolsüz sınıflandırma olmak üzere iki geleneksel sınıflandırma yöntemi vardır.

2.4.1.1 Kontrollü sınıflandırma

Kontrollü sınıflandırmada, görüntü analisti piksel sınıflandırma işlemini görüntüde mevcut olan Arazi Örtüsü çeşitlerini sayısal tanımlayıcılar ile bilgisayar algoritmasında kontrol etmektedir. LC sınıflarının tipik spektral örneklerini tanımlayan örnekleme alanları tanımlanır. Görüntüdeki pikseller örnekleme alanları ile sayısal olarak karşılaştırılır ve benzer özelliklere sahip LC sınıfı kategorisine dâhil edilir. Kontrollü sınıflandırma yönteminin üç temel aşaması: örnekleme adımı, sınıflandırma adımı ve doğruluk değerlendirmesi adımıdır (Şekil 2.4).




Şekil 2.4: Kontrollü sınıflandırma adımları.

Örnekleme adımının temel amacı, her bir arazi örtüsü çeşidini temsil edecek örnekleme bölgelerinin seçilmesi ve bu bölgelerin spektral özelliklerini açıklayacak sayısal değerlerin geliştirilmesidir. Örnekleme adımında her bir arazi örtüsü sınıfı için konum, boyut, şekil ve nokta bulutlarının oryantasyonu belirlenmektedir (Lillesand, 2001).

Örnekleme alanları görüntüdeki arazi örtüsü sınıflarının tipik spektral bilgisini temsil eden piksel değerleridir ve sınıflandırıcı oluşturmak için kullanıcı tarafından seçilmektedir. Kabul edilebilir sınıflandırma sonuçları için çalışılan veri, temsilci ve tam olmalıdır. Bunun anlamı her bir bilgi sınıfı için örnekleme alanları karakteristik olmalı ve bilgi sınıfı için tüm spektral değişkenliği kapsamalıdır (Mather, 1987). Diğer bir deyişle, her bilgi sınıfı için oluşturulan spektral sınıflar, görüntü

sınıflandırma için kullanılan örnekleme seti istatistiğinde yeterli bir şekilde temsil edilmelidir (Lillsand, 2001).Örnekleme alanları çeşitli araçlardan (örneğin fare) herhangi biri ile control edilen bir referans imleci kullanarak çalışma alanının özetlenmesi ile oluşturulabilir. Örnekleme alanları seçilirken arazi örtüsü türleri arasında kenarlar boyunca bulunan piksellerde seçilen örnekleme alanlarının tipik spektral bilgi bulundurduğundan emin olunmalıdır (Lillesand, 2001). Bu çalışmada, LU/LC haritalaması için çalışma alanı “Bina, Yol, Boş Alan, Ağaç, Sulak Alan, Çim Alan, Tarım Alanı” olmak üzere toplam 7 sınıfa ayrılmıştır. Her bir sınıftan kontrollü sınıflandırma işlemini yapmak için ayrı ayrı örnek alan seçimleri gerçekleştirilmiştir. Bu sınıflandırma adımı, örnekleme alanları seti ve kesin bir sınıflandırma algoritması belirtildikten sonra sınıflandırma gerçekleştirilir. Yaygın olarak kullanılan sınıflandırma algoritmaları (sınıflandırıcılar) aşağıda detaylı olarak anlatılacaktır. Görüntüdeki pikseller her bir örnekleme alanıyla sayısal olarak karşılaştırılır ve belirli algoritmalara göre arazi örtüsü sınıflarına dâhil edilir.Piksel tabanlı görüntü analizinde kullanılan klasik sınıflandırıcılar güçlü sınıflandırıcılardır. Bu sınıflandırıcılar objeye 1 ve 0 ilişki değerleri atayarak bir objenin belirli bir sınıfa ait olup olmadığını ifade eder. Sınıflandırıcıların objelerin ilişkisini sadece ikili biçimde (evet veya hayır) ifade ettiği için bu sınıflandırıcılar ‘güçlü sınıflandırıcılar’ olarak isimlendirilmektedir. Paralel kenar, En kısa uzaklık, mahalnobis uzaklığı, En çok benzerlik, IsoData, K-Means ve obje tabanlı özellik çıkarım SVM yöntemidir yaygın olarak kullanılan sınıflandırıcılardır.


Paralel kenar yöntemi: Paralel kenar sınıflandırıcı varyansa duyarlı olduğundan her kategorideki örnekleme setinde spektral değerlerin aralığını dikkate almaktadır (Lillesand, 2001). Bu aralık ile tanımlanabilir en yüksek ve en düşük dijital piksel değerleri tanımlanmaktadır. Paralel kenar sınıflandırıcı hesap yönünden çok hızlıdır (Lillesand, 2001). Şekil 2.5’te paralel kenar sınıflandırıcının duyarlılığı gösterilmektedir.



Şekil 2.5: Paralel kenar sınıflandırıcı.

En kısa uzaklık yöntemi: En kısa uzaklık sınıflandırıcı ile görüntü sınıflandırırken ilk olarak her bir bilgi sınıfı için her bantta ortalama spektral değerler belirlenir. Bu spektral değerler, her sınıf için ortalama vektör içermektedir. Bilinmeyen piksel ile her bir sınıf arasındaki uzaklığın hesaplanmasıyla tanımlanamayan her hangi bir piksel sınıflandırılabilir. Eğer piksel analistin tanımladığı herhangi bir sınıfın ortalamasından olan uzaklıktan daha ileride olsaydı, ‘bilinmeyen’ olarak sınıflandırılacaktı (Lillesand, 2001).


Mesafe sınırı her bir sınıf için sınıfın beklenen yoğunluk derecesine bağlı olarak değişebilir. Yoğunluk, belirli bir sınıf için örnekleme alanları oluşturulan piksellerin her özelliği için standart sapmadan kestirilebilir (Mather, 1987). En kısa uzaklık sınıflandırma stratejisi matematiksel olarak basit ve hesaplama zamanı kısadır ancak bazı sınırlamaları bulunmaktadır. Fakat spektral tepki verilerinde mevcut olan farklı derecedeki varyans değişimlerine duyarlı değildir. Bu sebeple, bu sınıflandırıcılar ölçme uzayında spektral sınıfların bir birine çok yakın olduğu ve yüksek varyansın olduğu uygulamalarda yaygın olarak kullanılmamaktadır (Lillesand, 2001). Şekil 2.6’da en kısa uzaklık sınıflandırıcı gösterilmiştir.



Şekil 2.6: En kısa uzaklık sınıflandırıcı.

Mahalanobis uzaklığı yöntemi: Mahalanobis uzaklık sınıflandırması her sınıf için istatistik kullanan doğrultu duyarlı uzaklık sınıflandırıcısıdır. Bu yöntem maksimum olabilirlik sınıflandırmaya benzemektedir fakat bütün sınıfların kovaryanslarının eşit olduğunu varsayar ve bu yüzden daha hızlı bir yöntemdir. Tüm pikseller bir mesafe eşiği belirtilmediği sürece en yakın ROI sınıfına sınıflandırılmaktadır (Richards, 1999).

En çok benzerlik yöntemi : Maksimum olabilirlik karar kuralı, her sınıfın olasılık yoğunluk fonksiyonunun normalleştirilmiş (Gauss) kestirimine dayanmaktadır (Pedroni, 2003). Maksimum olabilirlik sınıflandırıcı bilinmeyen pikseli sınıflandırırken spektral tepki patternlerinin varyans ve kovaryanslarını hesaplamaktadır. Maksimum olabilirlik sınıflandırıcı örnekleme veri sınıfını oluşturan nokta bulutunun dağılımını normal dağılımlı (Gauss) kabul eder. Bu varsayım altında, kategori tepki patterninin (category response pattern) dağılımı ortalama vektör ve kovaryans matrisi ile tamamen tanımlanabilmektedir. Bu parametrelerin verilmesiyle, belirli bir arazi örtüsü sınıfının üyesi olan verilen piksel değerinin istatistiksel olasılığı hesaplanabilmektedir. Tanımlanan piksel her bir kategoriye ait olan piksel değerinin olasılığının hesaplanmasıyla sınıflandırılmaktadır. Her sınıfın olasılığının hesaplanmasından sonra, piksel olasılık değerine göre en çok benzediği sınıfa atanır veya eğer pikselin olasılık değeri tüm sınıfların olasılık değerinin altındaysa piksel 'bilinmeyen' olarak etiketlenir (Lillesand, 2001). Bu yöntemin başlıca zorluğu her bir pikseli sınıflandırmak için gerekli olan hesap yükünün fazla olmasıdır. Bu durum özellikle çok sayıda spektral kanallar olduğunda veya ayırt edilmesi gereken spektral sınıfın çok fazla olduğu durumlarda geçerlidir. Maksimum olabilirlik sınıflandırıcı önceki tekniklere göre hesaplama yönünden çok daha yavaştır (Lillesand, 2001). Şekil 2.7'de maksimum olabilirlik sınıflandırıcı gösterilmiştir.



Şekil 2.7: Maksimum olabilirlik sınıflandırıcı.

2.4.1.2 Kontrolsüz sınıflandırma


Kontrolsüz sınıflandırma, arazi örtüsü çeşitlerinin dağılımları hakkında yeterli bilgi bulunmadığı durumlarda kullanılmaktadır. Kontrolsüz sınıflandırmanın sonuçları spektral sınıflardır. Arazi örtüsü çeşitleri ile spektral sınıfın referans verisini kullanarak ilişkilendirmek analist tarafından yapılmaktadır.

Kontrolsüz sınıflandırma, sınıflandırma için temel olarak örnekleme verisini kullanmamaktadır. Sınıflandırıcılar görüntüdeki bilinmeyen pikselleri inceler ve bu pikselleri doğal gruplamaya dayalı olarak sınıflandırır. Burada temel kriter, belirli bir örtü çeşiti içindeki değerlerin ölçme uzayında birbirine yakın olmasıdır, oysa farklı sınıf verileri oldukça iyi ayrılmalıdır (Lillesand, 2011).

Kontrolsüz sınıflandırma adımları:

- Kümeleri oluşturma
- Kümelere atama

Şekil 2.8’de kontrolsüz sınıflandırma adımlarının diyagramı gösterilmektedir.



Şekil 2.8: Kontrolsüz sınıflandırma adımları.

Kontrolsüz sınıflandırmada K-Ortalama (K-Means) ve ISODATA sınıflandırma olmak üzere iki farklı algoritma kullanılmaktadır.

ISODATA sınıflandırma: ISODATA kontrolsüz sınıflandırma eşit dağılmış data uzayında sınıf ortalamalarını hesaplar ve iteratif bir şekilde pikselleri en yakın mesafe tekniğine göre kümeler. Her iterasyon ortalamayı yeniden hesaplamaktadır ve yeni ortalama göre pikselleri tekrar sınıflandırmaktadır. Bu işlem seçilen piksel değişim değerinden küçük olana kadar veya maksimum iterasyon sayısına ulaşana kadar devam etmektedir (Tou J.T. vd., 1974).


K-Means sınıflandırma: K-Means kontrolsüz sınıflandırma eşit dağılımlı veri uzayında birinci sınıf ortalamalarını hesaplar sonra iteratif bir şekilde pikselleri minimum mesafe tekniğini kullanarak en yakın sınıfa kümeler. Her iterasyon sınıf ortalamasını tekrar hesaplar ve pikselleri yeni ortalamalara göre yeniden sınıflandırır. Seçili kriterlere uymayan piksellerin sınıflandırılmamasının olabileceği durumlarda bir standart sapma veya uzaklık eşiği belirtilmediği sürece tüm pikseller en yakın sınıfa sınıflandırılırlar. Bu işlem seçilen piksel değişim değerinden küçük olana kadar veya maksimum iterasyon sayısına ulaşana kadar devam etmektedir (Tou J.T. vd., 1974).

2.4.2 Obje tabanlı görüntü sınıflandırma

Obje tabanlı sınıflandırma yöntemi özellikle dar bantlı ve yüksek konumsal çözünürlüğü olan veride daha başarılı sonuçlar elde etmektedir (Willhauck, 2000). Piksel odaklı yaklaşım yerine obje yönelimli yaklaşım ile sınıflandırma uygulamasının birçok avantajı bulunmaktadır. Görüntü objeleri spektral bilgilerin yanında sınıflandırmada kullanılabilecek ilave özellikler (şekil, doku, ilişkisel ve bağlamsal bilgiler) içermektedir (Baatz vd., 2000). Bu durumda sınıflandırma işlemi, homojen birimler veya objelerdeki komşu piksellerin segmentasyonu ile başlar (Baatz vd., 2004). Görüntü sınıflandırmada obje yönelimli yöntemler son yıllarda EXILES VIS tarafından geliştirilen ve özellik çıkarımı aracı olan ENVI v5.0 uzaktan algılama yazılımı sayesinde daha popüler hale gelmiştir. Obje tabanlı sınıflandırmada farklı ölçek seviyelerinde ve farklı büyüklüklerde piksellerin gruplandırıldığı segmenteler oluşturulur. Şekil 2.9’da obje tabanlı görüntü sınıflandırma özelliği çıkarımı süreci gösterilmektedir (URL-7).

Piksel tabanlı görüntü analizi ve obje tabanlı görüntü analizi arasındaki en temel fark, obje tabanlı görüntü analizinde temel işleme birimleri tek piksel değil, görüntü obje veya segmentleridir. Diğer bir fark, obje tabanlı görüntü analizinde kullanılan sınıflandırıcılar bulanık mantığa dayalı olan yumuşak sınıflandırıcılardır. Obje tabanlı görüntü analizinde temel işleme birimleri objeler veya piksel kümeleridir. Görüntü analizinde obje tabanlı yaklaşımda birinci adım görüntü segmentasyonu ile işleme birimlerini oluşturmaktır. Görüntü segmentasyonu, obje tabanlı görüntü analizinde temel yapı taşlarını sağlamak için çok önemlidir (Gao Yan, 2003). Birçok durumda görüntü segmentasyonundaki beklenti belirli bir iş için görüntüdeki istenen ilgili objeleri otomatik olarak çıkarabilmektir (Gao Yan, 2003). ENVI v.5.0

yazılımının tabanlı özellik çıkarımı, kural tabanlı özellik çıkarımı, sadece özellik çıkarımı segmenti ve görüntü segmentasyonu gibi güçlü özellik çıkarımı uygulamaları vardır (URL-7).



Şekil 2.9: Obje tabanlı özellik çıkarım adımları.

2.5 Doğruluk Analizi

Kontrollü sınıflandırma yönteminin üçüncü ve son aşaması yapılan analizlerin doğruluk değerlendirmesidir. Doğruluğu değerlendirilene kadar hiç bir sınıflandırma tam değildir (Lillesand, 2001). Bu çalışmada doğruluk, sınıflandırıcı tarafından atanan etiketler ile test verisi olarak kullanıcı tarafından zeminden toplanan test verisinin uyum derecesi anlamına gelmektedir.

Haritanın örneklerinde haritanın doğruluğu ile ilgili geçerli sonuçlar elde edebilmek için örnekler özenli bir şekilde seçilmelidir. Bu önemli kriter ile ilgili başarısızlık bu veriyi kullanılarak daha sonra yapılacak analizlerin geçerliliğini olumsuz yönde etkileyecektir. Çünkü elde edilen hata matrisi gerçek doğruluğu düşük veya yüksek tahmin edilebilir. Doğruluk değerlendirme maliyetini önemli ölçüde etkileyen

örnekleme şeması, arazi karşısındaki örneklerin dağılımını belirler (Congalton vd., 1998). Sınıflandırılmış görüntünün bütünü için doğruluk değerlendirmesi yaparken bilinen referans verisi sınıflandırıcıları eğitmek için kullanılan gruptan farklı başka bir veri grubu olmalıdır. Eğer örnekleme alanları referans verisi olarak kullanılırsa, doğruluk değerlendirme sonuçları sadece örnekleme alanlarının nasıl sınıflandırıldığını gösterir, sınıflandırıcıların nasıl performans gösterdiğini göstermez (Lillesand, 2001). Doğruluk değerlendirmesi yapmak için yaygın olarak kullanılan iki yöntem aşağıda anlatılacaktır.

2.5.1 Hata matrisi

Hata matrisi, sınıflandırma sonuçları ile arazi araştırması bilgilerini karşılaştırarak sınıflandırma sonuçlarının doğruluğunu göstermektedir. ENVI klasik yazılımı hata matrisini yer araştırma görüntüsünü veya zemin gerçeği kullanarak ilgi bölgesi kullanarak hesaplayabilmektedir. Her iki durumda da, genel doğruluk, üretici ve kullanıcı doğruluğu, kappa katsayısı, hata matrisi, komisyon ve ihmal hataları rapor edilmektedir. Şekil 2.10'de hata matrisi doğruluk değerlendirme yöntemi gösterilmiştir.

Sınıf	bina	yol	sukak alan	tarım alanı	ağaç
Sınıflandırılmamış	0	0	0	0	0
bina [Sa]	32	1	0	1	0
yol [Siyah]	68	52	0	5	0
sulak alan [Mavi]	0	51	258	0	0
tarım alanı [Yeşil]	7	0	0	323	160
ağaç [Beyaz]	15	6	22	33	0
Toplam	122	110	280	377	160

Sınıf	boş	Toplam
Sınıflandırılmamış	0	0
bina [Sa]	2	36
yol [Siyah]	3	128
sulak alan [Mavi]	0	258
tarım alanı	150	531

Şekil 2.10: ENVI klasik yazılımındaki hata matrisi.

2.5.2 Genel doğruluk

Genel doğruluk sınıflandırılmış piksellerin sayısının doğru bir şekilde toplanmasıyla ve toplam piksel sayısına bölünmesiyle hesaplanmaktadır. Arazi araştırması görüntüsü ve zemin gerçeği ilgi bölgesi piksellerin doğru sınıfını tanımlamaktadır. Doğru sınıflandırılmış pikseller doğru arazi araştırması sınıfına sınıflandırılan piksellerin sayısını listeleyen hata matrisinin köşegeninde bulunmaktadır. Toplam piksel sayısı, arazi araştırması sınıflarındaki tüm piksellerin toplamıdır.

2.5.3 Kappa katsayısı

Kappa katsayısı (k), sınıflandırmanın doğruluğu ölçmek için kullanılan bir diğer ölçüdür. Tüm gerçek zemin sınıflarındaki (N) toplam piksel sayısının, karışıklık matris diyagonallerinin toplamı ile çarpılıp (x_{kk}), bu sonuçtan bir sınıftaki gerçek zemin pikselleri toplamı ile o sınıfta sınıflandırılmış piksellerin tüm sınıflar ($X_K \sum X \sum_K$) için toplam sayısı ile çarpımının çıkarılması ve toplam piksel sayısının karesinden o sınıftaki gerçek zemin piksellerinin toplamı ile sınıflandırılmış piksellerin tüm sınıflar için toplamının çarpımına bölünmesi ile hesaplanır (2.2).


$$K^x = \frac{N_K \sum_K x_{KK} - K \sum_K x_K x_K}{N^2 - K \sum_K x_K x_K} \quad (2.2)$$

Üretici doğruluğu: Üretici doğruluğu, gerçek zeminin A Sınıfı olduğu göz önüne alındığında sınıflandırıcının görüntü pikselini A sınıfına atama olasılığını gösteren bir ölçüttür. Yapılan tez çalışmasında, kullanılan tüm sınıflandırma metotlarında elde edilen üretici doğrulukları Çizelge 3.4'te verilmiştir.


Kullanıcı doğruluğu: Kullanıcı doğruluğu, sınıflandırıcının pikseli A sınıfına atadığında pikselin A sınıfında olma olasılığını gösteren bir ölçüttür. Yapılan tez çalışmasında kullanılan tüm sınıflandırma metotlarında elde edilen kullanıcı doğrulukları Çizelge 3.4'te verilmiştir.

3. ARAŞTIRMA BULGULARI

Bu çalışmada piksel ve obje tabanlı sınıflandırma yöntemleri kullanılmıştır. Piksel tabanlı sınıflandırma yönteminde Paralel Kenar, En Kısa Uzaklık, En Çok Benzerlik ve Mahalonobis Uzaklığı kontrollü sınıflandırma yöntemleri, K-means ve Isodata kontrolsüz sınıflandırma yöntemleri ve obje tabanlı SVM sınıflandırma yöntemi kullanılarak orijinal görüntü üzerinden toplam 7 sınıflandırma işlemi gerçekleştirilmiştir. Çalışmada, PCA ve Minimum Gürültü Bölümlemesi (Minimum NoiseFraction- MNF) görüntü iyileştirme teknikleri orijinal görüntüye uygulanmıştır. Uygulama sonucunda elde edilen PCA ve MNF bandlarının ilk üç bandı orijinal görüntü bandlarına eklenerek yeni çok bantlı görüntüler elde edilmiştir. Uzaktan algılama uygulamalarında PCA ve MNF gibi yöntemlerden elde edilen sonuçlarda en çok görüntü bilgisi ilk üç bantta toplandığı için orijinal görüntüye bu bandlar eklenmiştir (Şekil 3.1 ve Şekil 3.2). Elde edilen çok bantlı yeni PCA-orijinal ve MNF-orijinal görüntülerine piksel (kontrollü ve kontrolsüz sınıflandırma) ve obje tabanlı sınıflandırma yöntemleri tekrar uygulanmış ve bu yöntemlerin sınıflandırma sonucuna etkileri analiz edilmiştir. Sonuç olarak, toplamda 18 tane piksel tabanlı ve 3 tane obje tabanlı sınıflandırılmış görüntü elde edilmiştir.



Şekil 3.1: MNF sonuçları.



Şekil 3.2: PCA sonuçları.

Yapılan kontrollü, kontrolsüz ve obje tabanlı sınıflandırma işlemlerinin doğruluğunu analiz etmek için hata matrisi oluşturulmuştur (Çizelge 3.1, Çizelge 3.2 ve Çizelge 3.3). Hata matrisinde referans verileri Google Earth ve bölgeye ait ortofotolardan elde edilmiştir. Hata matrislerinden genel doğruluk, üretici doğruluğu, kullanıcı doğruluğu ve Kappa istatistiği elde edilmiştir. Kappa katsayısı, sınıflandırma ile doğruluk değerleri arasındaki uyumu ölçmektedir, değerinin 1 olması, mükemmel bir uyumayı temsil ederken, 0 olması, hiçbir uyumayı temsil etmez. (Çizelge 3.4). Kontrollü sınıflandırma işleminin sonuçlarına bakıldığında zaman, MNF-Orijinal görüntüye uygulanan sınıflandırma işlemlerinde en yüksek doğruluk % 70.33 ve 0.61 kapa istatistiği ile En Çok Benzerlik yönteminden elde edilmiştir (Şekil 3.3 (a)). MNF-orijinal görüntüye uygulanan kontrolsüz sınıflandırma işleminde en iyi sonuç % 59.37 ve 0.48 kapa istatistiği ile ISODATA dan elde edilmiştir (Şekil 3.3 (b)). Objeye tabanlı sınıflandırma işleminde en yüksek doğruluk %80.45 ve 0.74 kapa istatistiği ile orijinal görüntüden elde edilmiştir (Şekil 3.3 (c)).

Çizelge 3.1: Kontrollü sınıflandırma yöntemi sonuçlarına ait hata matrisi.

	Bina	Yol	Sulak Alan	Tarım Alanı	Ağaç	Boş Alan	Toplam
Bina	32	1	0	1	0	2	36
Yol	68	52	0	5	0	3	128
Sulak Alan	0	0	258	0	0	0	258
Tarım Alanı	7	51	0	323	0	150	531
Ağaç	0	0	0	15	160	13	188
Boş Alan	15	6	22	33	0	21	97
Toplam	122	110	280	377	160	189	1238
Genel Doğruluk = (846/1238) 70.3340%							
Kappa statistics = 0.6053							

Çizelge 3.2: Kontrolsüz sınıflandırma yöntemi sonuçlarına ait hata matrisi.

	Ağaç	Boş Alan	Tarım Alanı	Yol	Bina		Sulak Alan	Toplam
Ağaç	7481613	0	0	0	0		0	7481613
Boş Alan	0	20611	897817	0	0		0	918428
Tarım Alanı	0	21709	946889	28485	0		1321	998404
Yol	0	16011	0	1521326	2559737		17360	4114434
Bina	0	0	0	0	2412383		5293816	7706199
Sulak Alan	0	0	0	0	0		528689	528689
Toplam	7481613	58331	1844706	1549811	4972120		5841186	21747767
Genel Doğruluk = (12911511/21747767) 59.3694%								
Kappa statistics = 0.4768								


Çizelge 3.3: Obje tabanlı sınıflandırma yöntemi SVM sınıflandırıcının özgün veri çıktısına dayanan sonuçlara ait hata matrisi.

	Tarım Alanı	Ağaç	Sulak Alan	Bina	Yol	Boş Alan	Toplam
Tarım Alanı	3867744	264679	8360	10178	43790	623956	4818707
Ağaç	3062905	5717404	27562	1748	10876	116211	8936706
Sulak Alan	425	3217	1871468	12	107	798	1876027
Bina	2505	0	1676	134487	7196	23333	169197
Yol	296	0	32	1389	5263	6147	13127
Boş Alan	383379	249	0	54653	198404	892119	1528804
Toplam	7317254	5985557	1909098	202467	265636	1662564	17342576
Genel Doğruluk = (19971869/24825960) 80.4475%							
Kappa statistics = 0.7411							

Çizelge 3.4: Tüm sınıflandırma yöntemlerinden elde edilen doğruluk analizi sonuçları.

Sınıf	Kontrollü Sınıflandırma		Kontrolsüz Sınıflandırma		Obje Tabanlı Sınıflandırma	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Yol	26.23	88.89	100.00	100.00	52.86	80.27
Bina	47.27	40.63	35.33	2.24	95.52	63.98
Sulak Alan	92.14	100.00	51.33	94.84	98.03	99.76
Boş Alan	85.68	60.83	98.16	36.98	66.42	77.49
Ağaç	100.00	85.11	48.52	31.30	1.98	40.09
Tarım Alanı	11.11	21.65	9.05	100.00	53.66	58.35
Genel Doğruluk	70.3340%		59.3694%		80.4475%	
Kappa statistics	0.6053		0.4768		0.7411	

Tüm sınıflandırma yöntemlerinde elde edilen sonuçlara göre bu çalışmada obje tabanlı sınıflandırma yöntemi en yüksek doğruluğu vermiştir.



Şekil 3.3: Sınıflandırılmış görüntü sonuçları: (A) kontrollü sınıflandırma sonucu, (B) kontrolsüz sınıflandırma sonucu ve (C) obje tabanlı sınıflandırma sonucu.

Bu çalışmada, görüntü zenginleştirme ve iyileştirme metotlarından olan PCA ve MNF analizleri gerçekleştirilmiş ve bu analizlerden elde edilen sonuçlardan yararlanılarak yeni çok bantlı uydu görüntüleri oluşturulmuştur. Bu iki uygulamanın piksel tabanlı sınıflandırma yöntemlerinde doğruluğun artması bakımından olumlu etkileri olmuştur. Fakat, bu olumlu etki obje tabanlı sınıflandırma yönteminin seviyesinin üstüne çıkamamıştır. Uygulamada karşılaşılan en büyük sorunlardan biri, şehir bölgelerinin heterojen ve kompleks yapıda olmasıdır. İnsan yapımı özelliklere ait (örneğin, yol, çatı vb.) çok farklı spektral yansıtım özellikleri olduğundan yerleşim alanlarını belirlemek oldukça zordur. Diğer yandan, bitki örtüsü, gerek farklı tür gerekse farklı toprak ve nem koşullarına sahip olduğundan spektral

yansıtımında farklılıklar göstermektedir. Elde edilen en yüksek doğruluk analizi sonuçlarına göre; kontrollü sınıflandırma işleminde tarım alanı sınıfı ile boş alan sınıfı ve yol ve bina sınıfları seçiminde problemler yaşanmıştır. Kontrolsüz sınıflandırma işleminde tarım alanı sınıfı yol ve boş alan sınıfları ile karışmıştır.

Bu genel durum doğruluk oranını düşürmüştür. Nesnelerin spektral yansıması ve zayıf piksel değerleri gibi bazı sorunlardan dolayı ortaya çıkan bir problemdir. Ayrıca, tarım alanlarının bir kısmında akili tarım ürünü bulunmamaktadır. Bu gibi problemlerden dolayı bazı sınıfların seçiminde zorluklar yaşanmıştır.

4. SONUÇ VE ÖNERİLER

Uzaktan algılama verileri kullanarak LU/LC digital haritalarının oluşturulması önemli bir araştırmadır ve uzaktan algılama uygulamalarında yaygın olarak kullanılmaktadır.

LU/LC haritalamada uzaktan algılama uygulamaları maliyeti azaltmaktadır.

RapidEye uydu verileri, kırmızı kenar bandı, ekonomik ve yüksek çözünürlüklü, aynı zamanda yüksek tekrarlama zamanı ile birkaç ticari uydu sensörlerinden birisidir. Bu tür çalışmalarda RapidEye gibi yüksek çözünürlüğe sahip uydu görüntülerinin kullanımı detayları görme açısından ve yüksek doğrulukta sonuç ürünlerinin elde edilmesi bakımından büyük önem taşımaktadır. Sonuç olarak, LU/LC sınıflarını tanımlama ve haritalama işlemlerinde yüksek çözünürlüklü uzaktan algılama verisi çok etkindir.

Tez çalışmasının amacı, piksel tabanlı ve obje tabanlı görüntü sınıflandırması (kontrollü sınıflandırma, kontrolsüz sınıflandırma, obje tabanlı özellik çıkarımı sınıflandırması) gerçekleştirmektir. Çalışmada 7 farklı sınıflandırıcı kullanılmıştır ve bu sınıflandırıcılar; Paralel kenar yöntemi, En kısa uzaklık yöntemi, Mahalanobis uzaklığı yöntemi, En çok benzerlik yöntemi, ISODATA sınıflandırma, K-Ortalama sınıflandırma ve Obje tabanlı görüntü sınıflandırma SVM yöntemidir.

Obje tabanlı sınıflandırma yöntemlerinin, özellikle ayrıntılı uzamsal-çözünürlüğe sahip veriler için piksel tabanlı sınıflandırma yaklaşımlarından daha iyi sınıflandırma sonuçları ortaya koyduğu görülmüştür.

PCA ve MNF yöntemleri, gürültü giderme, ilintisiz bant dışı ve PCs bileşeni (Çizelge 3.2 ve Çizelge 3.1) işlemlerinde etkili sonuçlar sağlamıştır. Kontrollü ve kontrolsüz sınıflandırma analizlerinde özellikle MNF uygulamasının sonuç haritanın doğruluk oranına olumlu yönde katkı sağladığı görülmüştür. Bu tür çalışmalarda kullanılan uydu görüntüsünün her zaman gürültü içeriği kontrol edilmeli ve bunun için veri iyileştirme teknikleri kullanılmalıdır.

Çalışma alanı olan Hatay'ın Samandağ ilçesi birçok LU/LC kategorileriyle çevrelenmiştir ve kendi karakteristiğini gösteren çeşitli yapay ve doğal alanları mevcuttur. Çalışmada kullanılan yüksek çözünürlüklü uzaktan algılama verisi ve

farklı sınıflandırma tekniklerinin yardımı ile çalışma alanına ait en uygun LU/LC haritasının başarı ile üretildiği görülmüştür. Çalışmada, farklı sınıflandırma tekniklerini kullanarak desenleri kolay tanımlamak için yüksek çözünürlüklü uydu görüntü verisi kullanılarak uygun ve doğru LU/LC sınıflandırılmış görüntü çıktılarını başarmak için çalışılmıştır. Çalışmanın bir sonraki aşamasında bölgeye ait WorldView gibi daha yüksek çözünürlüklü uydu görüntüleri kullanımının LU/LC haritalamaya etkileri araştırılabilir.

Bu araştırmanın Samandağ vatandaşlarını her LU/LC sınıf kategori seviyesinden haberdar etmek ve Hükümet ile Özel sektörü bu konuda bilgilendirmek için temel çalışma olarak baz alınması tavsiye edilmektedir. Ayrıca, alandaki doğal ve yapay kaynakların doğal çevreyi muhafaza etmek ve doğal çevrenin özelliklerinin azalmasını önleme konusundaki önemi yetkililere ve bölge halkına aktarılmalıdır.

KAYNAKLAR

- Al- Ahmadi, F.S., 2008. Comparison four classification methods to extract land use and land cover from row satellite images for some remote arid areas, kingdom of Saudi Arabia, JKAU; Earth Sci., 20, 1, 167-191.
- Anderson, J.R., Ernest, E., Hardly, John, T., Roach, ve Richard, E. W., 1976. A land use land cover classification system for use with remote sensor data, geological survey, professional paper964, Geological Survey Circular 671, United States Government Printing Office, Washington.
- Baatz, M., Heynen, M., Hofmann, P., Lingenfelder, I., Mimler, M., Schäpe, A., Weber, M. ve Willhauck, G., 2000. eCognition user guide, Definiens imaging GmbH, München, Germany.
- Baatz, M., Benz, U., Dehghani, S. ve Heynen, M., 2004. eCognition user guide 4. Definiens imagine GmbH, Munich, Germany.
- Boardman, J. W. ve Kruse, F. A., 1994. Automated spectral analysis: a geological example using AVIRIS data, north Grapevine Mountains, Nevada: in Proceedings, ERIM Tenth Thematic Conference on Geologic Remote Sensing, Environmental Research Institute of Michigan, Ann Arbor, MI, I-407 - I-418.
- Bokhary, Marwa A.M., 2007, comparison between pixel based classification and object based feature extraction approaches for a very high-resolution remote sensed image.
- Congalton, R. G. ve Green, K., 1999. Assessing the accuracy of remotely sensed data: principles and practices, Second Edition, Lewis Publishers.
- Estornell, J., Mart, J., Gavil, M., Sebasti, T. ve Mengual, M., 2013. Principal component analysis, Modelling in Science Education and Learning, 6(2), p7.
- ENVI Users Guide, Research Systems Inc., September 2004 Edition.
- EXELIS, 2015. ENVI, Feature extraction classification tutorial.
- Feature extraction with Example-based classification tutorial, ENVI, EXELIS Inc., Harris Corporation.

- Fountanas, L., 2004. Principal components based techniques for hyper spectral image data, Naval Postgraduate School, California.
- Fundamentals of remote sensing, Canada center for remote sensing, remote sensing tutorial.e-book. Giri, C. P., 2012. Remote sensing of Land uses Land cover: principals and applications, Taylor and Francis Group, version date 20120207, international standard book numbr-13:978-1-4200-7075-0.
- Gonzalez, L., 2012. Principal component analysis, landscape toolbox Wikipedia.
- Green, A. A., Berman, M., Switzer, P. ve Craig, M. D., 1988. A transformation for ordering multispectral data in terms of image quality with implications for noise removal, IEEE Transactions on Geoscience and Remote Sensing, 26, 1, 65-74.
- Jensen, J.R., 2005. Introductory Digital Image Processing: *A Remote Sensing Perspective*, Third Edition, Upper Saddle River, NJ: Pearson Prentice Hall.
- Karmer, H. J., 2002. RapidEye earth observation constellation, earth observation portal. Alındığı tarih: ESA 2000-2016.
- Lillesand, T.M., ve Kiefer, R.W., 2001. Remote sensing and Image Interpretation, Fourth Edition, John Wiley and sons, Inc., USA.
- Lillesand, M. T. ve Kiefer, W. R., 2004. Remote sensing and image interpretation, Fifth Edition, John Wiley ve Sons, Inc, New York.
- Lodhi, A., 2014. Environmental modeling and spatial simulations, important remote sensing satellites and sensors, brief description and resolutions in context of Envi V 4.7.
- Mather, P. M., 1987. Computer processing of remotely sensed images, St Edmunds bury Press Ltd., Bury St Edmunds, Suffolk, Wiley and Sons, ISBN: 0-471-90648-4.
- Mather, P. M., 2004. Computer processing of remotely sensed images, Third Edition, John Wiley and Sons, Ltd, 9600 Garsington Road, Oxford, OX4 2DQ, UK.
- MSc. Hassan Elnour Adam Zakaria, 2010. Integration of Remote Sensing and GIS in studying vegetation trends and conditions in the Gum Arabic Belt in North Kordofan, Dissertation for awarding the academic degree Doctor of Natural Science, Sudan.

- Mutlu, M., 2010. Estimating canopy fuel parameters with in-situ and remote sensing data, dissertation, Office of Graduate Studies of Texas A&M University.
- Netsanet Deneke Norie, 2007. Land use and land cover changes in Harena forest and surrounding area, Bale mountain national park, Master Thesis, School of Graduate Studies of Addis Ababa University.
- Pedroni, L., 2003. Improved classification of Landsat Thematic Mapper data using modified prior probabilities in large and complex landscapes, *Int. J. Remote sensing*, 24, 1, p 91-113.
- Price, J. C., 1994. How unique are spectral signatures? *Remote Sensing of Environment*, 49, 3, 181-186.
- Richards, J.A., 1999. *Remote sensing digital image analysis: an introduction*, Fourth Edition, Springer-Verlag, Berlin, Germany.
- Sanderson, Dr. R., *Introduction to Remote Sensing*, New Mexico State University, e-book.
- Schowengerdt, R. A., 2007. *Remote sensing, models and methods for image processing*, third Edition, Elsevier Inc., New York, USA.
- Thomson, A.G., Fuller, R.M. ve Eastwood, J.A., 1998. Supervised versus unsupervised methods for classification of coasts and river corridors from airborne remote sensing, *International Journal of Remote Sensing*, 19, 17, 3423-3431.
- Tou, J. T. ve Gonzalez, R. C., 1974. *Pattern Recognition Principles*, published by Nasa Technical reports server, 395P.
- Tso, B, and Mather, P.M, 2001, *Classification Methods for Remotely Sensed Data*, Taylor and Francis Inc, ISBN: 0-415-25909-6.(publication type monograph)
- Use the MNF transform to a) remove residual noise from the spectral data and b) provide a convenient mechanism for selecting prototype spectra. *Hyper spectral image data*, CEE 615: Digital Image Processing, Lab 11: Hyper spectral Noise p. 1.
- Willhauck, G., 2000. Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos, Nineteenth Congress of the International Society for Photogrammetry and remote Sensing (ISPRS).

Geometrics Information and Trading Center (GITC) bv, Amsterdam, 33, 214-221.

URL_1<[www.physicalgeography.net, file:///E:/Research/Preparation/2\(e\).%20Introduction%20to%20Remote%20Sensing.html](http://www.physicalgeography.net, file:///E:/Research/Preparation/2(e).%20Introduction%20to%20Remote%20Sensing.html)>, Alındığı Tarih: physical geography.net, fundamentals e-book chapter 2, Maps, Remote sensing, GIS 2006.

URL_2<<http://gisgeography.com/image-classification-techniques-remote-sensing/>>, Alındığı Tarih: 30 Jul 2016.

URL_3<<https://en.wikipedia.org/wiki/Samanda%C4%9F>>, Alındığı tarih: Samandag wikipediya 12 September 2016.

URL_4<[file:///D:/test%20pca/MNF/Image%20Transform%20\(Using%20ENVI\)%20%20Exelis%20VIS%20Docs%20Center.html](file:///D:/test%20pca/MNF/Image%20Transform%20(Using%20ENVI)%20%20Exelis%20VIS%20Docs%20Center.html)> Alındığı tarih: EXELIS visual information solutions 2015.

URL_5<www.satimagingcorp.com, <http://www.satimagingcorp.com/satellitesensors/other-satellite-sensors/rapideye/>>, Alındığı tarih: satellite-imaging corporation 2015.

URL_6<<http://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/rapideye/>>, Alındığı tarih: satellite-imaging corporation 2001-2017.

URL_7<<https://environmentalsciencesociety.org/tag/suds/>>, Alındığı tarih: 2009

ÖZGEÇMİŞ

Ad Soyad : Hoshmand Al-Shateri
Doğum Yeri ve Tarihi : Al suleymaniyeh / 01.01.1991
E-Posta : hoshmendg@gmail.com

ÖĞRENİM DURUMU

- **Lisans** : 2012, Suleymaniyeh Üniversitesi, Eğitim Fakültesi, Coğrafya Bölümü