

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NESNE TABANLI GÖRÜNTÜ ANALİZİNDE ÖLÇEK VE EĞİTİM
SETİ BOYUTUNUN SINIFLANDIRMA DOĞRULUĞUNA
ETKİLERİNİN ARAŞTIRILMASI

İSMAİL AŞIK
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİĞİ TEKNOLOJİLERİ PROGRAMI

GEBZE
2019

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NESNE TABANLI GÖRÜNTÜ ANALİZİNDE
ÖLÇEK VE EĞİTİM SETİ BOYUTUNUN
SINIFLANDIRMA DOĞRULUĞUNA
ETKİLERİNİN ARAŞTIRILMASI

İSMAİL AŞIK
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİGİ TEKNOLOJİLERİ PROGRAMI

DANIŞMANI
DOÇ. DR. İSMAİL ÇÖLKESEN

GEBZE

2019

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**INVESTIGATION OF THE EFFECTS OF
SCALE AND TRAINING SET SIZE ON
CLASSIFICATION ACCURACY IN OBJECT
BASED IMAGE ANALYSIS**

İSMAİL AŞIK

**A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE**

DEPARTMENT OF GEOMATICS ENGINEERING

GEODESY AND GEOGRAPHIC INFORMATION TECHNOLOGIES PROGRAM

**THESIS SUPERVISOR
ASSOC. PROF.DR. İSMAİL ÇÖLKESEN**

**GEBZE
2019**

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 31/07/2019 tarih ve 2019/34 sayılı kararıyla oluşturulan jüri tarafından 02/08/2019 tarihinde tez savunma sınavı yapılan İsmail AŞIK'ın tez çalışması Harita Mühendisliği Anabilim Dalında Jeodezi ve Coğrafi Bilgi Teknolojileri programında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Doç.Dr.İsmail ÇÖLKESEN

ÜYE

: Prof.Dr.Arif ÇAĞDAŞ AYDINOĞLU

ÜYE

: Dr.Öğr.Üyesi Emrehan Kutluğ ŞAHİN

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Son yıllarda, yüksek konumsal çözünürlüğe sahip uydu görüntülerinin sınıflandırılmasında klasik piksek tabanlı sınıflandırma yaklaşımı yerine nesne tabanlı sınıflandırma yaklaşımı tercih edilmeye başlanmıştır. Nesne tabanlı sınıflandırma analizlerinde benzer piksellerin bir grup altında bir araya getirilmesi için kullanılan segmentasyon işleminin gerçekleştirilmesinde, üretilecek görüntü nesnesi boyutunu belirleyen ölçek parametresinin tespiti önemli bir husustur. Bununla birlikte nesne tabanlı sınıflandırma bir kontrollü sınıflandırma tekniği olduğundan kullanılacak algoritmanın eğitimi ve testi için kullanılacak örnek sayısı sınıflandırma doğruluğuna etki edebilecek diğer önemli bir husustur. Bu çalışmada, segmentasyon parametreleri ve eğitim veri seti boyutu arasındaki ilişki incelenmiştir. Temel veri seti olarak 2018 tarihli Sentinel-2 uydu görüntüsü kullanılmıştır. Görüntü segmentasyonu için ölçek parametrelerini belirlemede ESP-2 ve Moran's *I* yöntemi kullanılmıştır. ESP-2 algoritması ile muhtemel ölçek parametreleri 32, 59, 77, 94 ve Moran's *I* yöntemiyle de 20 olarak belirlenmiştir. Örneklem oranının nesne tabanlı sınıflandırma doğruluğu üzerindeki etkisini değerlendirmek ve her ölçek parametresi için en iyi örneklem oranını belirlemek için, sekiz örneklem oranı (10:90, 20:80, 30:70, 40:60, 50:50, 60:40, 70:30, 80:20) göz önünde bulundurularak eğitim ve test veri setleri oluşturulmuştur. Oluşturulan segmentlerin sınıflandırılmasında ve tematik harita üretiminde en yakın komşuluk (EYK), karar ağaçları (KA), rastgele orman (RO), AdaBoost (hızlandırma) algoritmalarından yararlanılmıştır. Sonuçlar, AdaBoost algoritmasının sınıflandırma performansının, her bir ölçek parametresi ve sınırlı eğitim örnekleri için EYK, KA ve RO performanslarına göre daha üstün olduğunu gösterdi. En yüksek toplam doğruluk AdaBoost ile ölçek parametresi 20 ve örneklem oranı 70:30 için %89,02 olarak hesaplanmıştır. Eğitim veri seti boyutundaki artış ile sınıflandırma performansının belirli bir düzeye kadar arttığı gözlenmiştir. Çalışma sonuçları ölçek parametresi ve eğitim veri seti boyutundaki değişimlerin obje tabanlı sınıflandırma doğruluğuna etkileri açısından önemli bilgiler sağlayacaktır.

Anahtar Kelimeler: Obje Tabanlı Sınıflandırma, Segmentasyon, Ölçek Parametresi, ESP-2, Morans-I.

SUMMARY

In recent years, instead of traditional pixel-based classification approach, object-based classification approach is preferred for especially classification of the high spatial resolution satellite imagery. Determination of the optimal scale parameter identifying image object size for segmentation process aiming to combine pixels having similar characteristics into a group is an important issue in performing effective object-based image analysis. Due to object-based method is a supervised image classification technique, the number of samples to be used for the training of the algorithm is another important issue that can affect the classification accuracy. In this study, the relationship between scale parameter and the training set size was investigated. The Sentinel-2 satellite image acquired in 2018 was used as a main input dataset. The ESP-2 and Moran's I methods were used to determine the optimal scale parameters for image segmentation process. The optimal scale parameters were estimated by the ESP-2 algorithm as 32, 59, 77, 94 while the scale parameter was determined as 20 with the Moran's I method. In order to assess the effect of sampling ratio on object-based classification accuracy and to determine the best sampling ratio for each scale parameter, training and testing datasets were formed considering the eight sampling ratios as 10:90, 20:80, 30:70, 40:60, 50:50, 60:40, 70:30 and 80:20. For the classification of segmented image objects and to produce land use and land cover thematic map, nearest neighbour (NN), decision trees (DT), AdaBoost and random forest (RF) algorithms were used. Results showed that the classification performance of the AdaBoost algorithm was found to be superior compared to those of NN, DT and RF for each scale parameter and for the case of limited training samples. The highest overall accuracy was estimated with AdaBoost as 89.02% for scale parameter 20 and sampling ratio of 70:30. Moreover, it was observed that the performance of the algorithms increased to a certain level with the increase in the size of the training dataset. The results of the study will provide important information on the effects of scale parameters and changes in the size of the training dataset to the object-based classification accuracy.

Key Words: Object-Based Classification, Segmentation, Scale Parameters, ESP-2, Morans-I.

TEŞEKKÜR

Yüksek lisans eğitimim boyunca bana her türlü desteği gösteren, tez konusu belirlemede, yürütülmesinde, sonuçlandırılmasında ve diğer her aşamasında değerli bilgilerini ve tecrübelerini, yardımlarını esirgemeyen değerli tez danışmanım Doç. Dr. İsmail ÇÖLKESEN'e,

Eğitimim boyunca beni birikimleri ve emekleriyle aydınlatan Gebze Teknik Üniversitesi Harita Mühendisliği Bölümü değerli hocalarına,
Tez çalışmalarım süresince bana maddi ve manevi desteklerini esirgemeyen çalışma arkadaşlarıma,

Hayatım boyunca büyük destek olan her zaman yanımda duran ablam, yeğenim ve eşi, Tuğba, Yusuf ve Ahmet AKGÖZ'e, bugünlere gelmemde en çok emeği olan maddi ve manevi desteğini hiç zaman esirgemeyen Gülfe AŞIK'a, babam Muhittin AŞIK'a, kardeşim S.Buğra AŞIK'a,

Tez sürecinde ve hayatımın iyi ve kötü gününde yanımda olan sabır ve anlayışıyla bana her zaman destek olan değerli eşim, hayat arkadaşım Merve AŞIK'a
Teşekkürlerimi ve şükranlarımı sunuyorum.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xiii
1.GİRİŞ	1
1.1. Tezin Amacı	2
1.2. Metodoloji	3
1.3. Literatür Araştırması	4
2. UZAKTAN ALGILAMADA SINIFLANDIRMA İŞLEMİ İLE İLGİLİ TEMEL TANIM VE KAVRAMLAR	12
2.1. Piksel Tabanlı Sınıflandırma	12
2.2. Nesne Tabanlı Sınıflandırma	13
2.3. Eğitim Veri Seti Boyutu	14
2.4. Sınıflandırma Algoritmaları	15
2.4.1. Karar Ağaçları	16
2.4.2. Rastgele Orman Algoritması	17
2.4.3. AdaBoost Algoritması	18
2.4.4. En Yakın Komşuluk Algoritması	18
3.UYGULAMA	19
3.1. Çalışma Alanı	19
3.2. Uydu Görüntüsü ve Özellikleri	20
3.3. Çalışmada Kullanılan Yazılımlar	22
3.4. Nesne Tabanlı Sınıflandırma	23
3.4.1. Görüntü Segmentasyonu	24
3.4.1.1. ESP-2 Aracı Yardımıyla Ölçek Parametresi Tespiti	24

3.4.1.2. Moran's <i>I</i> Yöntemi ile Ölçek Parametresi Tespiti	26
3.4.2. Görüntü Nesnelere İlişkin Özelliklerin Tanımlanması	29
3.4.3. Eğitim ve Test Verisi Setlerinin Oluşturulması	29
3.4.4. Nesne Tabanlı Sınıflandırma ve Performans Analizi	32
3.4.4.1. En Yakın Komşuluk Algoritması İle Nesne Tabanlı Sınıflandırma	33
3.4.4.2. Karar Ağaçları Algoritması İle Nesne Tabanlı Sınıflandırma	35
3.4.4.3. Rastgele Orman Algoritması İle Nesne Tabanlı Sınıflandırma	37
3.4.4.4. AdaBoost Algoritması İle Nesne Tabanlı Sınıflandırma	39
4.BULGULAR VE TARTIŞMA	42
4.1. Ölçek Parametresi ve Eğitim Veri Seti Boyutundaki Değişimlere Göre Performans Analizi	42
4.1.1. Ölçek Parametresi 20 İçin Sınıflandırma Performansının Analizi	42
4.1.2. Ölçek Parametresi 32 İçin Sınıflandırma Performansının Analizi	47
4.1.3. Ölçek Parametresi 59 İçin Sınıflandırma Performansının Analizi	52
4.1.4. Ölçek Parametresi 77 İçin Sınıflandırma Performansının Analizi	57
4.1.5. Ölçek Parametresi 94 İçin Sınıflandırma Performansının Analizi	62
4.2. Sınıflandırmada Kullanılan Algoritmaların İstatiksel Analizi	67
4.2.1. 20-Ölçek İçin Kullanılan Algoritmaların İstatiksel Analizi	67
4.2.2. 32-Ölçek İçin Kullanılan Algoritmaların İstatiksel Analizi	69
4.2.3. 59-Ölçek İçin Kullanılan Algoritmaların İstatiksel	71

Analizi	
4.2.4. 77-Ölçek İçin Kullanılan Algoritmaların İstatiksel	73
Analizi	
4.2.5. 94-Ölçek İçin Kullanılan Algoritmaların İstatiksel	75
Analizi	
5.SONUÇ VE ÖNERİLER	77
KAYNAKLAR	80
ÖZGEÇMİŞ	88
EKLER	89

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
1.1: Tez çalışmasının iş akış diyagramı.	4
2.1: Obje Tabanlı Sınıflandırma işlem adımları.	14
2.2: Karar Ağaç yapısı.	17
3.1: Çalışma alanı.	19
3.2: Sentinel-2 uydu görüntüsü RGB(bant-3,bant-2,bant-1).	22
3.3: ESP-2 aracı ve parametre seçimi arayüzü.	25
3.4: LV-RoC grafiği.	26
3.5: Uydu görüntüsünde belirlenen sınıflarının bulunduğu bölge örnekleri.	30
3.6: EYK algoritması ile %80 eğitim veri seti boyutundaki en yüksek doğruluğa sahip tematik harita ve uydu görüntüsü.	35
3.7: KA algoritması ile %60 eğitim veri seti boyutundaki en yüksek doğruluğa sahip tematik harita ve uydu görüntüsü.	37
3.8: RO algoritması ile %60 eğitim veri seti boyutundaki en yüksek doğruluğa sahip tematik harita ve uydu görüntüsü.	39
3.9: AdaBoost algoritması ile %70 eğitim veri seti boyutundaki en yüksek doğruluğa sahip tematik harita ve uydu görüntüsü.	41
4.1: 20 ölçek değerinde genel doğruluk grafiği.	43
4.2: En Yakın Komşuluk algoritmasının 20 ölçek değerinde F-skor değerleri.	44
4.3: Karar Ağaçları algoritmasının 20 ölçek değerinde F-skor değerleri.	45
4.4: Rastgele Orman algoritmasının 20 ölçek değerinde F-skor değerleri.	46
4.5: AdaBoost algoritmasının 20 ölçek değerinde F-skor değerleri.	47
4.6: 32 ölçek değerinde genel doğruluk grafiği.	48
4.7: En Yakın Komşuluk algoritmasının 32 ölçek değerinde F-skor değerleri.	49
4.8: Karar Ağaçları algoritmasının 32 ölçek değerinde F-skor değerleri.	50
4.9: RO algoritmasının 32 ölçek değerinde F-skor değerleri.	51
4.10: AdaBoost algoritmasının 32 ölçek değerinde F-skor değerleri.	52
4.11: 59 ölçek değerinde genel doğruluk grafiği.	53
4.12: En Yakın Komşuluk algoritmasının 59 ölçek değerinde F-skor değerleri.	54
4.13: Karar Ağaçları algoritmasının 59 ölçek değerinde F-skor değerleri.	55
4.14: RO algoritmasının 59 ölçek değerinde F-skor değerleri.	56

4.15:	AdaBoost algoritmasının 59 ölçek değerinde F-skor değerleri.	57
4.16:	77 ölçek değerinde genel doğruluk grafiği.	58
4.17:	En Yakın Komşuluk algoritmasının 77 ölçek değerinde F-skor değerleri.	59
4.18:	Karar Ağaçları algoritmasının 77 ölçek değerinde F-skor değerleri.	60
4.19:	RO algoritmasının 77 ölçek değerinde F-skor değerleri.	61
4.20:	AdaBoost algoritmasının 77 ölçek değerinde F-skor değerleri.	62
4.21:	94 ölçek değerinde genel doğruluk grafiği.	63
4.22:	En Yakın Komşuluk algoritmasının 94 ölçek değerinde F-skor değerleri.	64
4.23:	Karar Ağaçları algoritmasının 94 ölçek değerinde F-skor değerleri.	65
4.24:	RO algoritmasının 94 ölçek değerinde F-skor değerleri.	66
4.25:	AdaBoost algoritmasının 94 ölçek değerinde F-skor değerleri.	67
4.26:	20 ölçek değerinde a)EYK, b) KA, c) RO ve d) AdaBoost algoritmaları için hesaplanan doğrusal eğilim grafikleri.	68
4.27:	32 ölçek değerinde a)EYK, b) KA, c) RO ve d) AdaBoost algoritmaları için hesaplanan doğrusal eğilim grafikleri.	70
4.28:	59 ölçek değerinde a)EYK, b) KA, c) RO ve d) AdaBoost algoritmaları için hesaplanan doğrusal eğilim grafikleri.	72
4.29:	77 ölçek değerinde a)EYK, b) KA, c) RO ve d) AdaBoost algoritmaları için hesaplanan doğrusal eğilim grafikleri.	74
4.30:	94 ölçek değerinde a)EYK, b) KA, c) RO ve d) AdaBoost algoritmaları için hesaplanan doğrusal eğilim grafikleri.	76

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
3.1: Sentinel-2 uydusunun teknik özellikleri.	20
3.2: Sentinel-2 uydusuna ait bant değerleri ve çözünürlükleri.	21
3.3: Moran's <i>I</i> yöntemiyle ölçek değeri belirlemede kullanılan bantlar ve değerleri.	28
3.4: Nesne tabanlı sınıflandırmada dikkate alınan özellikler.	29
3.5: Her bir ölçek ve sınıf için toplanan eğitim veri seti değerleri.	31
3.6: EYK algoritması için hesaplanan genel doğruluk değerleri.	34
3.7: KA algoritması için hesaplanan genel doğruluk değerleri.	36
3.8: RO algoritması için hesaplanan genel doğruluk değerleri.	38
3.9: AdaBoost algoritması için hesaplanan genel doğruluk değerleri.	40

1. GİRİŞ

Son yıllarda uydu teknolojilerindeki yaşanan gelişmeler beraberinde uzaktan algılama teknolojileri ve uydu görüntülerinin sahip olduğu özelliklerin de iyileşmesine neden olmuştur. Uydu görüntüleri aracılığıyla arazi kullanımını temsil eden tematik haritalar hızlı, ucuz ve doğru bir şekilde üretilmekte ve analiz edilebilmektedir [Bisht and Kothiyari, 2001; Dedeoğlu ve diğ., 2016]. Uzaktan algılamada görüntü sınıflandırması, uydu görüntüsündeki her bir pikselin yeryüzünde karşılık geldiği arazi örtüsü sınıfına atanması işlemi olarak tanımlanabilir. Uydu görüntüsünün sınıflandırılması neticesinde farklı ölçeklerde yeryüzünü temsil eden arazi örtüsü ve arazi kullanım haritaları üretilmekte ve söz konusu haritalar yeryüzü ile ilişkili birçok çalışmada temel veri kaynağı olarak kullanılmaktadır. Kullanılan uydu görüntüsünün özelliklerine göre sınıflandırma işlemi için seçilen yöntem ve uygulanan algoritmalar doğruluğu etkileyen faktörlerdir.

Uydu görüntülerinin sınıflandırılmasında genel olarak piksel tabanlı ve nesne tabanlı sınıflandırma olmak üzere iki yaklaşım bulunmaktadır. Piksel tabanlı sınıflandırmada, uydu görüntüsünün temel birimi olan piksellerin parlaklık değerleri esas alınarak ayrı ayrı sınıflandırılması söz konusudur. Özellikle yüksek mekânsal çözünürlüklü uydu görüntülerinin kullanımıyla birlikte görüntü veri seti boyutu artmış ve benzer spektral özelliklere sahip piksellerin birbirinden ayırt edilerek sınıflandırılması güçleşmiştir. Bu zorlukların üstesinden gelebilmek ve yüksek çözünürlüklü görüntüler yardımıyla doğruluğu yüksek tematik harita üretiminde klasik piksel tabanlı sınıflandırma yerine nesne tabanlı sınıflandırma yaklaşımının kullanımı yaygın hale gelmiştir. Nesne tabanlı sınıflandırma, uydu görüntüsündeki pikselleri değil benzer spektral özelliklere sahip piksellerin bir araya gelmesiyle oluşan nesnelerin (objelerin) sınıflandırılması işlemi yapmaktadır.

Nesne tabanlı sınıflandırmada, görüntü segmentasyonu, görüntü nesnelerinin özelliklerinin belirlenmesi ve görüntü nesnelerinin sınıflandırılması olmak üzere üç temel işlem adımı bulunmaktadır. Bunlardan ilki ve nesne tabanlı sınıflandırmanın temel işlem adımı olan ve benzer spektral özelliklere sahip piksellerin bir araya getirilerek görüntü nesnelerinin oluşturulması olarak bilinen segmentasyon işlemidir. Ölçek parametresi, segmentasyon ile elde edilen nesnelerin boyutunun belirlenmesinde en önemli faktördür [Bo and Han, 2010; Li and Shao, 2012; Kavzoğlu ve Yıldız, 2015]. Bu amaçla en uygun segmentasyon parametresinin tespiti

nesne tabanlı sınıflandırma işleminin doğruluğunu doğrudan etkileyen önemli bir husustur [Kim et al., 2011; Myint et al., 2011; Dragut et al., 2014; Ma et al., 2015]. Ölçek parametresi belirlemede farklı yaklaşımlar kullanılmaktadır. Bunlardan en yaygın kullanılanı, kullanıcı tarafından anlamlı görüntü nesneleri elde edilene kadar ölçek parametresinin manuel olarak ayarlanmasıdır (deneme yanılma yolu). Açıkçası bu yaklaşım kullanıcının tecrübe ve deneyimine bağlı olduğundan tercih edilmemektedir [Ma et al., 2015]. Literatürde ölçek parametresini otomatik tespiti için farklı yöntemler önerilmiştir. Dragut et al. 2014 yılında en uygun ölçek parametresini belirlemek için ESP2 yöntemini geliştirmişlerdir. Ölçek parametresini belirlemede kullanılan diğer bir yöntem konumsal otokorelasyon tekniği olan Moran's *I* indeksi ve varyans değerinin birlikte kullanılmasıdır [Kavzoğlu ve Yıldız, 2015].

Nesne tabanlı sınıflandırma bir kontrollü sınıflandırma tekniği olduğundan, sınıflandırma doğruluğuna etki eden diğer bir etken ise sınıflandırma modelinin oluşturulmasında kullanılacak eğitim veri seti boyutudur [Pal and Mather, 2003; Foody et al., 2006]. Eğitim veri seti boyutu belirlemede kullanılan standart bir yaklaşım bulunmamakta olup güncel araştırma konusudur.

Bu tez çalışmasında, Sentinel-2A uydu görüntüsü kullanarak nesne tabanlı sınıflandırma yaklaşımıyla çalışma alanı olarak belirlenen Sakarya ili Ferizli ilçesine ait arazi kullanımını ve arazi örtüsünü temsil eden tematik haritanın üretilmesi problemi ele alınmıştır. Çalışmanın genel amacı, segmentasyon işlemi için seçilecek farklı ölçek parametreleri ve eğitim veri seti boyutundaki değişimlerin sınıflandırma doğruluğuna etkilerinin araştırılmasıdır. Bu amaçla ölçek parametresi tespitinde Moran's *I* indeksi ve ESP yöntemleri kullanılırken, her bir ölçek parametresi için 8 farklı boyutta eğitim veri seti kullanılmıştır. Algoritmalar ile her ölçek ve eğitim veri seti için doğruluk analizi yapılmış ve sonuçları karşılaştırılmıştır.


1.1. Tezin Amacı

Orta çözünürlüklü uydu görüntü üzerinden arazi kullanımını ve arazi örtüsünün nesne tabanlı yaklaşımla sınıflandırılmasında segmentasyon işlemi için esas teşkil eden ölçek parametresi ile eğitim veri seti boyutu arasındaki ilişkinin incelenmesi ve sınıflandırma doğruluğuna etkilerinin araştırılması amaçlanmıştır. Bu amaç doğrultusunda tezin hedefleri;

- Orta konumsal çözünürlüğe sahip olan Sentinel-2 uydu görüntüsünün obje tabanlı sınıflandırma yaklaşımıyla sınıflandırılması ve tematik harita üretimi,
- Segmentasyon işleminin gerçekleştirilmesinde en uygun ölçek parametre değerinin tespiti,
- Segmentasyon işleminde farklı ölçek parametre değerleri ve eğitim veri seti boyutundaki değişimler arasındaki ilişkinin incelenmesi,
- En uygun ölçek parametresi ve eğitim veri seti boyutu esas alınarak çalışma alanının arazi örtüsü ve arazi kullanımına ilişkin tematik harita üretimi olarak belirlenmiştir.

1.2. Metodoloji

Tez kapsamında nesne tabanlı sınıflandırmada ölçek parametresi ve veri seti boyutunun sınıflandırma doğruluğuna etkisini araştırmak ve elde edilen veriler neticesinde tematik harita üretimi amaçlanmaktadır. Bu kapsamda öncelikli olarak çalışma alanı tespit edilmiş ve sınıflandırma işlemine esas teşkil edecek uydu görüntüsü temin edilmiştir. Tezin amacı doğrultusunda, uydu görüntüsün sınıflandırılması ve tematik harita üretiminde obje tabanlı yaklaşım kullanılmıştır. Obje tabanlı sınıflandırma yaklaşımının temel işlem adımları olan görüntü segmentasyonu, obje özelliklerinin tespiti ve sınıflandırma işlemleri sırasıyla gerçekleştirilmiştir. Son olarak segmentasyon işleminde kullanılan farklı ölçek parametrelerinin ve eğitim veri seti boyutuna etkileri analiz edilmiş ve en uygun sınıflandırma modeli ile çalışma alanına ait tematik harita üretilmiştir (Şekil 1.1).



Şekil 1.1: Tez çalışmasının iş akış diyagramı.

1.3. Literatür Araştırması

Literatürde, nesne tabanlı sınıflandırma yaklaşımı üzerine gerçekleştirilen çalışmalar genel olarak incelendiğinde piksel ve nesne tabanlı sınıflandırma yaklaşımlarının karşılaştırıldığını, kullanılan uydu görüntüleri, ölçek parametre değerini bulma yöntemleri, kullanılan algoritmaları, segmentasyon yöntemleri ve en son çalışmaların doğruluklarının analiz edildiği görülmektedir.

Örneğin, Marangoz ve diğ. (2005), yüksek çözünürlüklü IKONOS pansherpened görüntüsü kullanmıştır. Bu görüntü de segmentasyon ve diğer özellikleri kullanarak yol ve bina çıkarımını göstermiştir. Ölçek parametresi olarak 5, 10, 16, 25, 250 değerlerini kullanmıştır. Nesne tabanlı sınıflandırma için eCognition programını tercih etmiştir.

Marangoz (2009), kentsel ayrıntılar olan yol ve binaların piksel tabanlı ve nesne tabanlı sınıflandırma teknikleriyle otomatik olarak belirlenmesinde farklı yıllara ait IKONOS ve Quickbird görüntüleri kullanmıştır. Piksel tabanlı sınıflandırma da PCI yazılımını kullanmıştır. Sınıflandırma da maksimum benzerlik yöntemi kullanmıştır. Doğruluk analizinde görüntü üzerinde rastgele 50'şer piksel seçmiştir. Nesne tabanlı sınıflandırma da eCognition yazılımını kullanmıştır. Quickbird uydu görüntüsü segmentasyonu için ölçek faktörü 10, 20, 30, 35, 60 değerlerini denemiştir. Ölçek değeri "60" istenilen değere ulaşmıştır. Doğruluk analizinde 100 adet bina ve 50 adet yol örnek nesneler seçmiştir. Aynı işlemleri IKONOS görüntüsüne de uygulamıştır. İki görüntünün sonuçları değerlendirildiğinde IKONOS görüntünün detay çıkarımı Quickbird görüntünün detay çıkarımından başarısız olduğuna ulaşmıştır.

Maktav ve diğ. (2010), Berlin ve İstanbul şehirlerin kentsel gelişimi için potansiyel alanlarının uzaktan algılama ve CBS ile belirlenmesinde Quickbird-2 görüntüsü kullanmıştır. 1/5000 ölçekli ortofotolardan yer kontrol noktası seçilmiş ve ortorektifikasyon işlemi yapmıştır. Sınıflandırıcı algoritma olarak en yakın komşuluk ve fuzzy algoritmaları kullanmıştır. Ölçek parametresi belirlenen sınıflara göre değer vermiştir. Ölçek olarak 50, 100, 200, 500 değerlerini kullanmıştır.

Kalkan ve Maktav (2010), nesne ve piksel tabanlı sınıflandırma yöntemlerinin karşılaştırılmasında IKONOS multispektral uydu görüntüsü kullanmıştır. Piksel tabanlı sınıflandırma için Erdas Image programı kullanmıştır. En büyük benzerlik algoritması ile kontrollü sınıflandırma işlemi yapmıştır. Nesne tabanlı sınıflandırma işleme için eCognition yazılımı kullanmıştır. Ölçek parametresi için birçok deneme yapmıştır ve ölçek faktörünün 20 seçilmesini uygun görmüştür. En yakın komşuluk algoritması ve sınıflara ait eşik değer karar seti dosyası kullanmıştır. Yapılan doğruluk analizi sonucunda nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha iyi sonuç verdiğini görmüştür.

Duro et al., (2012), çok ölçekli nesne tabanlı görüntü analizi ve rastgele orman kullanılarak 30m/2,5m konumsal çözünürlüğe sahip Landsat-5 TM/Spot-5 uydu

görüntüsü kullanmıştır. 10, 20, 40, 60 ölçek değerlerini deneme yanılma yöntemi ile değerlemeye almıştır. Çalışmada özellik seçiminde ve sınıf belirlemede rastgele orman algoritması ile 418 özellik 5 sınıf belirlemiştir. Her sınıf 200 örnek ile toplam 1000 yer doğruluk noktası kullanmıştır. Doğruluk ve test oranı %70/%30 oranı tercih etmiştir. Bu çalışmanın doğruluğunu %91,30 olarak bulmuştur.

Vieira et al., (2012), büyük alanlarda şeker kamışını haritalamak için uzaktan algılama Landsat zaman serisi uygulanan veri madenciliği ve nesne tabanlı görüntü analizinde çoklu çözünürlüklü segmentasyon yöntemini ve 20 ölçek değerini kullanmıştır. Özellik seçiminde ve sınıflandırma da karar ağaçları yöntemi tercih edilmiş ve 164 özellik belirlemiştir. 500 yer doğruluk noktası belirlemiştir. Doğruluk ve test için %90/%10 oranı kullanmıştır. Çalışmanın doğruluğu %94 olarak bulunmuştur.

Duro et al., (2012), piksel ve nesne tabanlı sınıflandırma yöntemi ile Spot-5 HRG görüntüler kullanılarak tarımsal alanların sınıflandırması için makine öğrenme algoritması seçmiştir. 2,5 m konumsal çözünürlüğe sahip SPOT-5 uydu görüntüsü kullanmıştır. Çoklu çözünürlük segmentasyon kullanmıştır. Ölçek değeri için deneme yanılma ile 5, 15, 30 değerini bulmuştur. 300 özellik belirlemiştir. Sınıflandırma algoritması olarak destek vektör makine, rastgele orman ve karar ağaçları kullanılmıştır.

Pinho et al., (2012) yüksek çözünürlüklü görüntüler ve nesne tabanlı görüntü analizi kullanarak şehir içi bir ortamın arazi örtüsü sınıflandırması çalışmasında 1m/4m konumsal çözünürlüğe sahip Ikonos-2 uydu görüntüsü kullanmıştır. Çoklu çözünürlük segmentasyonu ve deneme yanılma yöntemi ile ölçek değerlerini 15, 20, 40 belirlemiştir. Sınıflandırma da karar ağacı yöntemini kullanmış ve 12 sınıf belirlemiştir. Her sınıf için 100 örnek belirlemiştir. Bu çalışmada doğruluğunu %71,91 olarak bulmuştur.

Pu et al., (2012), kentsel ağaç türlerinin haritalandırılması için yüksek uzaysal çözünürlüğe sahip IKONOS ve Worldview-2 (WV-2) görüntülerinin karşılaştırmalı analizinde 1 metre ve 0.5 metre konumsal çözünürlüğe sahip IKONOS ve WV-2 uydu görüntüsü kullanmıştır. Çoklu çözünürlük segmentasyonu kullanmıştır. Ölçek parametreleri olarak 70, 100, 130, 150 (deneme yanılma yolu ile) değerlerini kullanmıştır.

Boyacı ve diğ. (2013), 1/50000 ölçekli harita üretiminde değerlendirilen alanlar dikkate alınarak 9 farklı sınıf belirlemiştir. ASTER uydu görüntüsünden faydalanmış

ve piksel, nesne tabanlı sınıflandırma yapmıştır. Sınıflandırmanın doğruluğunu karşılaştırma araştırması yapmıştır. 12 farklı segmentasyon denemiş ve ölçek parametresi 10 değerinde sonuca ulaşmıştır.

Myburg et al., (2013), nesne tabanlı arazi örtü sınıflandırmasına özellik boyutunun etkisi üç sınıflandırıcının karşılaştırılması çalışmasında 2,5 m konumsal çözünürlüğe sahip Spot-5 uydu görüntüsü kullanmıştır. Çoklu çözünürlük segmentasyonu kullanmıştır. Ölçek parametresi 30 değeri ile çalışmalarını yapmıştır. 4 sınıf olarak yapılan çalışmada her sınıf için 40 örnek seçilmiş ve toplam yer doğruluk için 160 yer kontrol noktası seçmiştir. Yapılan çalışmada 3 farklı sınıflandırma algoritması kullanmıştır. Destek vektör makineleri, en yakın komşuluk, maksimum olabilirlik yöntemleri kullanmıştır. Bu yöntemlerle doğruluk karşılaştırılması yapmıştır ve doğrulukları sırasıyla %95,5, %69,6 ve %89,7 olarak bulunmuştur.

Cai et al., (2013), yüksek ve orta mekânsal çözünürlük görüntülerini kullanarak nesne tabanlı ve bağlamsal piksel tabanlı sınıflandırmaların karşılaştırılması çalışmasında 3 m ve 30 m konumsal çözünürlüğe sahip HYDICE / Landsat-5 TM uydu görüntüsü kullanmıştır. Gömülü (Embedded) segmentasyon yöntemi kullanmıştır. 7 sınıf belirlemiştir. Doğruluk ve test için %20/%80 oranı dikkate almıştır. Destek vektör makinaları ve Markov rastgele alan (Markov Random Field, MRF) sınıflandırma algoritmaları kullanmıştır. Bu sınıflandırma algoritmalarının doğruluklarını karşılaştırmıştır. Sınıflandırma doğruluklarını sırasıyla %75,7 ve %86,5 olarak bulmuştur.

Tehrany et al., (2013), 10m mekânsal çözünürlüğe sahip Spot-5 uydu görüntüleri yardımıyla arazi kullanımı / arazi örtüsü haritalandırması için nesne ve piksel tabanlı sınıflandırma yaklaşımları kullanmıştır. Segmentasyon yöntemi olarak çoklu çözünürlüklü yöntemi seçmiştir. Ölçek değerini 30 olarak belirlemiştir. Sınıflandırma algoritması olarak destek vektör makineleri ve k-en yakın komşuluk yöntemi kullanmıştır. 5 arazi örtüsü sınıfı belirlemiştir. Yıllara göre doğruluk araştırmasını karşılaştırmıştır. 2003 yılındaki doğruluk sonuçları sırası ile %80,6 ve %90,5 olarak bulmuştur. 2010 yılındaki doğruluk sonuçları sırası ile %78,15 ve %91 olarak bulmuştur.

Jonhson et al., (2013), çok ölçekli nesne tabanlı bir yaklaşım kullanarak yüksek çözünürlüklü kentsel arazi sınıflandırmasında 30 metre konumsal çözünürlüğe sahip hava fotoğrafları kullanmıştır. Çoklu çözünürlük segmentasyonu kullanmış ve ölçek

parametresi olarak (20-140) deęerleri arasında 20 artıřla 7 deęer kullanmıřtır. 15 zellik seęimi yapmıřtır. Sınıflandırmada destek vektr makinesi yntemini kullanmıř ve 9 sınıfa ayırmıřtır. Yapılan alıřmanın doęruluęu %82 olarak bulunmuřtur.

Belgiu et al., (2014), ok yksek znrlkl grntlerden binaların ıkarılması iin denetimli ve denetimsiz oklu znrlkl segmentasyon yaklařımlarının karřılařtırılması alıřmasında 0,6 metre ve 0,5 metre konumsal znrlęe sahip Quickbird/ Worldview-2 grnts kullanmıřtır. oklu znrlk segmentasyonunu kullanmıřtır. lek parametresi belirlemede ESP2 yntemi kullanmıřtır. 57 tane zellik belirlemiřtir. Sınıflandırma da rastgele orman yntemi ile 6 sınıf belirlemiřtir. Test ve eęitim verisi iin 80/20 oranını kullanmıřtır.

Yıldız ve Kavzoęlu (2015), segmentasyona etki eden lek parametre deęeri karřılařtırma alıřmasında Quickbird-2 uydu grntsnden yararlanmıřtır. lek parametresi olarak ESP(Estimation of Scale Parameter) tahmin aracının ataması ile belirlenen (26, 53, 77) deęeri ve nesnelerin varyans ve konumsal otokrolasyonuna baęlı (5-300) deęerleri arasında genel skor sonucu olarak (50, 70) deęerlerini kullanmıřlardır. Sınıflandırma algoritması olarak en yakın komřuluk algoritması kullanmıřtır. Sınıflandırma doęruluęunun tekli ve oklu lek doęruluk olarak kıyaslamasını yapmıřtır. Tekli lek parametrelerinin sınıflandırma doęruluęu karřılařtırıldıęında, en yksek sınıflandırma doęruluęu %90,14, oklu lek parametrelerinde ise doęruluęun artıř gstererek %93,26 ve %91,80 deęerlerini verdięini grmřtr.

lkesen ve dię. (2015), obje tabanlı sınıflandırmada blgeleme esasına dayalı lek parametre tespitinde Worldview-2 grnts kullanmıřtır. Segmentasyon iin oklu segmentasyon algoritması kullanmıřtır. Tm grnt iin tek lek yerine grnt blgelere ayrılarak bir blge iin ayrı lek parametresi uygulamıřtır. Blgeler iin kullanılan lek faktrleri olarak 50, 70, 90, 100 deęerlerini uygun grmřtr. Objelerin sınıflandırılmasında DVM ve EYK algoritmaları kullanmıřtır. Tek lek parametresinde DVM'nin % 85,86 genel doęruluk verdięini EYK'nın ise genel doęruluęunun %80,82 olduęunu grmřtr. Blgelere gre ayrı lek deęeri kullanıldıęında DVM algoritmasının %91,78 genel doęruluęa ulařtıęı EYK'nın ise %83,76 genel doęruluk rettięi gzlenmiřtir. DVM'nin EYK algoritmasına gre daha yksek doęruluęa ulařtıęını tespit etmiřtir. Her bir blge iin kullanılan lek deęerinin tek lek deęerine gre daha iyi sonu verdięini bulunmuřtur.

Kavzoğlu ve diğ. (2015), obje tabanlı yaklaşımda makine öğrenme algoritmalarının sınıflandırma etkisini Worldview-2 uydu görüntüsü ile incelemiştir. Sınıflandırma da karar ağaçları, en yakın komşuluk ve destek vektör makineleri algoritmaları kullanmıştır. Kentsel ve kırsal olmak üzere iki alan belirlemiştir. Ölçek parametresi kentsel alan için 40, kırsal alan için 70 değerini uygulamıştır. İki alan için ayrı ayrı 3 algoritmayı hem obje tabanlı sınıflandırma hem de piksel tabanlı sınıflandırma için uygulamıştır. Kentsel alan için obje tabanlı sınıflandırma doğrulukları DVM %90,32, KA %86,18, EYK %84,79 piksel tabanlı sınıflandırma doğrulukları DVM %87,22, KA %83,64, EYK %82,64 sonuçlarına ulaşmıştır. Kırsal alan için obje tabanlı sınıflandırma doğrulukları DVM %96,59, KA %91,78, EYK %91,79 piksel tabanlı sınıflandırma doğruluklarında ise DVM %92,93, KA %90,26, EYK %90,34 sonuçlarına ulaşmıştır. Doğruluk sonuçları kıyaslandığında destek vektör makineleri algoritmasının daha iyi sonuçlar verdiğini tespit etmiştir.

Fırat ve Erdoğan (2015), multispektral hava fotoğrafları ile sayısal yüzey modeli ve sayısal arazi modellerini kullanarak otomatik bina çıkarımını amaçlamıştır. Nesne tabanlı sınıflandırma yazılımı olarak eCognition yazılımını kullanmıştır. Segmentasyon değerleri için denemeler yapmış ve ölçek değerini 25 olarak belirlemiştir. Doğruluk kontrol edildiğinde 144 binanın 116' sını tespit etmiştir. Bina sınıfında %81, ağaç sınıfında %86, su sınıfında %89 doğruluk ile tespit etmiştir.

Karakuş ve Karabörk (2016), arazi örtüsü belirlemesinde SPOT-6 uydu görüntüsünü kullanmıştır. ENVI yazılımıyla atmosferik ve geometrik düzeltme yapmıştır. En uygun ölçeği seçebilmek için ölçek 10, 60 ve 100 değerlerini esas almıştır. Bu değerlerden "60" ile en uygun sonuca ulaşmıştır. ESP ile bulunan en uygun değer "56" olduğunu bulmuştur. Doğruluk karşılaştırılmasında ESP ile bulunan değer deneme yoluyla bulunan değere göre daha iyi sonuç verdiğine ulaşmıştır.

Kavzoğlu ve diğ. (2016), nesne tabanlı sınıflandırma da boyutsallık problemi ve parametre seçiminde AVIRIS sensörüne ait 200 spektral bant, 16 bit radyometrik ve 20 metre konumsal çözünürlüğe sahip 145*145 boyutlarında ve 16 sınıftan oluşan India Pine hiperspektral veri seti kullanmıştır. Piksel tabanlı sınıflandırma da en büyük benzerlik yöntemini tercih etmiştir. Temel bileşen analizi yaparak görüntü boyutunda azaltma yapmıştır. Eğitim alanları referans veri seti olarak tanımlanan bölgenin yaklaşık %30 kapsayacak şekilde her bir sınıf için seçmiştir. Ölçek

parametresi ESP-2 ile hesaplanan grafiğin deęişimin ilk olduęu 29 deęerini seçmiştir. Nesne tabanlı sınıflandırma doęruluęu %78,3 iken piksel tabanlı sınıflandırma doęruluęunu %72,2 olarak bulmuştur.

Sabuncu ve dię. (2016), afet sonrası hasar görmüş ve yıkılmış binaların tespitinde mevsimsel koşulların etkisini yüksek çözünürlüklü uydu verilerinin ve uzaktan algılama teknolojilerinin kullanılabilirliğini Quickbird-2 uydu görüntüsü ve doęruluk için ortofotolar ile incelemiştir. Homojen ve heterojen olmak üzere iki bölgeye ayrı ölçek deęeri vermiştir. Homojen bölge için ölçek deęeri 150, heterojen bölge için ölçek deęeri 80'ni kullanmıştır. Her iki bölge için kontrollü ve kontrolsüz sınıflandırma uygulamıştır. Doęruluklarını karşılaştırmış ve mevsim etkisi ile çatı tiplerinin doęruluęu etkileyen faktörler olduęunu bulmuştur.

Çömert ve dię. (2016), insansız hava aracı verilerinden üretilen ortofotolar ve sayısal yükseklik modeli kullanarak bina çıkarımını gerçekleştirmiştir. Bina çıkarımını eCognition develeoper 6.4 versiyonu ile yapmıştır. Ölçek parametresi için yapılan denemeler ve görsel analizler sonucunda 25 deęeri en uygun ölçek olarak tespit edilmiştir. Doęruluk için elle yapılan sayısallaştırma ile sınıflandırmayı karşılaştırmış ve toplam 37 binanın 34 tanesini başarılı çıkarmıştır. Karşılaşılan problemin gölge etkisi olduęunu bulmuştur.

Dedeoęlu ve dię. (2016), tahıl alanlarının parsel haritalarının obje tabanlı sınıflandırma yöntemi ile SPOT-5 uydu görüntüsüyle yapmıştır. Sınıflandırma ve parsel ayrımları için Erdas Imagine 9 yazılımı kullanmıştır. Ölçek parametresi için yapılan denemeler sonucunda 150 deęerini bulmuştur. Segmentasyon ve elle çizilen sınırlar ArcGIS 9.3 yazılımı kullanılarak karşılaştırmıştır. Doęruluk analizinde %86 oranında benzerlik bulmuştur.

Tonbul ve Kavzoęlu (2017), segmentasyon kalitesinin sınıflandırma doęruluęu üzerine etkisi probleminde multispektral pan-sherpened Quikbird-2 görüntüsü kullanmıştır. Ölçek parametresi olarak ESP-2 tahmini aracından faydalanmıştır. Belirledięi deęerler grafikteki en uç noktalara karşılık gelen 24, 42, 92 olup bunları kullanmıştır.

Yeler ve dię. (2017), tarımsal ürün deseninin 2013 yılındaki yazlık ve kışlık tarımsal desenin haritalanmasında Landsat veri seti kullanmıştır. Sınıflandırmada kontrollü sınıflandırma algoritmalarından maksimum olabilirlik yöntemini tercih etmiştir. Doęruluk analizinde toplam 321 yer gerçeęi verisinin 186'sı sınıflamada kalan 165' i ise doęrulamada kullanmıştır.

Kaynarca ve Demir (2017), karayollarında yer alan araçların çıkartılması ve kategorize edilmesi için 3 bantlı ortofoto görüntüsü kullanmıştır. Nesne tabanlı sınıflandırma için eCognition yazılımı kullanmıştır. Ölçek parametresi için yapılan denemelerde araba için ölçek değerinin 3, otobüs için ölçek değerinin 5 değerini kullanmıştır. Genel doğruluk %80 oranına ulaşmıştır.

Delen ve Şanlı (2017) tarım arazilerinin ürün desenini gösteren tematik harita oluşturmak için RapidEye uydu görüntüsü kullanmıştır. Çoklu çözünürlüklü segmentasyon kullanmıştır. Genel sınıflandırma doğruluğu %93,33 oranına ulaşmıştır.

2. UZAKTAN ALGILAMADA SINIFLANDIRMA İŞLEMİ İLE İLGİLİ TEMEL TANIM VE KAVRAMLAR

Ham halde elde edilen uydu görüntülerinden yeryüzüne ait önemli ve değerli bilgilerin elde edilmesi için çeşitli istatistiksel analizler ve yorumlama tekniklerinden yararlanılmaktadır. Uzaktan algılamada bu amaç doğrultusunda kullanılan en yaygın yöntem uydu görüntülerinin sınıflandırılmasıdır [Çölkesen, 2015]. Elde edilen dijital görüntülerin sınıflandırılmasında ki amaç görüntüdeki her bir piksele karşılık gelen verileri arazi üzerindeki bilgiyle eşleştirerek sınıflarına ayırmaktır.

Sınıflandırma işlemi iki ana basamaktan oluşmaktadır. Birincisi yeryüzündeki nesneleri sembol eden sınıfların tayin edilmesi, ikinci basamak ise sınıflandırılacak piksellere ilişkin sınıf etiketlerinin belirlenmesidir [Mather and Koch, 2011].

Uzaktan algılama da sınıflandırma birçok etkenin düşünülmesini gerektiren kompleks bir yöntem olup tematik bilgi oluşturmak için önemli bir işlemdir. Çalışma alanının ölçeği, kullanıcının yeterliliği ve ihtiyaçları, ekonomik koşullar sınıflandırma sonuçlarının niteliğini, sınıflandırma yönteminin tasarımını, uzaktan algılanmış verinin seçimini etkileyen önemli etmenlerdir [Lu and Weng, 2007]. Uzaktan algılanmış görüntülerin sınıflandırılmasında iki yaklaşım mevcuttur. Bunlar piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırmadır.

2.1. Piksel Tabanlı Sınıflandırma

Piksel tabanlı sınıflandırma, uydu görüntüsünü oluşturan her bir pikselin tek bir arazi örtüsünü tanımlayarak sınıflandırdığı yöntemdir [Çölkesen, 2015]. Sınıflandırma işleminde iki yaklaşım kullanılmaktadır. Bunlar; kontrollü ve kontrolsüz sınıflandırma yöntemleridir. Kontrolsüz (denetimsiz) sınıflandırma da sınıflar algoritmalar aracılığıyla tayin edilirken, kontrollü (denetimli) sınıflandırma da ise sınıflar analizi yapan kullanıcı tarafından belirlenmektedir.

Kontrolsüz sınıflandırma görüntü üzerindeki bilginin tanımlanamaması durumunda tercih edilen sınıflandırma yöntemidir. Bu yöntemin ilk adımı görüntü üzerindeki sınıf sayılarının belirlenmesidir. Kontrolsüz sınıflandırma görüntü üzerindeki piksellere ait değişik bantlardaki sayısal verileri kullanarak benzeri piksellerin otomatik olarak seçilmesi ve bu piksellerin bir sınıfa etiketlenmesini esas almaktadır.

Kontrolsüz sınıflandırmanın ana ilkesi, belirli bir arazi örtüsüne ait piksellerin benzer parlaklık değerlerine sahip olması ve farklı sınıflar arasında belirli bir dereceye kadar ayırım yapılabilmesidir [Lillesand et al., 2007, Çölkesen, 2015]. Sınıflandırma neticesinde ortaya çıkan sınıflar spektraldir. Oluşturulan spektral sınıfların gerçek özellikleri o bölgenin topografik haritaları, hava fotoğrafları ve verilerin mukayese edilmesiyle belirlenebilmektedir [Özkan, 1998].


Kontrollü sınıflandırma, kontrolsüz sınıflandırmanın aksine görüntü üzerindeki bilginin tanımlanması veya uydu görüntüsündeki hangi sınıfların oluşacağı önceden tayin edilerek yapılan sınıflandırmadır. Çalışma alanındaki yeryüzü niteliklerini temsil eden yeterli test alanları kullanılarak sınıflandırılacak her bir cisim için spektral özellikleri tanımlı özellik dosyaları oluşturulur. Belirlenen özellik dosyalarının görüntü verilerine uygulanması ile her bir pikselin hesaplanan olasılık değerlerine göre en çok benzer olduğu sınıfa atanır. Kontrollü sınıflandırma da en çok tercih edilen algoritmalar en kısa uzaklık karar kuralı, paralel kenar kuralı, mahalanobis uzaklığı ve en çok benzerlik algoritmalarıdır [Çölkesen, 2015]. Uydu görüntüsünün sınıflandırılmasında üretilen tematik haritaların doğruluğu ve güvenilirliği açısından en çok başvurulan yöntem kontrollü sınıflandırmadır.

2.2. Nesne Tabanlı Sınıflandırma

Objeler üzerinde sınıflandırma işlemi çıkış noktası görüntüdeki karakteristik doku özelliğinin diğer klasik yöntemlerde göz ardı edilmesi sebebiyle ortaya çıkmıştır [Blaschke et al., 2001; Bilgilioğlu, 2015]. Piksel tabanlı sınıflandırma yönteminden ayıran en büyük özelliği uydu görüntüsündeki pikselleri sınıflandırmaya dahil etmeyip benzer spektral özelliklere sahip piksellerin bir araya gelmesiyle oluşan nesnelerle sınıflandırma işlemi yapmasıdır. Bu yöntem görüntüdeki milyonlarca piksel yerine piksellerin oluşturduğu objeleri baz alan sınıflandırma işlemidir. Obje tabanlı sınıflandırma elde edilen homojen nesnelerin yapı, doku ve spektral bilgileri ile ve bu bilgiler arasındaki ilişkileri esas alarak sınıflandırma işlemidir. Obje tabanlı sınıflandırma da özellikle dar bantlı yüksek konumsal çözünürlüğe sahip verilerde daha iyi neticeler elde edilmektedir [Willhauck, 2000].

Obje tabanlı sınıflandırma Şekil 2.1’de de görüleceği üzere üç temel işlem adımıyla oluşmaktadır. İlk ve en önemli adım uydu görüntüsünün segmentasyonu

ikinci adım veri setinin oluşturulması ve son adım sınıflandırma ve tematik harita üretimi işlemlerinden oluşmaktadır.



Şekil 2.1: Obje Tabanlı Sınıflandırma işlem adımları.

Görüntü segmentasyonunda iki yaklaşım mevcuttur. Bu yaklaşımlar aşağıdan-yukarıya ve yukarıdan-aşağıya olarak ifade edilir. Yukarıdan-aşağıya yaklaşım bütün parçadan küçük parçalara ayrılması işlemi olarak tanımlanabilir ve satranç tahtası, dörtlü ağaç, kontrast ayırma algoritmaları bu yaklaşıma örnektir. Aşağıdan-yukarıya yaklaşım ise küçük parçadan belirli şartları sağlayarak bütün parça oluşturulması olarak ifade edilebilir. Çoklu çözünürlük algoritması (MRS) aşağıdan-yukarıya yaklaşımında en çok tercih edilen segmentasyon yöntemidir [Batz and Schape, 2000; Benz et al., 2004]. Çoklu çözünürlük segmentasyonu görüntüdeki her bir pikseli bağımsız bir obje olarak değerlendirmeye alır ve sonrasında her bir görüntü objesi (piksel) belirli bir homojenlik kriteri esas alınarak komşu pikselleri bir araya getirerek daha büyük görüntü objeleri elde edilir [Çölkesen, 2015]. Çoklu çözünürlüklü segmentasyon işleminde objelerin oluşmasında kullanıcı tarafından belirlmesi gereken parametreler; ölçek, bütünlük ve şekil parametreleridir. Söz konusu parametreler arasında nesne tabanlı görüntü analizi için en önemlisinin ölçek parametresi olduğu ifade edilmektedir [Kavzoğlu ve diğ., 2015; Myint et al., 2011; Belgiu et al., 2014]. Ölçek parametresinin büyüklüğü oluşacak objenin boyutunun büyüklüğünü ifade ederken oluşan segment sayısının azalmasına neden olmaktadır. Kullanıcı tarafından belirlenen değerler duyarlı ve arazi örtüsüne göre seçilmez ise oluşan nesnelerin farklı sınıflara ait bilgiler içereceğinden sınıflandırma doğruluğuna etkisi olacaktır.

2.3. Eğitim Veri Seti Boyutu

Kontrollü sınıflandırma, uzaktan algılanmış görüntüler yardımıyla tematik harita üretimini de içerisine alan birçok çalışmada en sık kullanılan görüntü analiz

teknikidir. Eğitim veri setinin literatürde sınıflandırma veya tahmin doğruluğunda bir işlevi olduğu bu nedenle eğitim veri setinin boyutunun ve kalitesinin tematik harita doğruluğu ile doğrudan ilişkili olduğu ifade edilmektedir [Foody, 1999; Tsai and Philpot, 2002; Foody and Mathur, 2004]. Dolayısıyla sınıflandırmada kullanılacak algoritma farklı biçimlerde eğitim veri setine gerek duyabilmektedir [Foody, 1999]. Eğitim veri seti kullanılan sınıflandırma algoritmalarında yüksek ya da düşük doğrulukta sonuçlar verebilmektedir. Eğitim veri setinin belirlenmesine yönelik literatürde birçok çalışma mevcuttur. Örneğin, Mather (2004), eğitim veri setinde, her bir sınıf için (örneğin heyelan olan ve olmayan alanlar) en az kullanılan faktör sayısının 10 veya 30 katı (10p ve 30p kuralı) kadar örnek nokta veya piksel içermesi gerektiğini ifade etmiştir. Congalton and Green (2008), eğitim veri seti boyutunun belirlenmesinde çoklu terimli olasılık teorisine dayanan istatistiksel bir yaklaşım önermişlerdir. Bu noktada yer doğrulama verisini temsil eden eğitim veri seti boyutu tematik harita üretiminde ve sınıflandırma doğruluğu üzerine etkileri göz önüne alınması gereken önemli bir husustur. Örneğin en çok benzerlik ve Naive Bayes algoritmaları eğitim verisini oluşturan örnekler için olasılık fonksiyonları hesaplanmakta ve buna göre bir pikselin duyarlılık seviyesi belirlenebilmektedir. Bu yüzden istatistiksel hesaplamalar aracılığıyla tahminler gerçekleştirebilen parametrik algoritmalar için fazla sayıda örneğe ihtiyaç duyulmaktadır. Söz konusu yöntemlerin aksine son yıllarda kullanılmaya başlanan karar ağaçları, yapay sinir ağları ve destek vektör makineleri gibi parametrik olmayan yöntemler daha az örnek kullanarak doğru tahminler gerçekleştirebilmektedir [Kavzoglu ve Colkesen, 2012].

2.4. Sınıflandırma Algoritmaları

1972’de ilk uydu görüntüsünün elde edilmesiyle birçok sınıflandırma yöntemi geliştirilmiştir. Sınıflandırma algoritmalarında iki yaklaşım mevcuttur. Bunlar parametrik ve parametrik olmayan yöntemlerdir. Son yıllarda parametrik olmayan yöntemler istatistiksel kabullere dayalı olmadığı için tercih edilmektedir. Parametrik olmayan yöntemlere örnek olarak yapay sinir ağları, destek vektör makineleri ve karar ağaçları verilmektedir [Çölkesen, 2009]. Veri setinin normal dağılımda olduğu kabulüne dayanmayan parametrik olmayan sınıflandırıcı birçok çalışmada parametrik sınıflandırıcılara göre daha yüksek sınıflandırma performansı sergiledikleri vurgulanmıştır [Lu and Weng, 2007]. İleri sınıflandırma algoritmalarının piksel

tabanlı yaklaşımında birçok uygulamadaki başarısı, obje tabanlı sınıflandırmadaki etkinliği önemli bir araştırma konusudur [Heuman, 2011; Ghosh and Joshi, 2014; Kavzoğlu ve diğ., 2015]. Hesaplama açısından hızlı ve matematiksel olarak kolay anlaşılabilen en çok benzerlik yöntemi yaygın bir kullanıma sahip olmakla birlikte dezavantaj olarak görüntü üzerindeki piksellerin normal dağılımda olduğu kabulünü esas almaktadır. Bu sebeple en çok benzerlik yöntemi birbirine benzer spektral özelliğe sahip kompleks ve heterojen yapıdaki piksellerin ayırt edilebilirliğinde yetersiz kalmaktadır [Çölkesen, 2015]. Bu nedenle ileri sınıflandırma teknikleri kullanımı yaygınlaşmıştır.

2.4.1. Karar Ağaçları

Karar ağaçları, sınıflandırma işlemindeki başarısı ve kullanılan karar kurallarının kullanıcılar tarafından açık bir şekilde anlaşılmasından dolayı son yıllarda en sık kullanılan sınıflandırma algoritmalarındandır. Karar ağaçlarının temel çalışma prensibi, kompleks yapıdaki bir sınıflandırma işleminin çözümlenmesinde problemi çok aşamalı bir hale getirerek işlemi gerçekleştirmesidir [Safavian and Langrebe, 1991].

Karar ağacı kök düğüm, dal ve yaprak olmak üzere 3 temel bölümden oluşur (Şekil 2.2) [Quinlan, 1993]. Her uydu görüntüsü için bant değeri bir düğüm tarafından simgelenir [Kavzoğlu ve Çölkesen, 2010]. Karar ağacının oluşumunda ana ilke, verilere bağlı bir dizi soruların sorulması ve elde edilen cevaplara göre karar kuralları oluşturmaktır. Karar ağacının kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar tespit edilene kadar işlem devam eder [Pal and Mather, 2003]. Ağaç yapısının oluşturulmasında dallanmanın hangi şartlara ya da hangi bant değerlerine göre oluşturulacağı en önemli işlem adımıdır [Tso and Mather, 2009; Mather and Koch, 2011]. Bu problemin çözümü için birçok ölçüt bulunmaktadır. Bunlar bilgi kazancı ve bilgi kazanç oranı [Quinlan,1993], Gini indeksi [Breiman et al., 1984], Towing kuralı [Breiman et al., 1984], ve Ki-kare olasılık tablo istatistiği [Mingers, 1989] yaklaşımlarıdır.

2.4.3. AdaBoost Algoritması

AdaBoost algoritması birçok sınıflandırma probleminde kullanılan bir topluluk öğrenme algoritmasıdır. Algoritmanın temel çalışma prensibi iteratif olarak temel sınıflandırıcı olarak seçilen algoritmanın performansına bağlı olarak eğitim veri setinin yeniden düzenlenmesidir. Başlangıç olarak eğitim veri setindeki her bir örnek eşit ağırlıklı kabul edilerek, iteratif olarak sınıflandırma işlemi yapılır. Her bir sınıflandırma sonucunda hatalı sınıflandırılan örnekler eğitim veri setinde tekrar edilerek (ağırlığı artırılarak) sınıflandırma işlemi belirli bir seviyeye ulaşıncaya kadar devam eder. Hatalı sınıflandırılan örnekler yoğunlaşarak sınıflandırma doğruluğunun artırılmasını hedeflemektedir [Çölkesen ve Kavzoğlu, 2017].

Literatürde birçok araştırmacı tarafından kullanılan AdaBoost algoritması etkili bir birleştirme metodudur [Bauer and Kohavi, 1999; Dietterich, 2000; Quinlan, 1996; Maclin and Opitz, 1997]. AdaBoost (hızlandırma) yöntemi en çok tercih edilen algoritma olmasına rağmen dezavantajları da bulunmaktadır. Yetersiz veri olması ve gürültü miktarının fazla (örneğin yanlış sınıf etiketi olması) olduğu durumlarda iyi bir performans elde edilememektedir [Çölkesen, 2009].

2.4.4. En Yakın Komşuluk Algoritması

Parametrik bir algoritma olan en yakın komşuluk (EYK), sınıflandırmada kullanılan yaygın bir metottur. EYK'nın çalışma prensibi sınıf etiketi belli olan piksellerden veya görüntü objelerden faydalanarak sınıfı belli olamayan piksellerin ve objelerin hangi sınıfa ait olduğunun belirlenmesinde bir uzaklık fonksiyonu (örneğin öklit uzaklığı) kullanarak spektral uzaklıkları kullanmaktadır [Lillesand et al., 2007]. En yakın komşuluk algoritması yalın, hızlı ve kolay işlem adımına sahip sınıflandırma işlemidir. EYK algoritmasının dezavantajı görüntüdeki nesnelerin spektral olarak birbirine yakın değerlere sahip olmasından ve yüksek varyans değerlerinden dolayı düşük doğrulukta sonuçlar elde edilmektedir [Lillesand et al., 2007].

3.2. Uydu Görüntüsü ve Özellikleri

Sentinel uydular, programları ve çalışma prensipleri bakımından her biri 2 uydu takımı olmak üzere 6 farklı uydu sisteminden oluşmaktadır. Bu uydu sistemleri Sentinel-1, Sentinel-2, Sentinel-3, Sentinel-4, Sentinel-5 ve Sentinel-6' dan oluşmakta olup görevleri bakımından farklılık göstermektedir [Web 1, 2018, Web 2, 2018].

23 Haziran 2015'de Sentinel-2 uydusu Avrupa Uzay Ajansı tarafından Copernicus programını desteklemek amacıyla gönderilmiş olup Sentinel-2a ve Sentinel-2b olmak üzere 2 eş uydudan oluşmaktadır. Sentinel-2 uydusu; arazi değişimi, arazi analizi ve acil yardımlarda bilgi vermek için gönderilmiştir.

Sentinel-2 uydularının her biri 1,2 ton ağırlıktan oluşmaktadır. Her bir uydu birbiriyle 180° açıyla aynı yörüngede bulunmaktadır. Sentinel-2 uydusunun teknik özellikleri Tablo 3.1'de gösterilmiştir. Tablodan da görüleceği üzere Sentinel-2 uydusu yerden 786 km uzaklıktan görüntüleme yapmakta olup, radyometrik çözünürlüğü 12 bittir. Sentinel-2 uydusunun yaşam süresi 7 yıldır. Sentinel uyduları taramaya başladıkları başlangıç noktasına 5 gün sonra tekrar dönmesiyle aynı bölgeyi 5 gün aradan sonra tekrar görüntüleme şansı tanımaktadır. Dünyayı taradığı şerit genişliği 290 km'den oluşmaktadır [Web 1, 2018].

Tablo 3.1: Sentinel-2 uydusunun teknik özellikleri.

Konumsal Çözünürlük	10/ 20/ 60 m
Yörünge Yüksekliği	786 km
Yaşam Süresi	7 yıl
Radyometrik Çözünürlüğü	12 bit
Ziyaret Sıklığı	5 gün
Sensör Tipi	MSI
Çekim Alanı	-54 ile +84 enlemleri
Şerit Genişliği	290 km

Sentinel-2 uyduları 13 spektral banttan oluşmaktadır. 13 banta ait dalga boyu ve konumsal çözünürlükleri Tablo 3.2'de gösterilmiştir. Tablodan da görüleceği

üzere Sentinel-2 uydusunda mekânsal çözünürlüğü sırasıyla 10, 20 ve 60 m'den oluşmaktadır. Görünür bölgede mavi, yeşil ve kırmızı bantların mekânsal çözünürlüğü 10 metre ve yakın kızılötesi de 10 konumsal çözünürlüğe sahiptir. Bitki sıcak noktaları ve kısa dalga kızılötesinde mekânsal çözünürlüğü 20 metreden oluşmaktadır. 60 metre konumsal çözünürlüğü sahip 3 banta sahiptir. Bunlar kıyı aerosol, su buharı ve kısa dalga kızılötesi (cirrus)dır.

Tablo 3.2: Sentinel-2 uydusuna ait dalga boyu ve çözünürlükleri.

Bantlar	Dalga Boyu (μm)	Çözünürlük (m)
Bant 1 – Kıyı aerosol	0,443	60
Bant 2 - Mavi	0,490	10
Bant 3 - Yeşil	0,560	10
Bant 4 - Kırmızı	0,665	10
Bant 5 - Vejetasyon kırmızı kenar	0,705	20
Bant 6 - Vejetasyon kırmızı kenar	0,740	20
Bant 7 - Vejetasyon kırmızı kenar	0,783	20
Bant 8 - Yakın Kızılötesi	0,842	10
Bant 8A - Vejetasyon kırmızı kenar	0,865	20
Bant 9 – Su Buharı	0,945	60
Bant 10 - Kısa Dalga Kızılötesi	1,375	60
Bant 11 - Kısa Dalga Kızılötesi	1,610	20
Bant 12- Kısa Dalga Kızılötesi	2,190	20

Çalışmada bölgenin arazi örtüsü ve arazi kullanımını belirlenmesi amacıyla 2018 yılında kaydedilen Sentinel-2 uydu görüntüsü kullanılmıştır (Şekil 3.2). Bu çalışmada Sentinel-2 uydu görüntüsünün 10m çözünürlüğe sahip 4 bandı (bant-2, bant-3, bant-4 ve bant-8) ve 20m çözünürlüğündeki altı bandı (bant-5, bant-6, bant-7, bant-8A, bant-11 ve bant-12) kullanılmıştır. 20m konumsal çözünürlüğe sahip bantlar seçilen 10m çözünürlüklü bantlar kullanılarak Gram-Schmidt algoritması yardımıyla pan-sharpen işlemi yapılmıştır. Gram-Schmidt algoritması aynı sensör ile elde edilmiş en yakın komşuluğa sahip bantların pan-sharpen işlemi yapması olarak tanımlanabilir [Sridharan & Qiu 2013; Cho et al. 2015; Kamal et al. 2015; Zhou &

tanımlama işlemi eCognition v9.0.1 yazılımı ile gerçekleştirilmiştir. Doğruluk analizinde kullanılacak olan eğitim ve test veri seti seçimi ile Morans-I yönteminin indeks değerinin hesaplanmasında ArcGIS yazılımından yararlanılmıştır. Rastgele orman, AdaBoost, karar ağaçları ve en yakın komşuluk algoritmaları ile sınıflandırma işleminin gerçekleştirilmesinde, doğruluk analizlerinin gerçekleştirilmesinde Matlab yazılımı kullanılmıştır.

3.4. Nesne Tabanlı Sınıflandırma

Nesne tabanlı sınıflandırma işlemi görüntü üzerindeki benzer spektral özelliklere sahip piksellerin oluşturduğu görüntü objelerini oluşturmak ve sınıflandırma işleminde pikseller yerine oluşturulan bu objeleri sınıflandırma işlemini temel almaktadır. Bu sayede amaç uydu görüntüsündeki milyonlarca pikseller yerine piksellerin oluşturduğu objelerin sınıflandırılmasıdır. Nesne tabanlı sınıflandırmada görüntü segmentasyonu, objelerin özellik tanımlanması, eğitim ve test veri seti oluşturulması son olarak sınıflandırma ve tematik harita üretilmesi adımlarından oluşmaktadır.

Nesne tabanlı sınıflandırmada görüntü segmentasyonu benzer spektral piksellerin bir araya gelmesi görüntü objelerinin oluşturulması olarak adlandırılabilir. Segmentasyon işleminden sonra oluşan görüntü objelerinin birbirinden ayırt edilebilmesi için objelere ait özellikler tanımlanabilir. Temel spektral bilgiler olarak standart sapma, ortalama, minimum ve maksimum değerler tanımlanabilir aynı zamanda obje olarak çalışıldığından objelerin birbirine ilişkileri açısından geometrik özellikleri de değerlendirmede kullanılabilir. Nesne tabanlı sınıflandırma işlemi kontrollü sınıflandırma olduğundan eğitim ve test veri setlerinin oluşturma işlemi yapılmaktadır. Sınıflandırma algoritması yardımıyla oluşturulan eğitim ve test veri setleri kullanılarak doğruluğu yüksek sınıflandırma modeli oluşturulur. Test veri seti yardımıyla sınıfı belli olmayan objelerin sınıflandırma işlemi yapılır. Oluşan görüntü objelerinin sınıflandırma işlemi tamamlandıktan sonra tematik harita üretilir.

3.4.1. Görüntü Segmentasyonu


Uydu görüntüsünün segmentasyon işlemi benzer spektral özelliklere sahip piksellerin bir araya gelmesiyle oluşan nesneler olarak tanımlanabilir. Uydu görüntüsünün segmentasyonu için eCoginition yazılımı kullanılmıştır. Segmentasyon işlemi için çoklu çözünürlüklü segmentasyon (MRS) tercih edilmiştir. Segmentasyon işleminde kullanıcı tarafından belirlenmesi gereken parametreler mevcuttur. Belirlenecek parametreler ölçek, şekil ve bütünlüktür. Bu tez çalışmasında literatürde en çok tercih edilen şekil ve bütünlük parametre değerleri kullanılmıştır. Nesne tabanlı sınıflandırma işleminde ölçek parametre değerinin tespit edilmesi güncel bir araştırma konusudur (Ye ve diğ, 2018). Bu çalışma kapsamında ölçek parametresinin tespitinde ESP-2 (Estimation of Scale Parameter-2) ve Moran's *I* yöntemleri kullanılmıştır.

3.4.1.1. ESP-2 Aracı Yardımıyla Ölçek Parametresi Tespiti

Ölçek parametresi belirleme (Estimation of Scale Parameter- ESP) aracı 2010 yılında Dragut et al., tarafından ecognition developer programının cognition network language (cnl) ortamında geliştirilen ve segmentasyon parametrelerinin belirlenmesi için yardımcı olan bir araçtır. Dragut et al., 2014 yılında ESP aracını geliştirerek lokal varyans değeri hesaplamada tek bant yerine çok bantlı görüntüde işlem yapma imkanı sağlayan ESP-2 aracını geliştirmiştir.

Bu tez çalışmasında uydu görüntüsünün 10 bantlı olmasından dolayı ESP-2 yöntemi tercih edilmiştir. ESP-2 aracının 11 bilinmeyen parametre değeri kullanıcı tarafından belirlenmektedir. Bu parametreler;

- Farklı ölçek parametresi artış miktarı
- Farklı ölçek parametresi başlangıç değeri
- Döngü sayısı
- Hiyerarşisi kullanım onayı
- Hiyerarşi kullanım tipi
- Şekil ve bütünlük parametrelerinden oluşmaktadır (Şekil 3.3).



Şekil 3.3: ESP-2 aracı ve parametre seçimi arayüzü.

ESP-2 aracıyla belirlenen başlangıç ölçek parametresi ile artış miktarına göre görüntü segmentasyonu işlemi ayrı ayrı gerçekleştirilir ve her bir segmentasyon için lokal varyans değeri hesaplanmaktadır. Hesaplanan lokal varyans değerinin değişim oranı Eşitlik 3.1'e göre belirlenmesiyle bir LV-RoC grafiği elde edilmektedir [Kalkan, 2011; Kavzoğlu ve Tombul, 2018].

$$R = \left[\frac{L - (L-1)}{(L-1)} \right] \times 100 \quad (3.1)$$

eşitlikte, L ; hedef nesnenin lokal varyansını, $L - 1$; bir sonraki alt nesne seviyesinin lokal varyansını ve R ; değişim oranını göstermektedir.

Belirlenen ölçek parametrelerine karşılık gelen lokal varyans değerinin değişim oranı grafiği Şekil 3.4'de gösterilmektedir. Değişim oranı grafiğine göre optimum ölçek parametreleri belirlemek için grafikteki ani pik değerleri esas alınmıştır. Şekil 3.4'deki grafiğe bakılarak optimum ölçek parametre değerleri olarak 32, 59,77 ve 94 değeri belirlenmiştir.

için Moran's I yöntemine göre belirlenen optimum ölçek parametresi genel skor değerinin minimum değer aldığı 20'dir.

Tablo 3.3: Moran's *I* yöntemiyle ölçek değeri belirlemede kullanılan bantlar ve değerleri.

	NIR					KIRMIZI					YEŞİL					
Ölçek	Moran's I	Varyans	M_{norm}	Var_{norm}	GS	Moran's I	Varyans	M_{norm}	Var_{norm}	GS	Moran's I	Varyans	M_{norm}	Var_{norm}	GS	$\sum GS/3$
5	0,82	197,32	1	0,00	1,00	0,78	11,658	1	0,00	1,00	0,77	12,99	1	0,00	1,00	1
10	0,70	7622,34	0,82	0,06	0,88	0,70	317,69	0,85	0,02	0,87	0,68	228,00	0,85	0,03	0,87	0,875
15	0,61	21464,03	0,69	0,18	0,87	0,63	1242,7	0,74	0,07	0,81	0,60	649,54	0,72	0,08	0,80	0,828
20	0,55	34524,28	0,60	0,29	0,89	0,57	2537,5	0,64	0,15	0,79	0,55	1165,30	0,62	0,15	0,77	0,817
25	0,50	44961,27	0,54	0,38	0,91	0,52	3838,8	0,56	0,22	0,78	0,50	1708,70	0,54	0,22	0,76	0,818
30	0,46	53797,75	0,47	0,45	0,92	0,49	5080,7	0,50	0,30	0,79	0,46	2248,20	0,49	0,29	0,77	0,826
35	0,42	61231,32	0,42	0,51	0,93	0,45	6296,8	0,44	0,37	0,81	0,43	2788,20	0,43	0,35	0,79	0,840
40	0,39	67707,32	0,37	0,57	0,93	0,42	7386,2	0,39	0,43	0,82	0,40	3282,70	0,38	0,42	0,80	0,851
45	0,36	73636,67	0,33	0,62	0,94	0,39	8383,8	0,34	0,49	0,83	0,37	3749,10	0,33	0,48	0,80	0,856
50	0,33	79540,90	0,29	0,67	0,95	0,35	9391,2	0,27	0,55	0,81	0,33	4247,10	0,25	0,54	0,79	0,854
55	0,30	83689,78	0,25	0,70	0,95	0,34	10216	0,24	0,60	0,83	0,31	4628,00	0,23	0,59	0,82	0,865
60	0,28	89179,88	0,21	0,75	0,95	0,30	11185	0,18	0,65	0,83	0,28	5083,00	0,17	0,65	0,81	0,867
65	0,26	93849,67	0,18	0,79	0,96	0,28	11980	0,14	0,70	0,84	0,26	5446,40	0,14	0,69	0,83	0,878
70	0,22	98232,16	0,12	0,82	0,94	0,27	12858	0,12	0,75	0,87	0,24	5833,80	0,11	0,74	0,85	0,889
75	0,21	101881,20	0,10	0,85	0,96	0,25	13593	0,09	0,79	0,88	0,22	6184,00	0,08	0,79	0,87	0,901
80	0,19	105782,37	0,07	0,89	0,96	0,23	14316	0,06	0,84	0,89	0,21	6514,80	0,05	0,83	0,88	0,910
85	0,18	109291,64	0,06	0,92	0,97	0,22	14954	0,04	0,87	0,91	0,19	6843,80	0,03	0,87	0,90	0,929
90	0,16	112849,82	0,03	0,94	0,98	0,22	15679	0,03	0,92	0,95	0,19	7166,80	0,03	0,91	0,94	0,955
95	0,15	116500,73	0,02	0,98	0,99	0,21	16419	0,01	0,96	0,97	0,18	7493,10	0,01	0,95	0,97	0,979
100	0,14	119422,57	0	1,00	1,00	0,20	17110	0	1,00	1,00	0,18	7853,10	0	1,00	1,00	1

3.4.2. Görüntü Nesnelere İlişkin Özelliklerin Tanımlanması

Tez kapsamında belirlenen çalışma alanının büyük bir çoğunluğu başta mısır, fındık olmak üzere tarım arazilerini kapsamaktadır. Bunun yanında bölgede kavak, gürgen ve farklı geniş yapraklı ağaçları içeren orman sınıfları da mevcuttur. Belirlenen optimum ölçek parametre değerleri ve çoklu çözünürlüklü segmentasyon algoritmasıyla görüntü nesneleri oluşturulmuştur. Oluşan nesnelere ait birçok temel özellik tanımlanabilmektedir. Bu çalışmada spektral özellikler olan minimum piksel, maksimum piksel, standart sapma, bant oranları, normalleştirilmiş fark bitki örtüsü indeksi (NDVI) hesaplanmıştır (Tablo 3. 4).

Tablo 3.4: Nesne tabanlı sınıflandırma işleminde dikkate alınan özellikler.

	Özellik	Açıklama
Temel Spektral Bilgiler	Ortalama	Sentinel-2 bantları (10 bant) ve NDVI
	Standart Sapma	Sentinel-2 bantları (10 bant) ve NDVI
	Maksimum Piksel	Sentinel-2 bantları (10 bant) ve NDVI
	Minimum Piksel	Sentinel-2 bantları (10 bant) ve NDVI
	Bant Oranlaması	Sentinel-2 bantları (10 bant) ve NDVI

3.4.3. Eğitim ve Test Verisi Setlerinin Oluşturulması

Çalışma alanını temsil eden arazi örtüsü ve arazi kullanım sınıfları tespitinde uydu görüntüleri ve tematik haritalardan faydalanılmıştır. Aynı zamanda çalışma alanı olarak belirlediğimiz bölgede yapılan ön etüt sonucunda sınıflar belirlenmiştir. Neticede, çalışma alanında mısır, su, orman, yol, fındık, şehir, toprak ve ekili olmayan arazi olmak üzere 8 arazi örtüsü/kullanım sınıfı belirlenmiştir (Şekil 3.5).

görüntü nesnesi içerirken, geriye kalan 2,318 görüntü nesnesi test veri seti olarak kullanılmıştır. 80:20 örnekleme oranı için 2,578 yer doğrulama nesnesinden 2,063 tanesi eğitim, 515 tanesi test veri seti olarak kullanılmıştır. 32 ölçek değerinde toplam 10,762 görüntü nesnesi üretilirken, örnekleme alanı olarak sınıfları temsil eden toplam 981 nesne tespit edilmiştir. Ölçek değeri 59 iken toplam 3,235 segmentten ise 481 görüntü nesnesi örnekleme alanı olarak seçilmiştir. 77 ölçek parametresinde toplam 1,940 görüntü nesnesi oluşturulmuş olup sekiz sınıf için toplam 368 örnek segmenti seçilmiştir. Son ölçek değeri olan 94 ölçek değerinde ise 1,330 segment elde edilmiştir ve bu segmentler içerisinde 337 eğitim ve test verisi olarak seçilmiştir.

Tablo 3.5: Her bir ölçek ve sınıf için toplanan eğitim veri seti değerleri.

Eğitim veri seti boyutu (Obje Sayısı)									
Ölçek-20	Sınıf	%10	%20	%30	%40	%50	%60	%70	%80
	Mısır	56	111	167	222	278	334	389	445
	Orman	24	49	73	97	122	146	170	194
	Fındık	16	31	47	63	79	94	110	126
	Yol	50	100	150	200	250	300	350	400
	Şehir	52	103	155	206	258	309	361	412
	Su	11	21	32	42	53	64	74	85
	Toprak	16	31	47	62	78	93	109	124
	Arazi	35	69	104	138	173	208	242	277
Ölçek-32	Mısır	20	39	59	78	98	118	137	157
	Orman	9	18	27	36	45	54	63	72
	Fındık	12	25	37	49	62	74	86	98
	Yol	14	28	43	57	71	85	99	114
	Şehir	21	42	63	84	106	127	148	169
	Su	4	8	11	15	19	23	27	30
	Toprak	9	17	26	34	43	52	60	69
	Arazi	10	19	29	38	48	57	67	76

Ölçek-59	Mısır	10	20	30	40	51	61	71	81
	Orman	5	10	15	20	26	31	36	41
	Fındık	5	10	16	21	26	31	36	42
	Yol	10	19	29	38	48	58	67	77
	Şehir	13	27	40	53	67	80	93	106
	Su	2	5	7	10	12	14	17	19
	Toprak	5	9	14	18	23	28	32	37
	Arazi	5	11	16	22	27	32	38	43
Ölçek-77	Mısır	8	16	24	32	41	49	57	65
	Orman	4	8	11	15	19	23	27	30
	Fındık	4	9	13	17	22	26	30	34
	Yol	5	9	14	18	23	27	32	36
	Şehir	7	14	20	27	34	41	48	54
	Su	1	2	4	5	6	7	8	10
	Toprak	4	8	13	17	21	25	29	34
	Arazi	4	8	12	16	20	23	27	31
Ölçek-94	Mısır	7	14	21	28	36	43	50	57
	Orman	4	7	11	14	18	22	25	29
	Fındık	4	8	11	15	19	23	27	30
	Yol	4	9	13	18	22	26	31	35
	Şehir	7	13	20	27	34	40	47	54
	Su	1	2	3	4	5	6	7	8
	Toprak	3	6	8	11	14	17	20	22
	Arazi	4	9	13	17	22	26	30	34

3.4.4. Nesne Tabanlı Sınıflandırma ve Performans Analizi

Nesne tabanlı görüntü sınıflandırma işleminin gerçekleştirilmesi için çoklu çözünürlük segmentasyonu kullanılmış ve ESP-2 ve Moran's *I* araçları yardımıyla 5 olası ölçek parametresi (20, 32, 59, 77 ve 94) tespit edilmiştir. Ölçek parametresi değişimi ile eğitim veri seti boyutu arasındaki ilişkinin analiz edilmesi amacıyla belirlenen 8 farklı eğitim-test veri seti oranı dikkate alınarak ayrı ayrı eğitim-test veri setleri oluşturulmuştur. Hem ölçek parametresindeki değişimlerin hem de eğitim veri setindeki değişimlerin sınıflandırma doğruluğuna etkilerinin araştırılması ve objektif

olarak karşılaştırılması amacıyla 4 farklı sınıflandırma algoritması kullanılmıştır. Sınıflandırma algoritmaları olarak en yakın komşuluk (EYK), rastgele orman (RO), karar ağacı (KA) ve AdaBoost algoritmaları yardımıyla sınıflandırma modelleri oluşturulmuştur.

3.4.4.1. En Yakın Komşuluk Algoritması ile Nesne Tabanlı Sınıflandırma

Her bir ölçek parametresi için segmente edilen görüntüler üzerinden tespit edilen 8 farklı boyutta eğitim-test veri seti en yakın komşuluk (EYK) ile sınıflandırılmıştır. En yakın komşuluk algoritmasının genel doğruluk sonuçları Tablo 3.6'da her ölçek için ayrı ayrı verilmiştir. Ölçek parametresinin 20 olarak seçildiği durumda elde edilen sınıflandırma sonuçları incelendiğinde %10 eğitim veri setinden %80 eğitim veri seti oranına kadar genel doğruluğun yaklaşık %7 değerinde arttığı görülmüştür. 32 ölçek değerleri incelendiğinde %10 eğitim veri setinden %70 veri setine kadar bir artış olduğu fakat %80 eğitim test verisinde genel doğruluğun düştüğü gözlenmiştir. 59 ölçek parametresini incelediğimizde ise belirlenen eğitim veri seti oranlarının genel doğruluk değerlerinde düzenli bir artış ya da azalışın olmadığı görülmektedir. 77 ve 94 ölçek değerlerinde eğitim veri seti artışıyla genel doğruluğun başlangıç seviyesinden %17-19 değerlerinde arttığı ve tekrar azaldığı gözlenmiştir. EYK algoritmasının sonuçları bir bütün olarak analiz edildiğinde en yüksek sınıflandırma doğruluğuna 20 ölçek değerinde %80 eğitim veri seti boyutu kullanıldığında ulaşılrken, en düşük genel doğruluğa da 94 ölçek parametresinde eğitim veri seti boyutunun %10 olarak kullanılması ile ulaşılmıştır. Elde edilen bu sonuç sınırlı sayıda eğitim örneği için EYK algoritmasının performansının düşük olduğunu, eğitim veri setinin boyutunun artışına paralel olarak EYK algoritmasının da arttığını göstermektedir.

Tablo 3.6: EYK algoritması için hesaplanan genel doğruluk değerleri.

Eğitim:Test Oranı (%)	Ölçek-20	Ölçek-32	Ölçek-59	Ölçek-77	Ölçek-94
10:90	78,81	73,62	70,93	63,57	60,21
20:80	80,33	77,71	78,48	73,91	68,53
30:70	81,33	81,23	78,47	75,21	71,62
40:60	83,00	81,16	80,31	77,39	68,97
50:50	82,63	82,49	81,73	78,27	76,34
60:40	83,43	82,44	79,82	80,41	79,26
70:30	83,46	84,41	82,15	78,38	78,44
80:20	86,05	81,22	79,46	72,97	72,06

EYK algoritması ile en yüksek genel doğruluğa sahip (%86,05) tematik harita Şekil 3.6’de verilmiştir. Tematik haritayı incelediğimizde sınıf ayrımlarını kolayca yapılabilmektedir. Su ve mısır sınıfı gerçek arazi örtüsü ve kullanımı ile örtüştüğü anlaşılmıştır. Yol sınıfın bazı bölgeler de şehir sınıfı ile karıştığı gözlenmiştir. Uydu görüntüsünde büyük alan kaplayan mısır sınıfının tematik haritada kapladığı bölge ile örtüştüğü görülmektedir.

Tablo 3.7: KA algoritması için hesaplanan genel doğruluk değerleri.

Eğitim:Test Oranı (%)	Ölçek-20	Ölçek-32	Ölçek-59	Ölçek-77	Ölçek-94
10:90	74,50	73,17	55,59	51,52	45,42
20:80	79,55	76,69	78,26	83,40	72,99
30:70	79,39	80,35	72,83	76,37	71,20
40:60	80,03	79,63	80,61	82,36	70,46
50:50	79,60	82,28	77,79	82,07	84,03
60:40	79,27	82,44	81,17	88,52	77,05
70:30	83,08	82,37	79,17	80,19	74,52
80:20	80,43	77,67	78,57	87,84	79,42

KA algoritması ile en yüksek doğruluğa sahip (%88,52) tematik harita Şekil 3.7’da gösterilmektedir. Tematik haritayı incelediğimizde ekili olmayan arazi sınıfının ayırt edilebilir olduğu görülürken orman ve fındık sınıfının bazı alanlarda iç içe girdiği yani orman sınıfının fındık sınıfı olarak tanımlandığı görülmektedir. Su sınıfının analizi kolay olmakla birlikte bazı bölgelerde yol ve şehir sınıflarıyla karıştığı gözlenmiştir. Çalışma alanının büyük bir kısmını oluşturan mısır sınıfının tematik haritada kapladığı bölgenin gerçek harita ile örtüştüğü gözlenmiştir. Toprak sınıfının ayırt edilemediği ve fındık sınıfı olarak atandığı görülmüştür.

genel doğruluk sonucunu verdiği görülmüştür. Ölçek parametresi 32 olduğunda genel doğruluğun %10 eğitim veri setinden %70 veri setine kadar arttığı fakat %80 eğitim veri setinde genel doğruluğun düştüğü gözlenmiştir. 59 ölçek parametresi için eğitim veri seti oranının artmasıyla genel doğruluğun arttığı ve performansının %15 seviyelerinde yükselme olduğu görülmektedir. 77 ve 94 ölçek değerlerinde genel doğrulukların sabit bir artma ya da azalma eğiliminde olmadığı gözlenmektedir. RO en yüksek sınıflandırma doğruluğunu 77 ölçek değerinde %60 eğitim veri boyutunda elde etmiştir. 94 ölçek parametresi genel doğruluk değerleri RO algoritmasında düşük kaldığı gözlenmiştir. 20 ölçek değerinde veri setinde %30-%40 boyutlarına yaklaşıırken genel doğrulukta %2-4'lük azalma görülürken %80 boyutlarında tekrar yüksek doğruluğa ulaştığı tespit edilmiştir. 20 ölçek parametresi için RO doğruluklarının arasında karşılaştırıldığında daha iyi sonuçlar verdiği gözlenmiştir. 32 ölçek değerine bakıldığında eğitim veri setinin boyutundaki artış genel doğruluğa %9 olarak yansıdığı görülmüştür. RO sonuçları bir bütün olarak bakıldığında eğitim veri seti boyutunun RO algoritmasının performansında etkili olduğu ve ölçek parametresi arttıkça ihtiyaç duyulan örnek sayısının arttığı görülmüştür.

Tablo 3.8: RO algoritması için hesaplanan genel doğruluk değerleri.

Eğitim:Test Oranı (%)	Ölçek-20	Ölçek-32	Ölçek-59	Ölçek-77	Ölçek-94
10:90	87,40	79,40	71,93	73,51	62,53
20:80	84,69	82,30	82,07	84,76	76,32
30:70	83,27	83,56	82,57	82,18	80,52
40:60	85,59	83,70	84,78	84,17	75,88
50:50	86,04	83,71	81,73	84,79	85,21
60:40	85,56	86,52	85,65	88,52	85,19
70:30	87,73	88,47	86,31	84,69	80,40
80:20	87,40	86,29	86,61	87,84	82,35

RO algoritması ile doğruluğu en yüksek olan tematik harita Şekil 3.8'de verilmiştir. Üretilen tematik haritaya bakıldığında mısır sınıfının ayırt edilebilirliğinin yüksek, toprak sınıfının ise düşük olduğu görülmektedir. Fındık ve orman sınıfının karıştığı gözlenmiştir. Haritaya bir bütün olarak baktığımızda su

gözlenmiştir. 77 ve 94 ölçek parametresindeki sonuçlara bakıldığında eğitim veri setinin artışına bağlı olarak genel doğruluk değerlerinin düzenli artmadığı görülmüştür. Ancak ölçek değeri 77 ve 94 değerinde eğitim veri seti artışı ile birlikte genel doğruluğa pozitif etkisi görülmektedir. 94 ölçek parametre değerinin genel doğruluk değerleri diğer parametrelerin verilerine göre kıyaslandığında daha düşük sonuçlar verdiği gözlenmiştir. AdaBoost algoritmasında en yüksek genel doğruluğu 20 ölçek değeri %70 eğitim veri setinde %89,02 değeri ile vermiştir. En düşük genel doğruluk ise 94 ölçek parametresi %10 eğitim veri seti ile elde edilmiştir.

Tablo 3.9: AdaBoost algoritması için hesaplanan genel doğruluk değerleri.

Eğitim:Test Oranı (%)	Ölçek-20	Ölçek-32	Ölçek-59	Ölçek-77	Ölçek-94
10:90	83,63	75,77	73,32	70,80	52,01
20:80	86,00	84,97	85,43	83,06	76,69
30:70	84,16	85,16	85,91	79,46	82,64
40:60	85,91	86,25	85,38	84,17	75,87
50:50	86,66	85,34	84,59	85,33	86,99
60:40	86,44	86,77	88,79	88,52	82,97
70:30	89,02	87,80	85,72	86,49	82,36
80:20	88,76	85,79	88,39	85,14	80,89

Bu tez çalışmasında uydu görüntüsü ile AdaBoost algoritmasıyla (%89,02 doğruluk ile) üretilen tematik haritanın hemen hemen örtüştüğü Şekil 3.9'de görülmektedir. Tematik haritayı analiz ettiğimizde arazi örtüsü ve kullanımı hakkında detaylı bilgiye ulaşılabilmektedir. Tüm sınıfların ayırt edilebildiği ve sınıfların birbirine karışmadığı gözlenmiştir.

4. BULGULAR VE TARTIŞMA

4.1. Ölçek Parametresi ve Eğitim veri Seti Boyutundaki Değişimlere Göre Performans Analizi

Tez kapsamında Moran's *I* ve ESP-2 yöntemi yardımıyla sırasıyla 20, 32, 59, 77 ve 94 değerleri optimum ölçek parametre değerleri olarak belirlenmiştir. Her bir ölçek değerinde 8 farklı örnekleme oranı için EYK, KA, RO ve AdaBoost algoritmalarının performansı analiz edilmiştir. Analizlerde öncelikli olarak her bir ölçek parametresi için algoritmaların performansı genel doğruluk ölçütü kullanılarak ele alınmış, daha sonra sınıf bazında performans analizleri F-skor ölçütü kullanılarak analiz edilmiştir.

4.1.1. Ölçek Parametresi 20 İçin Sınıflandırma Performansının Analizi

Moran's *I* aracıyla belirlediğimiz 20 ölçek değeri kullanılarak gerçekleştirilen segmentasyon işlemi sonucunda oluşturulan görüntü nesneleri üzerinden tespit edilen örnekleme alanları kullanılarak 8 farklı örnekleme oranı göz önüne alınarak eğitim ve test veri setleri oluşturulmuştur. Söz konusu eğitim veri setleri kullanılarak EYK, KA, RO ve AdaBoost algoritmaları ile sınıflandırma modelleri oluşturulmuş ve modellerin doğruluğu test veri seti kullanılarak analiz edilmiştir. Farklı örnekleme oranları için her bir sınıflandırma algoritması ile elde edilen genel sınıflandırma doğrulukları Şekil 4.1' de gösterilmektedir. Şekil 4.1' i incelediğimizde sınıflandırma için kullanılan algoritmaların genel doğrulukların %74-%89 arasında olduğu gözlemlenmiştir. EYK algoritmasında eğitim veri seti boyutunun artışı ile genel doğruluğun da doğrusal bir şekilde arttığı gözlenmektedir. RO algoritması ve AdaBoost algoritmasının yaklaşık aynı genel doğruluk değerlerini verdiği grafikte görülmektedir. Ancak RO algoritması %10 eğitim test verisindeki genel doğruluk AdoBoost algoritmasının %10 eğitim veri setindeki genel doğruluk sonucundan daha yüksektir. Karar ağaçları algoritmasının genel doğruluk sonuçlarına bakıldığında diğer algoritmaların genel doğruluk sonuçlarına göre daha düşük değerler verdiği görülmektedir. RO, EYK, KA ve AdaBoost algoritmalarının en yüksek genel doğruluk sonucunun %70 eğitim test verisinde elde edildiği görülmektedir. 20 ölçek

Grafikler incelendiğinde EYK algoritması için hesaplanan R^2 değeri 0.908 ve AdaBoost algoritması için hesaplanan değer 0,8003 olduğu görülmektedir. KA algoritması için hesaplanan R^2 değeri 0,5189 iken 20 ölçek parametresinde en düşük hesaplanan R^2 değeri RO algoritmasında elde edilen 0,1838 değeridir. Bu sonuçlara bakarak EYK algoritmasının eğitim veri seti boyutu ile tahmini doğruluğu arasında güçlü doğrusal bir ilişki olduğu görülmektedir. Diğer algoritmalar açısından eğitim veri seti boyutu ve sınıflandırma performansı arasında doğrusal bir ilişki olduğu söylenemez.

4.2.2. 32-Ölçek Değeri İçin Kullanılan Algoritmaların İstatistiksel Analizi

ESP-2 yöntemiyle belirlenen 32 ölçek değeri kullanılarak gerçekleştirilen segmentasyon işlemi neticesinde elde edilen görüntü nesnelerinin farklı eğitim veri seti boyutları için EYK, KA, RO ve AdaBoost ile sınıflandırılması neticesinde elde edilen sonuçların istatistiksel analizi için doğrusal regresyon denklemi ve R^2 değeri hesaplanmıştır (Şekil 4.27). Grafikler incelendiğinde hesaplanan en düşük R^2 değerinin 0,1838 olarak RO algoritması ile elde edildiği görülmektedir. Bu durum RO algoritmasının performansının 32 ölçek değerinde eğitim veri setine göre doğrusal olarak değişim göstermediğini ifade etmektedir. Diğer taraftan KA için R^2 değeri 0,5189 olarak hesaplanmış ve eğitim veri seti ile sınıflandırma performansı arasında zayıf bir doğrusal ilişki olduğu görülmüştür. EYK ve AdaBoost algoritmaları için hesaplanan R^2 istatistik değerleri sırasıyla 0,9080 ve 0,8003 şeklindedir. Elde edilen bu sonuç, ölçek parametresinin 32 olarak kullanıldığı durumda eğitim veri setindeki artışa paralel olarak EYK ve AdaBoost algoritmalarının performansının arttığını, dolayısıyla eğitim veri seti ile sınıflandırma performansları arasında doğrusal bir ilişki olduğunu göstermektedir. 32 ölçek parametresi kullanımı için eğitim veri seti boyutu arasındaki doğrusal ilişkinin artması, değişen eğitim veri seti boyutunun özellikle EYK ve AdaBoost algoritmalarının performanslarında pozitif etki edebileceğini göstermektedir.

4.2.3. 59-Ölçek Değeri İçin Kullanılan Algoritmaların İstatistiksel Analizi

ESP-2 yöntemiyle belirlenen 59 ölçek değeri kullanılarak elde edilen görüntü nesnelerinin farklı eğitim veri setleri kullanılarak sınıflandırılması durumunda elde edilen sonuçların istatistiksel analizi için doğrusal regresyon denklemi ve R^2 değeri hesaplanmıştır (Şekil 4.28). Şekilden de görüleceği üzere hesaplanan tüm R^2 değerleri 0,40 değerinin üzerindedir. EYK, KA ve AdaBoost algoritmaları için hesaplanan R^2 değerleri 0,50'nin altında olup sırasıyla 0,4855, 0,4212 ve 0,4802 olarak hesaplanmıştır. Diğer taraftan, 59 ölçek parametresi için RO algoritması ile en yüksek istatistiki R^2 değerinin 0,6350 olarak hesaplandığı görülmektedir. Elde edilen bu sonuç ölçek parametre değerinin 32'den 59'a çıkmasıyla RO algoritmasının sınıflandırma performansı ile eğitim veri setindeki değişimler arasındaki doğrusal ilişkinin arttığını göstermektedir. Diğer bir ifadeyle, RO algoritmasının tahmin performansı ile eğitim veri seti boyutu arasındaki doğrusal ilişkinin oldukça güçlü olduğunu göstermektedir. Diğer taraftan özellikle EYK ve AdaBoost algoritmaları için ölçek parametresinin 59 olarak kullanıldığı durumda, 32 ölçek değeri için hesaplanan yüksek doğrusal ilişkinin önemli derecede azaldığı görülmektedir. 59 ölçek parametresi kullanımı neticesinde hesaplanan istatistiki değerlere göre sınıflandırma performansı ile eğitim veri seti boyutu arasındaki doğrusal ilişkinin azalması, değişen eğitim veri seti boyutunun özellikle EYK ve AdaBoost algoritmalarının performanslarında pozitif veya negatif etki edebileceğini göstermektedir.

4.2.4. 77-Ölçek Değeri İçin Kullanılan Algoritmaların İstatistiksel Analizi

ESP-2 yöntemiyle belirlenen 77 ölçek değerindeki eğitim veri seti boyutundaki değişimler ile tahmin algoritmaları arasındaki ilişki hesaplanan doğrusal eğilim çizgileri ve hesaplanan ve R^2 değerleri kullanılarak incelenmiştir. Bu amaç doğrultusunda EYK, KA, RO ve AdaBoost algoritmaları için oluşturulan doğrusal eğilim çizgileri, doğrusal regresyon denklemleri ve hesaplanan R^2 değerleri Şekil 4.29'da ayrı ayrı verilmiştir. Şekilden de görüleceği üzere EYK, KA, RO ve AdaBoost algoritmaları için hesaplanan tüm R^2 değerleri 0,60 değerinin altında kalmıştır. Hesaplanan en büyük R^2 değeri 0,5880 olarak AdaBoost algoritması ile elde edilirken, en düşük istatistiki değer 0,3378 olup EYK algoritması için hesaplanmıştır. Diğer taraftan KA ve RO algoritmaları için hesaplanan R^2 değerleri sırasıyla 0,4607 ve 0,5979'dur. Elde edilen bu sonuç ölçek parametre değerinin 59'dan 77'ye çıkmasıyla özellikle EYK ve KA algoritmalarının sınıflandırma performansıyla eğitim veri setindeki değişimler arasındaki doğrusal ilişkinin azaldığını göstermektedir. Diğer taraftan küçük ölçek parametre değerleri için elde edilen sonuçlarla karşılaştırıldığında, AdaBoost ve RO algoritmalarının hesaplanan R^2 değerleri açısından performanslarının eğitim veri seti boyutundaki değişime göre olan doğrusal ilişkinin zayıf olduğu söylenebilir. 77 ölçek parametresi kullanımı neticesinde hesaplanan istatistiki değerlere göre sınıflandırma performansı ile eğitim veri seti boyutu arasındaki doğrusal ilişkinin azalması, değişen eğitim veri seti boyutunun EYK ve KA algoritmalarının performanslarında pozitif veya negatif etki edebileceğini göstermektedir.

4.2.5. 94-Ölçek Değeri İçin Kullanılan Algoritmaların İstatistiksel Analizi

Tez kapsamında değerlendirmeye alınan ve en yüksek ölçek parametresi olan 94 değerinin kullanılması durumunda eğitim veri seti boyutundaki değişimler ile tahmin algoritmaları arasındaki ilişki hesaplanan doğrusal eğilim çizgileri ve hesaplanan ve R^2 değerleri kullanılarak incelenmiştir. Bu amaç doğrultusunda EYK, KA, RO ve AdaBoost algoritmaları için oluşturulan doğrusal eğilim çizgileri, doğrusal regresyon denklemleri ve hesaplanan R^2 istatistik değerleri Şekil 4.30'da ayrı ayrı verilmiştir. Doğrusal eğilim grafiklerinden de görüleceği üzere EYK, KA, RO ve AdaBoost algoritmaları için hesaplanan tüm R^2 değerleri 77 ölçek değerinde elde edilen sonuçlara paralellik göstererek 0,60 değerinin altında kalmıştır. Hesaplanan en büyük R^2 değeri 0,5769 olarak EYK algoritması ile elde edilirken, en düşük istatistiki değer 0,4199 olup AdaBoost algoritması için hesaplanmıştır. Diğer taraftan KA ve RO algoritmaları için hesaplanan R^2 değerleri sırasıyla 0,4840 ve 0,5232'dir. Elde edilen bu sonuç ölçek parametre değerinin 77'den 94'e çıkmasıyla özellikle AdaBoost ve KA algoritmalarının sınıflandırma performansıyla eğitim veri setindeki değişimler arasındaki doğrusal ilişkinin azaldığını göstermektedir. Küçük ölçek parametre değerleri için elde edilen sonuçlarla karşılaştırıldığında, özellikle AdaBoost algoritması için hesaplanan R^2 değerleri açısından performanslarının eğitim veri seti boyutundaki değişime göre olan doğrusal ilişkinin zayıf olduğu söylenebilir. 94 ölçek parametresi kullanımı neticesinde hesaplanan istatistiki değerlere göre sınıflandırma performansı ile eğitim veri seti boyutu arasındaki doğrusal ilişkinin azalması, değişen eğitim veri seti boyutunun AdaBoost ve KA algoritmalarının performanslarında pozitif veya negatif etki edebileceğini göstermektedir.

5. SONUÇ VE ÖNERİLER

Yüksek çözünürlüklü uydu görüntülerini sınıflandırmak için klasik piksel tabanlı sınıflandırma yerine nesne tabanlı sınıflandırma tercih edilmektedir. Nesne tabanlı sınıflandırma işleminin doğruluğuna doğrudan etki eden ölçek parametre değeri ve buna bağlı olarak belirlenen veri seti boyutunu belirlemek önemli bir husustur. Sınıflandırmada tercih edilecek yöntem ve elde edilecek sınıflandırma doğruluğu, sınıflandırma sonucunda üretilen tematik haritaların ve belirlenen sınıfların verilerinin doğruluğu ile ilişkilidir. Bu tez kapsamında kullanılan yöntem ve bulgular aşağıda maddeler halinde sıralanmıştır.

- Bu çalışmada ölçek parametresi belirlemede literatürde de en çok tercih edilen ESP-2 ve konumsal otokorelasyon yöntemi olan Moran's *I* yöntemi tercih edilmiştir. Moran's *I* yöntemi ile 20 değeri belirlenirken ESP-2 yöntemi ile 32, 59, 77 ve 94 değerleri elde edilmiştir. Literatürde ele alınan çalışmalarda kullanılan deneme yanılma yönteminin aksine bu yöntemlerin daha hızlı ve doğru sonuçlar ürettiği gözlenmiştir. Belirlenen 5 farklı ölçek parametresinin her biri için 8 farklı veri seti boyutunda eğitim verisi toplanmıştır. Eğitim veri seti boyutu olarak 10:90, 20:80, 30:70, 40:60, 50:50, 60:40, 70:30, 80:20 oranları dikkate alınmıştır. Sınıflandırma işleminin gerçekleştirilmesinde ve tematik harita üretiminde toplu öğrenme algoritmalarından KA, RO, AdaBoost ve sınıflandırma algoritmalarından en sık kullanılan en yakın komşuluk algoritması ile çalışılmıştır.
- Söz konusu eğitim veri boyutları için belirlenen algoritmalarla (EYK, KA, RO ve AdaBoost) ayrı ayrı sınıflandırma modelleri oluşturulmuş ve sonuçlar detaylı şekilde analiz edilmiştir. Tez çalışması sonucunda özellikle eğitim veri seti boyutunun artışına bağlı olarak sınıflandırma doğruluğuna pozitif yönde etkisi olduğu gözlenmiştir. Tez kapsamında kullanılan algoritmaları kendi içerisinde kıyasladığımızda AdaBoost algoritmasının daha yüksek genel doğruluklar ürettiği tespit edilmiştir. 20 ölçek parametresinde örneklerin %60'ı eğitim veri seti olarak kullanıldığında AdaBoost algoritması ile %89,02 genel sınıflandırma doğruluğu elde edilmiştir. Bu tez kapsamında genel sınıflandırma doğrulukları incelendiğinde KA algoritmasının düşük seviyede kaldığı gözlenmiştir. 94 ölçek parametresinde %10 eğitim veri seti

boyutunda KA algoritması ile %45,42 en düşük genel doğruluk elde edilmiştir.

- Bu çalışmada arazi örtüsü ve kullanımı için belirlenen 8 farklı sınıfın her bir algoritma ve her bir ölçek değerinde F-skor sonuçları detaylı şekilde analiz edilmiştir. Bu analizlerin neticesinde su sınıfının arazi çalışma alanında en belirgin sınıf olduğu ve genel olarak F-skorun %100 olduğu görülmektedir. Su sınıfının sonrasında mısır sınıfının yüksek F-skor değerleri ürettiği gözlenmiştir. F-skor sonuçlarını bir bütün olarak incelediğimizde sınıflar içerisinde yol sınıfının düşük performans gösterdiği tespit edilmiştir.
- Sınıf bazında incelediğimizde yol ve şehir sınıfında AdaBoost algoritmasının 20 ve 32 ölçek değerlerinde yüksek F-skor değerleri ürettiği gözlenmiştir. Yani AdaBoost algoritmasının yol ve şehir sınıfının belirlenmesi için çalışmalarda tercih edilebilecek bir yöntem olduğu gözlenmiştir. Mısır, fındık için ölçek değeri 77 iken orman sınıfı için 20 ve 77 ölçek değerlerinde rastgele orman ve AdaBoost algoritmalarının kullanılmasıyla yüksek sonuçlar elde edildiği görülmüştür. Tez çalışmasında rastgele orman ve AdaBoost algoritmasının sınıflandırmada kullanılması genel doğruluk üzerinde pozitif yönde etkisi olduğu gözlenmiştir.
- Ölçek parametre değerinin eğitim veri seti ile genel doğruluk grafikleri irdelendiğinde %10 ile %70 eğitim veri seti boyutuna kadar doğrusal olmayan artışın olduğu gözlemlenirken bazı ölçeklerde %60-%70 ‘den sonra doğruluğun düşüş eğilimine geçtiği gözlenmiştir. Ölçek parametre değeri sınıfların yeryüzündeki kapladığı alan ve aynı zamanda sınıfların araziden ayırt edilebilirliği ile ilişkili olduğu gözlenmiştir.
- Eğitim veri seti boyutundaki değişimler ile sınıflandırma algoritmalar arasındaki ilişki hesaplanan doğrusal eğilim çizgileri kullanılarak ayrı ayrı incelenmiştir. Her bir ölçekteki algoritmalar için doğrusal regresyon denklemleri ve R^2 değerleri hesaplanmıştır. 20 ölçeğinde EYK algoritması için R^2 değeri 0,908 olarak hesaplanmıştır. EYK algoritmasının eğitim veri seti boyutu ile sınıflandırma doğruluğu arasında doğrusal ilişki oldukça güçlüdür.

- Her bir ölçek parametresinin en yüksek ve en düşük genel sınıflandırma doğruluğuna sahip algoritmalarla tematik haritalar üretilmiştir (Ek-A). Tematik haritalar incelendiğinde AdaBoost algoritması ile üretilen haritanın (20 ölçek değerinde) tüm arazi sınıflarının net bir şekilde ayırt edilebildiği gözlenmiştir. Arazi sınıfı ve kullanımı hakkında bilgi sahibi olunabilmektedir.

Tez çalışmasında ölçek değeri ve eğitim veri seti boyutunun sınıflandırma doğruluğunda etkili faktörler olduğu gözlenmiştir. AdaBoost algoritmasının uzaktan algılanan görüntülerin sınıflandırılmasında kullanılabilecek bir yöntem olduğu görülmüştür.

KAYNAKLAR

- Baatz M., Schäpe A., (2000), “Multi-resolution segmentation-An optimization approach for high quality multi-scale image segmentation, In: Strobl, J., Blaschke, T., Griesebner, G. (Eds.)”, Angewandte Geographische Informations Verarbeitung XII. Wichmann-Verlag, Heidelberg, 12-23.
- Bauer E., Kohavi R., (1999), “An empirical comparison of voting classification algorithms: bagging, boosting and variants”, Machine Learning, 36, 105–139.
- Belgiu M., Dragut L. (2014), “Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery.” ISPRS Journal of Photogrammetry and Remote Sensing 96, 67-75.
- Benz U.C., Hofmann P., Willhauck, G., Lingenfelder, I., Heynen, M., (2004), “Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information”, ISPRS Journal of Photogrammetry and Remote Sensing, 58(3-4), 239-258.
- Bilgilioğlu B.B., (2015), “Uzaktan algılanmış görüntülerden faydalınalarak nesne tabanlı sınıflandırma yöntemi ile kent merkezlerindeki detayların çıkarımı ve yorumlanması”, Yüksek Lisans Tezi, Aksaray Üniversitesi.
- Bisht B.S., Kothari B.P., (2001), “Land-Cover Change Analysis of Garur Ganga Watershed Using Gis/Remote Sensing Technique”, Journal of the Indian Society of Remote Sensing, 29 (3), 137-141.
- Blaschke T., (2010), “Object based image analysis for remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing”, 65(1), 2-16.
- Blaschke T., Strobl, J., (2001), “What’s wrong with pixels? Some recent development interfacing remote sensing and GIS”, GeoBIT/GIS, 6, 1, 12-17.
- Boyacı D., Erdoğan, M., Yıldız, F., (2013), “1/50.000 Ölçekli Harita Üretiminde Alan Detayların Aster Uydu Görüntüsünden Sınıflandırma İle Tespiti”, Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu (Tufuab’2013), 23-25 Mayıs 2013, Karadeniz Teknik Üniversitesi, Trabzon.
- Bo S., Han X., (2010), “Parameter Selection for Segmentation in Object-Oriented Classification of Remotely Sensed Imagery”, International Conference on Intelligent Computation Technology and Automation, 876-879.
- Breiman L., Friedman J.H., Olshen R.A. & Stone C.J. (1984), “Classification and Regression Trees”, Monterey, Calif, USA: Wadsworth Inc.
- Breiman L. (2001), “Random forests”, Machine Learning, 45(1), 5-32.

Cai S., Liu D., (2013), “A Comparison of Object-Based and Contextual Pixel-Based Classifications Using High and Medium Spatial Resolution Images”, Remote Sensing, Vol. 4, No. 10, 998-1007.

Cho MA, Malahlela O, Ramoelo A. (2015), “Assessing the utility WorldView-2 imagery for tree species mapping in South African subtropical humid forest and the conservation implications: Dukuduku forest patch as case study”, Int J Appl Earth Obs Geoinf. 38: 349–357.

Congalton R.G., Green K., (2008), “Assessing the Accuracy of Remotely Sensed Data. Principles and Practices”, 2nd edition Boca Raton, FL: CRS Press/Taylor & Francis.

Çölkesen İ., (2009), “Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi”, Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü.

Çölkesen İ., (2015), “Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme” Doktora Tezi, İstanbul Teknik Üniversitesi.

Çölkesen İ., Yomralıoğlu T., Kavzoğlu T., (2014), “Rotasyon Orman Algoritması İle Yüksek Çözünürlüklü Multispektral Uydu Görüntülerinin Sınıflandırılması”, 5. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2014), İstanbul, Türkiye, 14-17 Ekim 2014.

Çölkesen İ., Yomralıoğlu T., Kavzoğlu T., (2015), “Obje Tabanlı Sınıflandırmada Bölgeleme Esasına Dayalı Ölçek Parametresi Tespiti: WorldView-2 Uydu Görüntüsü Örneği”, Harita Dergisi, 154(2),9-18.

Çölkesen İ., Kavzoglu T., (2017), “Kanonik Korelasyon Orman Algoritması ile Uzaktan Algılanmış Görüntülerin Sınıflandırılması”, Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 17(1) Özel Sayı, 102-111.

Çömert R., Avdan U., Uça Avcı D., (2016), “İnsansız Hava Aracı Verilerinden Nesne Tabanlı Bina Çıkarımı”, 6. Uzaktan Algılama-Cbs Sempozyumu (Uzal-Cbs 2016), Adana, Türkiye, 5-7 Ekim 2016.

Dedeoğlu M., Başayığit L., Özaytekin H. H., (2016), “Spot 5 Uydu Görüntüsünde Obje Tabanlı Sınıflama Yöntemleri İle Tahıl Alanlarının Parsel Haritalarının Üretimi”, 6. Uzaktan Algılama-Cbs Sempozyumu, Adana, Türkiye, 5-7 Ekim 2016.

Delen A., Şanlı Balık F., (2017), “Nesne Tabanlı Sınıflandırma Yöntemi İle Tarımsal Ürün Deseninin Belirlenmesi”, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VI. Sempozyumu (TUFUAB VI), Afyon, Türkiye, 27–29 Nisan 2017.

Demers A. M., Banks S. N., Pasher J., Duffe J., Laforest S. (2015), “A Comparative Analysis of Object-Based and Pixel-Based Classification of RADARSAT-2 C-Band and Optical Satellite Data for Mapping Shoreline”, Types in the Canadian Arctic. Canadian Journal of Remote Sensing, 41(1), 1-19.

Dietterich T. G., (2000), “An experimental comparison of three methods for constructing ensembles of decision trees: bagging, boosting, and randomization”, *Machine Learning*, 40, 139 - 157.

Drăgut L., Tiede D., Levick S.R., (2010), “ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data”, *International Journal of Geographical Information Science*, 24(6), 859-871.

Drăgut L., Csillik O., Eisank C., Tiede D., (2014), “Automated parameterisation for multi-scale image segmentation on multiple layers”, *ISPRS J. Photogram. Remote Sens.* 88, 119–127.

Duro D. C., Franklin S. E., Dube M. G., (2012), “Multi-scale object-based image analysis and feature selection of multi-sensor earth observation imagery using random forests”, *International Journal of Remote Sensing*, 33(14), 4502-4526.

Duro D. C., S. E. Franklin, M. G. Dube. (2012), “A comparison of pixel-based and object-based image analysis ith selected machine learning algorithms for the classification of agricultural landscape using SPOT-5 HRG imagery”, *Remote Sensing of Environment* Vol. 118, 259-272.

Espindola G.M., Camara G., Reis I.A., Bins L.S., Monteiro A.M., (2006), “Parameter selection for regiongrowing image segmentation algorithms using spatial autocorrelation”, *International Journal of Remote Sensing*, 27(14), 3035-3040.

Fotheringham A., Brunsdon C., Charlton M., (2000), “Quantitative Geography: Perspectives on Spatial Analysis”, Sage Publications, California.

Fırat O., M. Erdoğan M., (2015), “Nesne (Obje) Tabanlı Sınıflandırma Tekniği İle Multispektral Hava Fotoğraflarından Otomatik Bina Çıkarımı”, *Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği (Tufuab) VIII. Teknik Sempozyumu*, Konya, Türkiye, 21-23 Mayıs 2015.

Foody G.M., (1999), “The Significance of Border Training Patterns in Classification by a Feedforward Neural Network Using Backpropagation Learning”, *International Journal of Remote Sensing*, 20: 3549–62.

Foody G.M., Mathur A., (2004), “A relative evaluation of multiclass image classification by support vector machines”, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1335–1343.

Foody G.M., Mathur A., Sanchez-Hernandez C., Boyd D.S., (2006), “Training set size requirements for the classification of a specific class”, *Remote Sens. Environ.* 104 (1), 1–14.

Ghosh A., Joshi P. K. (2014), “A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery”, *International Journal of Applied Earth Observation and Geoinformation*, 26, 298-311.

Heumann B. W. (2011), “An Object-Based Classification of Mangroves Using a Hybrid Decision Tree-Support Vector Machine Approach”, Remote Sensing, 3(11), 2440-2460.

Johnson B.A., (2013), “High Resolutian Urban Land-Cover Classification Using a Competitive Multi-Scale Object-Based Apprach" Remote Sensing Letters”, Vol.4, No. 2, 131-140

Kalkan K., (2011), “Kentsel Gelişim için Potansiyel Açık Alanların Belirlenmesinde Nesne Tabanlı Sınıflandırma Yöntemi ile Transfer Edilebilir Kural Dizisi Oluşturulması”, Yüksek Lisans Tezi, İstanbul.

Kalkan K., Maktav D., (2010), “Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği)”, III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Kocaeli, Türkiye, 11-13 Ekim 2010.

Kamal M, Phinn S, Johansen K., (2015), “Object-based approach for multi-scale mangrove composition mapping using multi-resolution image datasets”, Remote Sens. 7:4753–4783.

Karakuş P., Karabörk H., (2016), “Esp Ile Nesne Tabanlı Sınıflandırma Kullanılarak Arazı Örtüsünün Çıkarılması”, 6. Uzaktan Algılama-Cbs Sempozyumu (Uzal-Cbs 2016), Adana, Türkiye, 5-7 Ekim 2016.

Kavzoglu T., Çölkesen İ., Kutluğ Şahin E., (2015), “Obje Tabanlı Yaklaşımda Makine Öğrenme Algoritmalarının Sınıflandırma Performansının Analizi”, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Sempozyumu, Konya, Türkiye, 21–23 Mayıs 2015.

Kavzoğlu T.,Tonbul H., Yıldız Erdemir M., Çölkesen İ., (2016), “Hiperspektral Görüntülerin Nesne-Tabanlı Sınıflandırılmasında Boyutsallık Problemi ve Parametre Seçimi”,6. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2016), Adana, Türkiye, 5-7 Ekim 2016.

Kavzoğlu T., Çölkesen İ. (2010), “Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği”, Harita Teknolojileri Elektronik Dergisi, 2, 36-45.

Kavzoglu T., Colkesen I. (2012), “The effects of training set size for the performance of support vector machines and decision trees. In A.O Vieira, V.Bogomy, A.R.Aquino (Ed.), Proceedings of Tenth International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences, (pp.127-132), Brazil: Universidade Federal De Santa Catarina, July 10-13.

Kavzoğlu T., Çölkesen İ., Şahin E.K., (2015), “Makine Öğrenme Algoritmalarının Obje Tabanlı Görüntü Sınıflandırmasındaki Etkinliğinin Araştırılması”, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VIII. Sempozyumu (TUFUAB2015), Konya, Türkiye, 21–23 Mayıs 2015.

Kavzoglu T., Yıldız M., (2015), “Segmentasyonda Optimum Ölçek Parametresi Tespitinde Konumsal Otokorelasyon ve Varyansın Etkisinin Analizi”, Türkiye

Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) VIII. Teknik Sempozyumu, Konya, Türkiye, 21-23 Mayıs 2015.

Kavzoglu T., Sahin E.K., Colkesen I., (2014), “Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression”, *Landslides*, 11:425-439.

Kaynarca M., Demir N., (2017), “Nesne Tabanlı Sınıflandırma İle Karayolunda Bulunan Araçların Tespiti”, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 12-17.

Kim M., Madden M., Warner T., (2008), “Estimation of optimal image object size for the segmentation of forest stands with multispectral IKONOS imagery, In: T Blaschke, S. Lang, and G.J. Hay, (Eds.), *Object-based image analysis concepts for knowledge driven remote sensing applications*”, Springer, 291-307.

Kim M., Warner T.A., Madden M., Atkinson D.S., (2011), “Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects”, *Int. J. Remote Sens.* 32 (10), 2825–2850.

Li C., Shao G., (2012), “International Journal of Remote Object-oriented classification of land use / cover using digital aerial orthophotography”, *International Journal of Remote Sensing*, 33(4), 922-938.

Lillesand T.M., Kiefer R.W., Chipman J.W., (2007), “Remote Sensing and Image Interpretation”, Sixth edition, New York, USA: John Wiley & Sons.

Lu D. & Weng Q. (2007), “A survey of image classification methods and techniques for improving classification performance”, *International Journal of Remote Sensing*, 28(5), 823-870.

Ma L., Cheng L., Li m., Liu Y., Ma X., (2015), “Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery”, *ISPRS Journal of Photogrammetry and Remote Sensing* 102, 14-27.

Maclin R., Opitz D., (1997), “An empirical evaluation of bagging and boosting”, In: *Proceedings of the Fourteenth National Conference on Artificial Intelligence*. AAAI Press, Providence, RI, 546-551.

Maktav D., Siegmund A., Jürgens C., Naumann S., Sunar F., Eşbah H., Levent T., B., Akar İ., Uysal C., Kalkan K., Mercan Y., O., Wolf N., Thunig H., (2010), “Kentsel Gelişim İçin Potansiyel Alanların Uzaktan Algılama Ve Cbs İle Belirlenmesi Ve Değerlemesi”, *Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu*, Gebze – Kocaeli, Türkiye, 11 – 13 Ekim 2010.

Mather P.M. & Koch M. (2011), “Computer Processing of Remotely-Sensed Images: An Introduction. Fourth Edition”, Chichester, UK: Wiley-Blackwell.

Marangoz M. A., Karakış S., Oruç M., Büyüksalih G., (2005), “Nesne-Tabanlı Görüntü Analizi Ve İkonos Pan-Sharpned Görüntüsünü Kullanarak Yol Ve Binaların Çıkarımı”, TMMOB Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara, Türkiye, 28 Mart - 1 Nisan 2005.

Marangoz A.M., (2009), “Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi Ve Cbs Ortamında Bütünleştirilmesi”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.

Mather P.M., (2004), “Computer Processing of Remotely-Sensed Images”, 3rd ed. Chichester: Wiley.

Mybur, G., Niekerk A.V., (2013), “Effect of Feature Dimensionality on Object-Based Land Cover Classification: A Comparison of Three Classifiers”, South African Journal of Geomatics, Vol. 2, No. 1, February.

Myint S. W., Gober P., Brazel A., Grossman-Clarke S., Weng Q. H., (2011), “Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery”, Remote Sensing of Environment, 115(5), 1145-1161.

Özkan C., (1998), “Uzaktan algılama verileri ile orman yangını analizi”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.

Pal M., Mather P.M., (2003), “An assessment of the effectiveness of decision tree methods for land cover classification”, Remote Sensing of Environment, 86(4), 554-565.

Pinho C.M.,Fonseca L. M. G., Korting T. S., Almeida C. M., Kux H. J. H., (2012), “Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis”, International Journal of Remote Sensing Vol.33, No:19, 5973-5995.

Pu R., Landry S., (2012), “A comparative analysis of high spatial resolution IKONOS and Worldview-2 imagery for mapping urban tree species”, Remote Sensing of Environment 124:516–533.

Quinlan J.R., (1993), “C4.5: Programs for Machine Learning, Morgan Kaufmann”, San Mateo, CA, 302.

Quinlan J. R., (1996), “Bagging, boosting, and C4.5. In: Proceedings of the Thirteenth National Conference on Artificial Intelligence (AAAI-96)”, Portland, OR, 725-730.

Sabuncu A., Avcı U.,D., Z., Sunar F., (2016), “Yüksek Çözünürlüklü Uydu Verisi İle Nesne Tabanlı Sınıflandırma Uygulamasında Mevsimsel Koşulların Etkisi”, 6. Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu (UzalCBS'2016), Adana, Türkiye, 5-7 Ekim 2016.

Safavian S.R., Landgrebe D., (1991), “A survey of decision tree classifier methodology”, IEEE Transactions on Systems Man and Cybernetics, 21(3), 660-674.

Selva M., B. Aiazzi F., Butera, L. Chiarantini, S. Baronti. (2015), “Hyper-Sharpening: A First Approach on SIM-GA Data”, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 8 (6), 3008–3024.

Sridharan H, Qiu F. (2013), “Developing an object-based hyperspatial image classifier with a case study using WorldView-2 data”, Photogram Eng Remote Sens. 79:1027–1036.

Tehrany M.S., Pradhan B., Jebuv M.N., (2013), “A Comparative Assessment Between Object and Pikel-Based Classification Approaches for Land-Use/Land-Cover Mapping Using Spot-5 Imagery”, Geocarto International, 29:4, 351-369.

Tonbul H., Kavzoglu T., (2017), “Nesne-Tabanlı Sınıflandırmada Segmentasyon Kalitesinin Sınıflandırma Doğruluğu Üzerine Etkisi”, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VI. Sempozyumu (TUFUAB VI), Afyon, Türkiye, 27–29 Nisan 2017.

Tonbul H., Kavzoğlu T., (2018), “Nesne Tabanlı Görüntü Analizinde Görüntü Bölütleme Yaklaşımları ve Bölütleme Kalitesinin Analizi”, Harita Dergisi, 84(160): 12–23.

Tsai F., Philpot W.D., (2002), “A Derivative-Aided Hyperspectral Image Analysis System for Land Cover Classification”, IEEE Transactions on Geoscience and Remote Sensing, 40: 416–25.

Tso B., Mather P.M. (2009), “Classification Methods for Remotely Sensed Data” Second edition, Boca Raton, FL: CRC Press.

Vieira M. A., Formaggio A. R., Renno C.D., Atzberger C., Aguiar D.A., Mello M.P., (2012), “Object based image analysis and data mining applied to a remotely sensed landsat time-series to map sugarcane over large areas”, Remote Sensing of Environment Vol. 123, 553-562.

Web 1, (2018), <http://www.esa.int>, (Erişim Tarihi: 27/02/2018).

Web 2, (2018), <http://www.nik.com.tr/>, (Erişim Tarihi: 27/02/2018).

Web 3, (2018), <https://www.e-yasamrehberi.com/Turkiye/Sakarya/>, (Erişim Tarihi: 05/03/2018).

Web 4, (2018), <http://www.e-sehir.com/sakarya-cografyasi.html>, (Erişim Tarihi: 05/03/2018).

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 . Geometrics Information and Trading Center by Amsterdam, 33, 214-221.

Ye S., Pontius R.G., Rakshit R., (2018), “A review of accuracy assessment for object-based image analysis: From per-pixel to per-polygon approaches”, *Isprs Journal of Photogrammetry and Remote Sensing*, 141:137-147.

Yeler O., Şatır O., Berberoğlu S., (2017), “Tarım Alanlarında Çok Zamanlı Uydu Verileri Kullanılarak Ürün Deseninin Obje Tabanlı Sınıflama Yöntemiyle Belirlenmesi: Aşağı Seyhan Ovası Örneği”, *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi* , vol.27, 1-9.

Zhou YH, Qiu F. (2015), “Fusion of high spatial resolution WorldView-2 imagery and LiDAR pseudo-waveform for objectbased image analysis”, *ISPRS J Photogramm Remote Sens.* 101:221–232.

ÖZGEÇMİŞ

İsmail AŞIK, 2 Haziran 1990 tarihinde İstanbul'da doğdu. Lise eğitimini Kocaeli yabancı dil ağırlıklı 19 Mayıs Lisesinde tamamladıktan sonra, 2009 yılında Erciyes Üniversitesi harita mühendisliği'nde lisans eğitimine başladı. 2014 yılında mezun oldu. 2015 yılında Gebze Teknik Üniversitesi fen bilimleri enstitüsü harita mühendisliği bölümünde yüksek lisans eğitimine başladı. Yüksek lisans eğitimini sürdürmektedir. 2018 yılında harita mühendisi unvanı ile Ardahan Çevre ve Şehircilik İl Müdürlüğünde atandı. Halen bu görevi sürdürmektedir.