

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ORTOFOTO HARİTALARDAN AĞAÇ TÜRLERİNİN OTOMATİK OLARAK
BÖLÜTLENMESİ**

AKHTAR JAMIL

**DOKTORA TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
UZAKTAN ALGILAMA VE CBS PROGRAMI**

**DANIŞMAN
PROF. DR. BÜLENT BAYRAM**

İSTANBUL, 2018

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ORTOFOTO HARİTALARDAN AĞAÇ TÜRLERİNİN OTOMATİK OLARAK
BÖLÜTLENMESİ**

Akhtar JAMIL tarafından hazırlanan tez çalışması 21.06.2018 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Bülent BAYRAM
Yıldız Teknik Üniversitesi

Jüri Üyeleri





Prof. Dr. Bülent BAYRAM
Yıldız Teknik Üniversitesi

Prof.Dr. Dursun ZAFER ŞEKER
İstanbul Teknik Üniversitesi

Doç. Dr. M.Ümit GÜMÜŞAY
Yıldız Teknik Üniversitesi

Prof. Dr. Cem GAZIOĞLU
İstanbul Üniversitesi

Doç. Dr. Füsun BALIK ŞANLI
Yıldız Teknik Üniversitesi



ÖNSÖZ

“Her bitişin sonunda yeni bir başlangıç vardır.” Doktora çalışmamı yapmak üzere Yıldız Teknik Üniversitesi'nde başladığım gün sanki daha dün gibi. Oysa bu gün hedeflerime ulaşmamda yardımcı olanlara şükranlarımı ifade etme zamanının geldiğini görüyorum. Teşekkürlerime, öncelikle, Türkiye Cumhuriyeti Hükümeti ile başlamak istiyorum. Kendilerine Yıldız Teknik Üniversitesi'nde yaptığım çalışmalara mali destek oldukları için en içten teşekkürlerimi sunuyorum. Bu destek olmadan, doktora öğrenimi için İstanbul'a gelmek benim için mümkün olamazdı.

Diğer teşekkürümü, birçok alanda sahip olduğu engin, derin bilgi ve yeteneklerini her zaman takdir ettiğim tez yürütücüm Sayın Prof. Dr. Bülent Bayram'a sunmak ve doktora tez çalışmam süresince gösterdiği rehberlik, çalışma azmi ve motivasyon için kendisine sonsuz minnettarlığımı ifade etmek istiyorum. Onun rehberliği olmadan 3 dergi makalesi ve 3 konferans bildirisi ile tezimde belirlediğim hedeflere asla ulaşamazdım.

Doktora tez jürimde yer alan komite üyelerine de ayrıca teşekkür etmek istiyorum. Jüri üyelerinden, Prof. Dr. Dursun Zafer Şeker'e özellikle makale ve tez yazımı için verdiği ipuçları ve püf noktaları ile bana yaptığı yardımlar için çok teşekkür etmek istiyorum. Prof. Bayram ve Prof. Şeker'in bana sadece uluslararası bir öğrenci gibi değil, aynı zamanda bir aile üyesi gibi davranmaları nedeniyle, bana hayallerimin ötesinde destek ve rehberlik ettiklerini düşünüyorum. Onların desteği olmadan, tezimin Türkçe versiyonunun da hazırlanmasının mümkün olmadığını itiraf etmek ve bu desteklerinden dolayı da kendilerine bir kez daha teşekkür etmek istiyorum. Diğer tez izleme jüri üyesi olan Doç. Dr. Ümit Gümüştay'a gösterdiği anlayış ve tez izleme sürecindeki destekleri için teşekkürlerimi sunuyorum.

Aile üyelerime, özellikle de evimle ilgili endişe duymadan tezime yoğunlaşmam için çok yardımcı olan, nazik ve cesaret verici sözleri ve sonsuz desteği ile dört yıldır benim için hiçbir fedakârlığını esirgemeyen eşime çok teşekkür etmek istiyorum. Her durumda beni desteklediği için taktir ve minnettarlığımı bütün kalbimle ifade etmek istiyorum.

Bu arada, doktoram sırasında karşılaştığım tüm zorlukları aşmamda bana yardımcı olan arkadaşlarım Mirsat Yeşiltepe, Melih Çınar, Salih Bozkurt, Yavuz Koç, Serdar Yumrudaş ve Zehra Çetin'e teşekkür ederim. Ayrıca tanıştığım ve onlarla birlikte eğlenceli zaman geçirdiğim arkadaşlarıma da teşekkür ederim.

Haziran, 2018

Akhtar JAMIL

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ	xi
ÖZET	xii
ABSTRACT.....	xiv
BÖLÜM 1	
GİRİŞ	1
1.1 Genel Bakış	1
1.2 Problem Tanımı	2
1.3 Tezin Amaçları	3
BÖLÜM 2	
LİTERATÜR ARAŞTIRMASI	5
2.1 Giriş	5
2.2 Algılayıcılar	6
2.3 Piksel ve Nesne Tabanlı Yaklaşımlar.....	7
2.4 Uzaktan Algılama Verilerinin Sınıflandırmasında Makine Öğrenme Yaklaşımları	12
2.5 Çoklu Sınıflandırıcı Yöntemleri	15
2.6 Detay Çıkarma	17
2.7 Özellik Seçimi.....	20

2.8	Özet	22
BÖLÜM 3		
ÖNERİLEN YÖNTEM		23
3.1	Giriş	23
3.2	Çalışma Alanı	23
3.2.1	Başlıca Özellikler	23
3.2.2	Coğrafya ve İklim	24
3.3	Veri Seti	25
3.4	Önerilen Yöntem	27
3.4.1	Ön-işleme	27
3.4.2	Görüntü Bölütleme/Mean-Shift Yöntemi	29
3.4.3	Görüntü Filtreleme	34
3.4.4	Özellik Çıkartma	37
3.4.4.1	Özellik Analizi	40
3.4.4.2	Özelliklerin Normalizasyonu	45
3.4.5	Sınıflandırma	47
3.4.5.1	Destek Vektör Makinası (SVM)	47
3.4.5.2	Yapay Sinir Ağları	50
3.4.5.3	Rastgele Orman (Random Forest)	52
3.4.5.4	Çay Bahçesi Bölütlenemsi için Kullanılan Sınıflandırıcılar	54
BÖLÜM 4		
SONUÇ VE ÖNERİLER		57
4.1	Eğitim Verilerinin Hazırlanması	57
4.2	Sınıflandırıcı Konfigürasyonları.....	63
4.2.1	SVM Konfigürasyonu	63
4.2.2	Yapay Sinir Ağları (YSA) Konfigürasyonu	64
4.2.3	Rastgele Ağaçlar (Random Forest-RF) Konfigürasyonu	66
4.3	Sınıflandırıcıların Eğitimi.....	67
4.4	Sınıflandırma ve Doğruluk Analizi	68
4.5	Parametre Duyarlılık Analizi	74
4.5.1	Örnekleme Eğitim Verisi Seçimi	74
4.5.2	Mean-Shift Yönteminin Analizi	75

BÖLÜM 5

TARTIŞMA VE SONUÇLAR	78
----------------------------	----

5.1 Giriş	78
-----------------	----

5.2 Tezin katkıları ve Uygulamaları	79
---	----

5.3 Gelecek Perspektifi.....	81
------------------------------	----

EK-A

ORİJİNAL GÖRÜNTÜ.....	93
-----------------------	----

EK-B

ÇAY ALANLARINA AİT İKİLİ GÖRÜNTÜNÜN ORİJİNAL ORTOFOTO İLE ÇAKIŞTIRILMASI .	94
--	----



SİMGE LİSTESİ

σ	Standart Sapma
μ	Ortalama
$\mathbb{R}$	Gerçek Sayı
$K(x,y)$	Çekirdek Fonksiyonu
$\cap$	Kesişim
U	Birleşim
$\emptyset$	Boş Küme
$\sqrt{x}$	Karekök
γ	Gamma
C	Cost
$\oplus$	Genişleme
$\ominus$	Erozyon

KISALTMA LİSTESİ

ANN	Yapay Sinir Ağları
APs	Öznitelik Profilleri
CASI	Spektrografik Görüntüleyiciden
CTS	Renk-Doku-Yapı Tanımlayıcısı
DTs	Karar Ağaçları
GEOBIA	Coğrafi Nesne Tabanlı Görüntü Analizi
GLCM	Grey-Level Co-Occurrence
GLDV	Gri Seviye Fark Vektörü
IHA	İnsansız Hava Aracından
JM	Jeffries-Matusita
KFDA	Kernel Fisher Discriminant Analizi
k-NN	K-En Yakın Komşuluk
LISA	Mekansal İlişkilerin Yerel Göstergeleri
LTM	Landsat Tematik Haritalayıcı
ML	Eğitilmiş Makine Öğrenme
MO	Makine Öğrenme
MS	Mean Shift
MSAVI	Düzenlenmiş Toprak Bitki Örtüsü İndeksi
MSVSF	Mean-Shift Vektör Tabanlı Şekil Özelliklerini
NB	Naive Bayes
NDVI	Normalleştirilmiş Fark Bitki Örtüsü İndeksi
NDWI	Normalleştirilmiş Su İndeksi
NTGA	Nesne Tabanlı Görüntü Analizi
PCA	Temel Bileşen Analizi
RBF	Radyal Temel Fonksiyonu
RF	Rastgele Ağaçlar
RS	Uzaktan Algılama
SDA	Stepwise Discriminant Analizi
SVM	Destek Vektör Makinaları
TCC	Ağacın Tepe Genişliği
TCI	Ağaç Kümelenme İndeksi

ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1 Bir görüntüde birden fazla piksele yayılan bir ağaç nesnesi.	10
Şekil 3.1 Çalışma alanının Türkiye haritasında gösterimi.....	25
Şekil 3.2 Örnek ortofoto görüntü (a) RGB kompozit, (b) Referans ikili kodlanmış görüntü ...	26
Şekil 3.3 Önerilen yöntemle ait akış diyagramı	28
Şekil 3.4 RGB görüntüye farklı sigma değerleri seçilerek Gauss yumuşatma filtreis uygulanması a) Orijinal görüntü b) sigma =1 c) sigma = 3 d) sigma =5	29
Şekil 3.5 Rastgele bir veri kümesi için Mean-Shift yönteminin çalışma ilkesi	31
Şekil 3.6 Bant genişliği parametrelerinin bölütlemeye etkisi	33
Şekil 3.7 Çay bahçeleri, diğer vejetasyon, insan yapısı objeler, çıplak arazi ve su kütlelerini temsil eden örnek sınıflar için NDVI profilleri.....	35
Şekil 3.8 3x3 lük yapı taşı elemanı için morfoloji operatörlerinin sonuçları.....	37
Şekil 3.10 Her bir bant için ortalama ve standart sapma	42
Şekil 3.11 Çay bahçeleri ve diğer ağaç türleri için sekiz normalleştirilmiş dokusal özelliğe ait grafik	43
Şekil 3.12. Örnek eğitim verilerinden elde edilen, her bant için minimum, maksimum ve ortalama yansıma değerini gösteren grafik	43
Şekil 3.13 Çay bahçeleri ve diğer ağaç türleri sınıflarının kırmızı, yeşil, mavi ve NIR bantlarında spektral değişimleri	44
Şekil 3.14. Özellik normalizasyonu a) Orijinal gri değerler b) [0, 1] aralığında normalleştirilmiş veriler	46
Şekil 3.15 SVM sınıflandırıcı için hiper düzlem gösterimi.....	48
Şekil 3.16 Örnek bir çok katmanlı ileri beslemeli yapay sinir ağı.....	51
Şekil 3.17 Örnek RF ağaç modeli	54
Şekil 4.1 Her bir sınıf için seçilen örnek eğitim verileri (a) çay bahçeleri (b) diğer ağaçlar	58
Şekil 4.2 Bitki örtüsü olmayan alanları elimine etmek için NDVI maskesi uygulaması.....	60
Şekil 4.3 Eğitim verisi seçim örnekleri (a) Girdi görüntü (b) Bölütlenmiş görüntü (c) referans ikili görüntü (d) eğitim verilerinden türetilen son özellik vektörleri. -1 diğer ağaçları, +1 çay bahçelerini temsil eder.	62
Şekil 4.4 RBF çekirdeği ile SVM için elde edilen optimal parametrelerin görsel temsili	64
Şekil 4.5 MLP için öğrenme doğruluğu (LR) ve genel doğruluk	65
Şekil 4.6 MLP için Momentum vs Genel Doğruluk.....	66
Şekil 4.7 NT için RF genel doğruluk.....	67
Şekil 4.8 RF sınıflandırıcı için özelliğin önemi	67
Şekil 4.9 Sınıflandırma sonuçlarının bir görüntü örneğinde gösterimi	72

Şekil 4.10	(a) Orijinal görüntüde toplanmış çay alanları (b) referans veride toplanmış çay alanları	73
Şekil 4.11	Eğitim verisi büyüklüğünün, her bir sınıflandırıcı ve önerilen yöntemin sınıflandırma doğruluğuna etkisinin analizi	75
Şekil 4.12	Bant genişliği parametresinin önerilen yöntemin sınıflandırma doğruluğuna etkisi	77



ÇİZELGE LİSTESİ

Çizelge 3.1 Kamera ve uçuş bilgileri	26
Çizelge 3.2 Ultracam-X metric kamerasının bazı teknik özellikleri.....	27
Çizelge 3.3 Dokusal Özellikler.....	39
Çizelge 3.4 Çay bahçesi bölütlenmesi için kullanılan özellikler.	45
Çizelge 4.1 Eğitim ve test verisi istatistikleri	60
Çizelge 4.2 SVM ve RBF çekirdek parametreleri	63
Çizelge 4.3 YSA parametreleri	65
Çizelge 4.4 RF parametreleri için grid arama sonuçları.....	66
Çizelge 4.5 Doğruluk Analizi Sonuçları	70
Çizelge 4.6 Önerilen yöntemin doğruluğu (%).	74

ORTOFOTO HARİTALARDAN AĞAÇ TÜRLERİNİN OTOMATİK OLARAK BÖLÜTLENMESİ

Akhtar JAMIL

Harita Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Prof. Dr. Bülent BAYRAM

Uzaktan algılama (RS) teknolojisindeki ilerlemeler, yüksek spektral ve mekânsal çözünürlüklerle görüntü elde etmeyi mümkün kılmıştır. Hem pahalı hem de emek yoğun olan geleneksel saha araştırmaları yaklaşımlarına ve klasik fotoğraf yorumuna tekniklerine alternatif bir çözüm sunar. Öte yandan, çoklu / hiperspektral algılayıcılar ile elde edilen görüntüler genellikle yeterli detay bilgisi sağladığından, böylece nesnelerin ayırt edilebilirliği de artmaktadır. Günümüzde uzaktan algılama teknikleri orman ve tarımsal kaynakların yönetimi ve izlenmesi gibi çeşitli uygulamalarda kullanılabilmektedir. Bununla birlikte, edinilen veri miktarının büyük olması insan eliyle yapılacak sayısallaştırma ya da kullanılan klasik teknikler zaman ve maliyet açısından öngörülür olmaktan uzaktır. Özellikle, ağaç türlerinin elle bölütlenmesi, türler arasında bitki örtüsü bilgilerinin karmaşıklığı ve spektral benzerliğinden dolayı olanaksızdır.

Uzaktan algılama teknolojinin ilerlemesi ile görüntülerin çözünürlükleri artmıştır. Fakat, bu durum görüntülerden nesne çıkartma problem için yeni işlem tekniklerinin geliştirilmesini gerekli kılmıştır. Sunulan tez çalışmasının odak noktası, yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçelerinin tespiti için makine öğrenme temelli sınıflandırıcıların Mean-Shift bölütleme yöntemi ile entegre edilerek nesne tabanlı bir yaklaşıma dayalı çoklu kullanımlarının önerilmesidir. Önerilen yöntem

birkaç ardışık adımdan oluşmaktadır. İlk adımda, pikseller arasındaki semantik ve uzamsal ilişkiyi kullanılarak nesne tabanlı bölütler elde edilmiştir. Bu amaçla parametrik olmayan nesne tabanlı Mean-Shift yöntemi kullanılmıştır. Bu nesneler daha sonra işlemin geri kalanı için yapı taşı olarak kullanılmıştır. Görüntü filtreleme ile gürültülü öğeleri elimine edilmiş ve nesne sınırlarının gürültüsüz olarak elde edilmesi için ise morfolojik işlemler uygulanmıştır.

Öğrenme temelli sınıflandırma aşamasında kullanılacak özellikler üretilen nesne tabanlı bölütler kullanılarak ve bölütlerin spektral, konumsal ve doku özelliklerinden yararlanılarak üretilmiş ve daha sonra sınıflandırıcıları eğitmek ve test etmek için normalleştirilmiştir. Sadece ayırt edici olan ve sınıflandırma sonuçlarını optimize eden özellikler seçilmiştir. İleri derece ayırt edici özellik setini seçmek için Jeffries-Mautasia (JM) mesafe metriği ile sıralı ileriye doğru seçim yöntemi kullanılmıştır.

Sunulan tez çalışmasında Destek Vektör Makinaları (Support Vector Machines-SVM), Yapay Sinir Ağları (Artificial Neural Networks-ANN) ve Rastgele Orman (Random Forest-RF) yöntemleri olmak üzere üç öğrenme temelli sınıflandırıcı seçilmiştir. Bu sınıflandırıcılar, farklı istatistiksel öğrenim ailesine aittir ve büyük ölçekli veri sınıflandırması için etkili oldukları kanıtlanmıştır. Sınıflandırıcıları eğitmek için çay bahçeleri ve diğer ağaç türleri için eğitim verisi seçilmiştir. Söz konusu eğitim verileri her bir sınıflandırıcı için kullanılmıştır. Eğitim ve doğrulama setini kullanarak, her bir sınıflandırıcı için en uygun parametreleri bulmak amacıyla grid arama algoritması uygulanmıştır. Çay bahçelerinin otomatik bölütlenmesi için her bir sınıflandırıcıdan elde edilen çıktılar maksimum oylama yaklaşımı kullanılarak birleştirilmiştir.

Çalışmanın son aşamasında fotogrametrik yöntem ile stereo sayısallaştırılarak elde edilen çay bahçelerine ait sınırlar elde edilen sonuçlar ile karşılaştırılarak doğruluk analizi yapılmıştır. Nesne tabanlı bölütlemenin çoklu sınıflandırıcı yaklaşımla entegrasyonunun, yüksek sınıflandırma doğruluğu ile çay bahçelerinin çıkarılması için etkili bir yöntem olduğu gösterilmiştir.

Anahtar Kelimeler: Nesne tabanlı bölütleme, Destek Vektör Makineleri, Yapay Sinir Ağları, Rastgele Orman, Çoklu sınıflandırıcı

**TREE SPECIES CLASSIFICATION FROM HIGH RESOLUTION DIGITAL
ORTHOPHOTO MAPS**

Akhtar JAMIL

Department of Geomatics Engineering

Doctoral Thesis

Adviser: Prof. Dr. Bülent BAYRAM

Advancement in remote sensing (RS) technology has made it possible to acquire images with high spectral and spatial resolutions. It offers an alternate solution to the traditional approaches of field surveys and manual photo interpretation, which are both costly and labor intensive. On the other hand, images acquired using multi/hyperspectral sensors usually provide enough detail information so that objects even at fine scale can be obtained, which can be used in various applications, such as management and monitoring of forest and agricultural resources. However, the amount of data acquired is so large that manual interpretations by human experts become impractical in many situations. Especially, the task of tree identification is challenging due to complexity of vegetation information and spectral similarity among various species.

RS data has brought both opportunities and challenges which requires development of new processing techniques to effectively extract tangible information. The focus of this research is to investigate an object-based approach based on mean shift and combination of supervised classifiers for detection of tea gardens from high resolution digital orthophoto maps obtained from an airborne sensor. The proposed method was

carried out in several sequential steps. In the first step, the semantic relationship between pixels was exploited and transformed the raw pixels into an object-based representation by using the spatial relationship among pixels. Mean shift based clustering algorithm, which is a non-parametric mode seeking algorithm, was used for delineation of image objects. These objects were then used as building block for the rest of processing. Image filtering was then applied to remove unwanted noisy elements from the object-based representation before extracting features from individual objects. Morphological processing was performed to get smooth object borders and possibly remove small holes within the objects.

Features were derived from spectral, spatial and texture domains from each object and then normalized to train and test the classifiers. Several features were considered, however, only those features were selected which are discriminative and optimized the classification results. Sequential forward selection method was used with Jeffries-Mautasia (JM) distance metric to select highly discriminant feature set.

Three most widely used supervised classifiers were selected for this study, namely support vector machine (SVM), artificial neural network (ANN) and random forest (RF). These classifiers belong to a diverse family of statistical learning and they are proven to be effective for large scale data classification. To train the classifiers, training sample were selected for tea gardens and other types of trees. A brute force grid search algorithm was applied to find optimal parameters for each classifier using training and validation set. The outputs obtained from each individual classifier was combined using a maximum voting approach to produce the final output as thematic map for tea gardens.

Finally, experiments were performed to evaluate the effectiveness of the proposed method for classification of tea gardens from high resolution digital orthophoto maps by comparing with manually digitized tea gardens images. It was shown that integration of object-based segmentation with multi-classifier approach is an effective method for extraction of tea gardens with high classification accuracy.

Keywords: Object-based segmentation, Support Vector Machine, Random Forest, Artificial Neural Networks, Classifier ensemble.

GİRİŞ

1.1 Genel Bakış

Modern görüntüleme teknolojilerinin ortaya çıkışı ile, yer yüzeyine ait hızlı, yüksek mekansal, radyometrik, spektral ve zamansal çözünürlükte görüntü elde edilmesi olanaklı hale gelmiştir. Bu yüksek çözünürlüklü görüntüler; orman envanteri ve yönetimi, tarımsal analiz, afet izleme ve azaltma, kentsel planlama, çevresel izleme, ekosistemdeki değişimleri izleme, su kaynakları yönetimi gibi çeşitli uygulamalarda kullanılabilecek ayrıntılı ve değerli bilgilerin elde edilmesine yönelik önemli veri kaynakları olarak kullanılmaya başlanmıştır. Bu tür verilerden somut bilgiler çıkartmak zor ve karmaşık bir problem olmasına karşın, uzaktan algılama alanında ilginç ve en önemli araştırma konularından biri olarak önemini korumaktadır.

Uzaktan algılama ve ortofoto görüntüleri sadece ormanlık alanların dağılımına ilişkin değil aynı zamanda geniş coğrafi bölgelerdeki ağaç türleri hakkındaki niceliksel bilgileri de içeren ayrıntılı bitki örtüsü bilgi haritasını üretmek için kullanılabilir. Ayrıca, ürün verimliliği, büyüme ve hastalıklı-sağlıklı ağaç türlerinin belirlenmesine yönelik bilgilerin elde edilmesine yönelik amaçlar için de kullanılabilir. Ağaç türlerinin belirlenmesi ve zaman içinde değişimlerinin izlenmesi ekosistem biyoçeşitliliği açısından önemlidir. Bu çeşitli karar alma ve sürdürülebilir orman ve tarım yönetimi sistemleri için önemlidir. Örneğin, ağaç türlerinin dağılımıyla ilgili elde edilen bilgiler, karar vericilerin toplam alanın işgal, dağılım ve bitkisel üretim tahminlerinin sağlıklı yapılmasında yardımcı olabilir. Ayrıca, bölgesel, il veya hatta ülke düzeyinde çeşitli ekonomik faaliyetler için tahminlerin belirlenmesinde vazgeçilmez öneme sahiptir.

Geleneksel olarak, bu tür bilgileri elde etmek için saha araştırmaları veya insan eliyle foto-yorumlama işlemleri yapılır. Bununla birlikte, büyük coğrafik bölgelerde Bu işlem uzmanlık gerektiren, zor, zaman alıcı ve masraflıdır. Sonuçlar, analistin deneyimine büyük ölçüde bağımlıdır. Alternatif olarak, yüksek coğrafi bölgelerden ağaç türlerinin dağılım bilgilerini elde etmek için yüksek çözünürlüklü hiperspektral ve multispektral görüntüler kullanılabilir [1]. Bu nedenle uzaktan algılama veri analizine daha fazla odaklanılmış ve bu tür bilgileri elde etmek için çeşitli yöntemler başarıyla uygulanmıştır. Bu durum, sadece veri analizi uygulamasının şartlarını yerine getirmekle kalmayıp, aynı zamanda geleneksel yaklaşımların sorunlarını da ortadan kaldırır.

Yüksek çözünürlüklü görüntüler, ağaç türlerinin dağılımı hakkında ayrıntılı bilgi vermelerine rağmen, sınıflandırma doğruluğunu etkileyebilecek karışık sınıf problemi ortaya çıkabilmektedir [2], [3], [4]. Bu durum, piksel tabanlı yöntemler yerine nesne tabanlı yöntemlerin kullanımını zorunlu kılar. Piksel tabanlı sınıflandırma probleminin üstesinden gelmek için nesnelerin, piksel yerine temel ölçüm birimi olarak kullanıldığı nesne tabanlı yaklaşımlar önerilmiştir [5], [6]. Nesne tabanlı yöntemlerde spektral bilginin yanı sıra objelere ilişkin geometrik, dokusal ve topolojik özellikler de kullanılır[7].

Eğitilmiş makine öğrenme (Supervised machine learning-ML) yaklaşımları, çeşitli görüntü işleme ve desen tanıma problemlerini çözmek için en yaygın kullanılan makine öğrenme yaklaşımlarıdır. Buna karşın obje çıkartma probleminin çözümünde tek bir sınıflandırıcı kullanılması özellik uzayının boyutlarına bağlı olarak düşük sınıflandırma doğruluğuna neden olabilir. Bu nedenle farklı sınıflandırıcıların bir arada kullanıldığı hibrid yaklaşımlar doğruluğu artırabilecek potansiyele sahiptir [8].

1.2 Problem Tanımı

Dünya yüzeyindeki yeşil alanlar, özellikle ağaçlar, ekosistemin farklı bileşenleri arasındaki dengeyi korumak için hayati bir rol oynamaktadır. Ağaç türleri, karbon döngüsünün kontrolü, sıcaklık dengesi, hava kalitesinin iyileştirilmesi ve sel risklerinin azaltılması gibi paha biçilmez eko-hizmetler sağlamaktadır [9], [10]. Bu nedenle, ağaç türleri hakkında doğru, hızlı ve sürekli bilgi edinilmesi, sürdürülebilir stratejilerin geliştirilmesinde önemli bir rol oynamaktadır.

Ağaç alanı, hacim ve tür kompozisyonunun periyodik olarak raporlanması, izleme ve karar için önemli bir faktördür. Geniş alanlarda gerekli ölçmeleri arazide gerçekleştirmek oldukça zordur. Bu nedenle, uzaktan algılama verileri ağaç türlerinin tanımlanması için bir alternatif ve en ekonomik tekniktir.

Türkiye, Avrupa ve Asya'daki en büyük çay üreticisi ülkelerden birisidir. Çay üretimi ekonomik açıdan ulusal ölçekte önemli bir rol oynamaktadır. Bu nedenle, çay bahçelerinin dağılımının belirlenmesi, izlenmesi ve mevsim ya da yıl bazında çay üretiminin tahmin edilmesi için kullanılabilir. Ek olarak, üretim miktarını doğrudan etkileyecek olan çay türünün sağlığını değerlendirmekte mümkün olabilir.

Çay alanlarının sınırlarının belirlenmesi amacıyla uzaktan algılama verilerinin yanı sıra yüksek çözünürlüklü ortofoto görüntüleri uygun maliyetli veri kaynağı olarak kullanılabilir. Yüksek çözünürlüklü uydu görüntülerinden obje çıkartma problemlerinde nesne tabanlı yaklaşımların piksel tabanlı yaklaşımlara oranla daha tatmin edici sonuçlar ürettiği kanıtlanmıştır [3]. Bu nedenle, sunulan tez çalışmasında yüksek çözünürlüklü ortofoto görüntülerden çay bahçelerinin sınırlarının otomatik olarak çıkartılmasına yönelik nesne tabanlı yaklaşım önerilen multi sınıflandırma yöntemi ile entegre edilmiştir. Önerilen çoklu sınıflandırma yöntemi ise SVM, RF ve Yapay Sinir Ağları (YSA) yöntemlerinin kombinasyonundan oluşmaktadır. Büyük boyutta verilerin kullanıldığı obje çıkartma problemlerinin çözümü için literatürde makine öğrenme yaklaşımı önerilmesine rağmen [3], [11]–[13], tez çalışmasında kullanılan verilerin karmaşıklığı ve boyutları gözönünde bulundurularak alternatif çoklu makine öğrenme yaklaşımının entegre edildiği nesne tabanlı hibrid yaklaşım önerilmiştir.

1.3 Tezin Amaçları

Sunulan tez çalışmasının temel amacı, yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçelerinin çıkarılması için makine öğrenme temelli sınıflandırıcıların nesne tabanlı teknikle entegre edilerek yeterliliğini değerlendirmektir. Tez çalışmasında, Rize iline ait 25 adet üretilmiş dijital ortofoto harita kullanılmıştır. Bunların 15' i eğitim verilerinin elde edilmesinde kullanılmış, önerilen yöntem diğer 10 görüntüde test edilmiştir. Böylelikle, sunulan tezde çay

bahelerin otomatik b l tlenmesine y nelik alternatif  zg n bir y ntem geliřtirilmesi amalanmıřtır.

Genel olarak, sunulan tezin ana hedefleri řunlardır:

- ok bantlı dijital ortofoto g r nt lerinin b l tlenmesinde en uygun tekniėin belirlenmesi.
- B l tleme probleminde en optimum  zelliklerin ve  zellik arama y nteminin belirlenmesi.
- SVM, RF ve ANN y ntemlerinin kombinasyonu ve nesne tabanlı b l tleme y ntemi ile entegrasyonundan oluřan y ntemin y ksek  z n rl kl  g r nt lerde ay bahelerin b l tlenmesindeki performansının arařtırılması.

Sunulan tez alıřması beř ana b l mden oluřmaktadır:

B l m 1, arařtırma konusunun  nemini, problem tanımı ve arařtırmanın temel hedeflerini iermektedir.

B l m 2, hiperspektral ve multispektral veri sınıflandırması iin  nerilen mevcut tekniklerin, aėa t rlerinin belirlenmesine y nelik kapsamlı bir literat r arařtırmasını piksel ve nesne tabanlı y ntemlerin karřılařtırılması ve makine  ėrenme yaklařımlarının ayrıntılı bir aıklamasını iermektedir.

B l m 3, ay bahelerin y ksek  z n rl kl  dijital ortofoto g r nt lerden ıkarılması iin  nerilen y ntemi tarif etmektedir. Bu b l m alıřma alanı, veri seti, g r nt  b l tleme ve sınıflandırma olmak  zere d rt alt bařlıėa ayrılmıřtır.

B l m 4, bu tezde kullanılan veri setinde  nerilen y ntem kullanılarak elde edilen sonuların nicel analizini iermektedir.

B l m 5,  nerilen y ntemin ana katkısı, uzaktan algılamada uygulama potansiyeli ve geleceėe y nelik perspektifi iermektedir.

LİTERATÜR ARAŞTIRMASI

2.1 Giriş

Büyük coğrafi bölgelerdeki ağaç türlerinin haritalanması, bitki örtüsünün yönetimi, izlenmesi ve karar verme aşamalarında önemli bir rol oynamaktadır [14]. Geleneksel olarak ağaç envanteri (sayımı) uygulamalarında, arazi ölçmeleri ve hava görüntülerinin görsel yorumlanması yaygın olarak kullanılmaktadır [3]. Bununla birlikte, bu yöntemler sadece zaman alıcı değil, büyük oranda uzmanlık gerektirdiği için aynı zamanda maliyetleri çok yüksektir. Dahası, geniş coğrafi bölgelerdeki arazi çalışmaları bazen pratik olarak imkânsız olabilmekte ya da sınırlı miktarda toplanan verilerin kullanılmasıyla gerçekleştirilen büyük miktardaki noktalarının enterpolasyonu, yanlış tahminlere neden olabilmektedir. Neyse ki, günümüzde, modern uzaktan algılama teknolojilerinin gelişimi ile geniş alanların spektral ve mekânsal çözünürlükleri yüksek görüntülerin elde edilmesi olanaklı hale gelmiştir. Diğer taraftan, görüntü işleme ve bilgisayarlı görü teknikleri alanındaki gelişmeler, yüksek çözünürlüklü görüntülerden ilgili nesnelerinin otomatik veya yarı otomatik sınıflandırılmasını sağlamıştır [15]. Benzer şekilde, bu teknikler büyük alanlardaki ağaç türlerinin yüksek hassasiyetle sınıflandırılması için de kullanılabilir.

Pasif veya aktif uzaktan algılama algılayıcıları, dünyanın yüzeyindeki nesnelerden yansıyan elektromanyetik enerjiyi kaydeder. Her nesnenin kendine has dielektrik özellikleri olduğundan, geri dönen elektromanyetik enerji miktarı, nesnenin doğasına bağlı olarak değişir. Ayrıca spektral yansıma bilgileri bu nesneleri karakterize ettiği için

türleri birbirinden ayırt etmek için kullanılır ve objelerin spektral imzası olarak da bilinir[16].

2.2 Algılayıcılar

Geçmiş çalışmalar, farklı uygulamalar için çeşitli görüntü elde etme algılayıcılarının kullanıldığını göstermektedir. Bu algılayıcılar, uydulara, hava araçlarına ve hatta son zamanlarda yaygın olarak kullanılan insansız hava araçlarına monte edilebilirler [17]. Tarihsel olarak, hava fotoğrafları, ağaç türlerinin haritalanması için yaygın olarak kullanılmışlardır. Ancak sadece yeryüzündeki küçük alanlarda bu çalışmalarının gerçekleştirilmesine olanak sağlamıştır. Son yirmi otuz yıldır, geniş coğrafi bölgeleri kapsayan görüntüleri sağlayabilen, uydulara monte edilmiş algılayıcılar geliştirilmiştir. Bu algılayıcılar, MODIS ve SPOT-4 gibi göreceli olarak daha düşük çözünürlüklü görüntüler (0,5 - 1km) olmalarına karşın, nispeten daha büyük coğrafi değişiklikleri veya büyük ölçekli nesneleri haritalamak için kullanılmaktadır.

Orta çözünürlükte algılama yapan uyduların (10 - 30m) gelişimiyle birlikte, büyük coğrafi alanlarda orman alanlarının haritalanması ve yönetimi mümkün olmuştur. Örneğin, [18], Haiti'deki toplam orman alanının tahmini için Landsat Tematik Haritalayıcı (LTM) verilerini kullanmıştır. [19], Ekim alanlarının haritalanması için farklı zamanlarda alınmış Landsat ve MODIS verileri için özellik seçimi, nesne tabanlı bölütlendirme ve karar ağaçlarının entegrasyonuna dayalı bir yöntem önermiştir. SPOT uydu görüntü verileri [7], [20]–[24]' te kullanılmıştır. ASTER verileri ağaç türlerinin sınıflandırılması için [10], [25]–[30]'da kullanılmıştır. Benzer şekilde, SAR teknolojileri büyük alanlarda ağaç türleri bilgilerinin türetilmesi için [31], [32] gibi farklı çalışmalarda kullanılmıştır. Bu algılayıcılar, bulut veya hava koşullarından daha az etkilendikleri için geniş coğrafi alanlardaki ormanların haritalama çalışmaları için daha kullanışlıdır. Veri toplamak için doğal ışığa bağımlı olmadıkları için hem gündüz hem de gece boyunca herhangi bir kısıtlama olmaksızın çalışabilirler.

Son zamanlarda göreceli olarak yüksek geometrik, radyometrik ve spektral çözünürlüklerde görüntü toplayan yeni algılayıcılar geliştirilmiştir. Bu algılayıcılar 1 metreden daha az ve çok yüksek çözünürlüklü görüntüler elde etme kabiliyetine sahiptir. WORLDVIEW-2, QUICKBIRD-2, RAPIDEYE ve IKONOS gibi algılayıcılar, 0.5 ve

1m uzaysal çözünürlükte pankromatik görüntüler üretebilirken, multispektral görüntüler için çözünürlük 1,8 m ile 6,5 arasında değişiklik göstermektedir [21]. Bu algılayıcılar, [4], [10], [23], [26], [33], [34] gibi çalışmalarda ağaç türleri çıkartma ve arazi örtüsü sınıflandırma çalışmalarında yaygın olarak kullanılmışlardır.

Son yıllarda hava araçlarından toplanabilen, yüksek mekânsal ve spektral çözünürlüğe sahip algılayıcılar kullanılmaya başlanmıştır. Bu algılayıcılar, küçük detayların da görülmesini sağlayan görüntüler üretmekte ve bu görüntüler ile görece küçük nesneler algılanabilmektedir. Bu tür algılayıcıların bir örneği Ultracam D, X ve Xp'dir. Bu algılayıcılar (ve çeşitli versiyonları) [3], [19], [35]–[37] gibi ağaç türleri çıkarma ve arazi örtüsü sınıflandırması çalışmalarında kullanılmıştır.

Son zamanlarda hava araçlarından toplanan hiperspektral algılayıcılar çoğunlukla orman ve tarımla ilgili uygulamalarda kullanılmıştır. Bu algılayıcılar, elektomanyetik spektrum üzerinde 400 nm'den 2700 nm'ye kadar değişen aralıkta yüzden fazla band görüntüsü üretebilir [21]. Band şeklinde sağlanan ek bilgiler, ilgili nesnelerinin küçük detaylarını çıkarmak için kullanılabilir. [1], [23], [34], [38]–[40] gibi bazı yeni araştırmalar, ağaç türlerinin sınıflandırılması için hiperspektral görüntüleri kullanmaya odaklanmıştır.

2.3 Piksel ve Nesne Tabanlı Yaklaşımlar

Hem piksel hem de nesne tabanlı yaklaşımlar uzaktan algılama görüntü analizi işlemlerinde yaygın olarak kullanılmaktadırlar. Bununla birlikte, nesne tabanlı yöntemler son yıllarda özellikle de çoklu spektral ve hiperspektral bandlara sahip görüntülerin işlenmesinde piksel temelli yaklaşımlara göre daha üstün ve yaygın duruma gelmiştir [15]. Aslında, birçok araştırmacı, piksel tabanlı yaklaşımların sınırlamaları göz önüne alındığında, nesne tabanlı yöntemlerin, objelerin daha anlamlı bir temsilini sağladığını ve geleneksel yöntemlerle kıyaslandığında çeşitli uygulamalar için daha güvenilir sonuçlar üretebileceği sonucuna varmışlardır [41].

Geleneksel olarak uzaktan algılama verilerinin sınıflandırılması için geliştirilen yöntemlerin çoğu tekil olarak piksele dayanmaktadır [41]. Bununla birlikte, yeni nesil algılayıcıların ortaya çıkmasıyla, daha yüksek çözünürlüğe sahip görüntülerin elde

edilebilmesi nedeniyle piksel tabanlı yöntemlerin, modern görüntü bölütlemesi ve analizi ihtiyaçlarını karşılayamayacağı değerlendirilmiştir. Piksel tabanlı yaklaşımların yüksek çözünürlüklü verilerde sınıflandırma doğruluğunu düşürme potansiyeli vardır.

Uzaktan algılama görüntü analizi çalışmalarında kullanılan yaklaşımlar; bireysel piksel tabanlı yaklaşımlardan uzaklaşarak nesne tabanlı yaklaşımlara kaymıştır [15]. Nesne tabanlı yaklaşım, yüksek çözünürlüklü görüntülerin segmentasyonu için çok daha fazla avantajlar sağlar. Örneğin, gerçek dünyadaki ağaç gibi bir nesne, değişik spektral değerlere sahip birkaç pikselden oluşur. İdeal olarak, tüm bu pikseller farklı gri tonlama değerlerine sahip olsalar bile tek bir nesnede gruplandırılmalıdır. Daha sonra, tüm nesneye özelliklerine bağlı olarak bir sınıf etiketi atanabilir. Sonrasında, bütün objeler kendi karakteristik özelliklerine bağlı olarak aynı sınıf etiketine atanabilir. Ek olarak, nesnelerden piksel tabanlı yaklaşımla mümkün olmayan şekil, geometrik ve bağlamsal bilgiler gibi daha fazla bilgi elde edilebilir. Bu bilgi nesnelerin tanımlanmasında yardımcı olabilir ve sınıflandırma doğruluğunu artırabilir.

Piksel, bir görüntüdeki bilgileri tutan en küçük objedir ve boyutları, algılayıcı ve geometrik modellerle belirlenir [42]. Gerçek dünyadaki nesneler hakkında spektral yansıma biçiminde çok önemli bilgiler sağlar. Çünkü evrendeki her nesne, elektromanyetik ışınımına maruz kaldığında farklı bir tepki sinyali üreten bazı benzersiz dielektrik özelliklere sahiptir. Yansılardan toplanan enerji, bu nesneyi karakterize eden bir piksel içinde toplanabilir.

Yansıma (piksel) değeri, gözlemlenen nesnenin türünü yorumlamak için kullanılabilir. Birçok yöntem uzaktan algılama verilerinin sınıflandırılması için piksel yansıma değerlerini kullanmıştır. Örneğin, [43], SVM ile birlikte piksel tabanlı bir yöntemi ve maksimum benzerlik yöntemini arazi örtüsünün sınıflandırması ve multispektral görüntülerden iğne yapraklı ağaçlar türlerinin çıkarılması için kullanmıştır. [44]'te yabani otları haritalamak için QUICKBIRD algılayıcısından sağlanan veriler yardımıyla nesne ve piksel tabanlı yaklaşımların karşılaştırmalı bir analizini gerçekleştirmiştir. [45] uzaktan algılama verilerinden elde edilen zamansal değişimi belirlemek için piksel tabanlı ve nesne tabanlı yaklaşımlardan elde edilen sonuçları karşılaştırmıştır. [46], IKONOS görüntülerinden mangrov türlerini haritalamak için üç yaklaşım uygulamıştır.


Bunlar, piksel tabanlı sınıflandırma için en çok benzerlik sınıflandırıcısı, nesne tabanlı sınıflandırma için k-en yakın komşuluk yöntemi ve hem piksel hem de nesne tabanlı yöntemleri bir araya getiren bir karma yaklaşım kullanmıştır. Benzer şekilde, [26], WORLDVIEW -2 verilerinden on farklı ağaç türünün tanımlanması için RF sınıflandırıcısı ile hem nesne hem de piksel tabanlı yaklaşımları karşılaştırmışlardır. [47]'de, hiperspektral görüntülerin sınıflandırılması için SVM'li bir piksel tabanlı yöntem kullanılmış ve spektral-uzaysal bilgilerin kenar koruma filtresi uygulamışlardır. [48], WORLDVIEW -2 verilerinden tek tek ağaçların sınıflandırılması için piksel tabanlı bir yaklaşım ve en çok benzerlik yöntemini önermiştir.

[1]'de, hiperspektral görüntülerin sınıflandırılması için bir olasılık-tabanlı SVM ile piksel-tabanlı yöntemi birleştirilmesi önerilmiştir. Hem spektral hem de dokusal özellikler, her bir pikselden türetilmiş ve veri kümeleri için en iyi sınıflandırma doğrulukları üreten sınıflandırma için sınıflandırıcı desteklemiştir.

Piksel tabanlı yaklaşımların bazı dezavantajlara sahip olduğu gerçeğinin bilinmesine karşın, bazı çalışmalar bu yaklaşımların kullanılmasının uzaktan algılama veri sınıflandırmasında daha yüksek sınıflandırma doğruluğu elde edildiğini göstermiştir [1], [44], [45]. Ancak, modern algılayıcıların artık daha yüksek çözünürlükte görüntü elde edebiliyor olması nedeniyle görüntünün çözünürlüğü göz önünde bulundurulan nesnenin boyutundan daha düşük olduğunda, komşuluk bilgilerini birleştirmek, tek tek pikselleri kullanmaktan ziyade nesneleri temsil etmek için daha önemlidir. Örneğin, yüksek çözünürlüklü bir görüntüdeki tek bir ağaç, spektral yansıma değerleri birbirine yakın birkaç pikselden oluşabilir (Şekil 2.1). Bu durumda, komşu pikseller hakkında bilgi büyük önem taşımaktadır. Bununla birlikte, piksel tabanlı yaklaşımlar bağlamsal bilgileri hesaba katmaz ve her bir pikseli bağımsız olarak ele alır. Son yaklaşımların, piksel tabanlı yöntemlerin anlamsal boşluklarını doldurmak için nesneye dayalı bölümlere ayırma yaklaşımlarına bağlı olmasının temel nedeni budur.

Piksel tabanlı yaklaşımlar sadece bölge bilgilerini çıkarmakta yetersiz kalmaz aynı zamanda sınıf içi değişkenlik ve sınıflar arası benzerlikle de çözüm getiremez. Bu semantik boşlukların üstesinden gelmek ve daha yüksek mekânsal ve spektral çözünürlükte görüntü verilerinden daha doğru sınıflandırma sonuçları elde etmek için

nesne tabanlı yöntemler alternatif bir çözüm sunar. Son yıllarda uzaktan algılama verilerinin sınıflandırma problemlerinde nesneye dayalı sınıflandırma yöntemleri yaygın olarak kullanılmaktadır.



Şekil 2.1 Bir görüntüde birden fazla piksele yayılan bir ağaç nesnesi.

Nesne tabanlı görüntü analizi yöntemleri, spektral olarak benzer pikselleri homojen bölgeler halinde gruplandırır. Aslında, aynı nesneye ait piksellerin benzer spektral değerlere sahip oldukları varsayılır. Tek tek pikselleri bir nesne temsiline dönüştürerek, gerçek dünyada olduğu gibi nesneler arasında boyut, şekil ve coğrafi ilişki gibi ek bilgiler elde etmeyi sağlar [49]. Yüksek çözünürlüklü verilerle karşılaşılan sorunların üstesinden gelmek için coğrafi nesne tabanlı görüntü analizi (GEOBIA) tanıtılmıştır. GEOBIA ilk kez [41]'de yeni paradigma olarak ele alınmıştır. Pek çok araştırmacı nesne tabanlı yaklaşımları kullanarak daha yüksek sınıflandırma doğruluğu elde ettiklerini bildirmişlerdir. Örneğin, [50]'de nesne tabanlı bir teknik ile Pohutukawa ağaçlarının sınıflandırılması için LIDAR ve arazi verisini birleştirmeyi önermişlerdir. Yükseklik ve yapısal bilgiler LIDAR verilerinden elde edilirken, topografik ıslaklık indeksi ve eğim bilgileri CBS verisinden elde edilmiştir. Toprak zemin üzerindeki nesneleri elimine etmek için yükseklikteki eşik değeri gibi veya yeşil alanları binalardan ayırt etmek için NDVI kullanmak gibi birçok teknikle beraber LIDAR'ın ilk ve son dönüşü ve geometrik bilgiler kullanılarak tek ve aynı tür ağaç grupları arasındaki farkları ayırt edebilmek için uygulanmıştır. Ağaç kümelerini bireysel ağaçlara ayırmak için bölgesel büyüme yöntemi uygulanmıştır. Her nesneden geometrik nesne özellikleri (eliptik uyum, en boy oranı, nesne alanı) elde edilmiş ve özellik seçimi için Random Forest yöntemi uygulanmıştır.

Son olarak, nesneler, SVM sınıflandırıcısı tarafından ilgili sınıflara ayrılmışlardır. [51]'de LIDAR ve QUICKBIRD algılayıcılarından elde edilen verileri kullanarak orman türleri sınıflandırması için nesne tabanlı bir yaklaşım kullanılmıştır. Yalnızca spektral veriler kullanılarak üç nesne bölütleme yaklaşımı test edilmiştir. Son olarak, denetimli karar ağaçları sınıflandırma için kullanılmıştır. [5], insansız hava aracından (İHA) elde edilen dört ağaç türünün sınıflandırılması için Random Forest yöntemi ile bir nesne-taban görüntü analizi tekniğini birleştirmiştir. [50]'de, Pohutukawa ağaçlarının sınıflandırılması için nesne tabanlı teknik LiDAR ve arazi değişkenleri ile birleştirilmiştir. LIDAR verileri boy ve yapısal bilgiler sağlarken, topografik ıslaklık indeksi ve eğim bilgileri CBS verisinden elde edilmiştir. [28]'de ağaç türlerinin sınıflandırılması için nesne tabanlı yaklaşım kullanılmıştır. Gölge indeksi, NDVI, doku tabanlı özellikler ML, Mahalanobis Mesafesi, Yapay Sinir ağı ve spektral açışleştiricisi olarak ifade edilen dört sınıflandırıcı kullanılarak çıkartılmıştır. [52]'de, nesne tabanlı bir yöntem kullanarak uzaktan algılanan verilerin sınıflandırılması için SVM sınıflandırıcısının etkinliğini değerlendirmiştir. Sonuçlar k-NN sınıflandırıcısı ile karşılaştırılmış ve her iki yöntemin de en uygun sonuçları ürettiği belirlenmiştir. [20]'de, SPOT-5 uydu görüntülerinden moso bambu ormanının haritalanması için nesne tabanlı bir yaklaşım önerilmiştir. Çok ölçekli nesne bölütlemesi gerçekleştirilmiş ve her ağaç için sınıfları belirlemek için CART ve NN algoritmaları uygulanmıştır. Nesne tabanlı analiz ve sınıflandırma için görüntü bölütlemesi yöntemlerinin ayrıntılı bir açıklaması [42]'de verilmiştir. Benzer şekilde, [34]'deki çalışmada Pleiades-1A görüntü verisinden yeşil alanların çıkartılması için nesne tabanlı görüntü analizi (NTGA) kullanılmıştır. Bölütleri elde etmek için iki yöntem kullanılmıştır. Kullanılan yöntemler; çoklu çözünürlük bölütlemesi ve spektral fark bölütlemesidir. NDVI, Normalleştirilmiş Su İndeksi (NDWI) ve Düzenlenmiş Toprak Bitki Örtüsü İndeksi (MSAVI) gibi çeşitli özellikler elde edilmiştir. Son olarak, SVM, arazi örtüsünün ya "kentsel yeşil" ya da "kentsel olmayan yeşil alan" sınıflarına ayrıştırılması için kullanılmıştır.

[53]'te, multimodal özellik uzay analizi için parametrik olmayan bir yaklaşım önerilmiştir ve uygulamaları, 1975'te [54] tarafından önerilmiş olan Mean Shift (MS) adı verilen ve oldukça iyi bilinen örüntü tanıma algoritmasını kullanmışlardır. Yazarlar, MS işleminin durağan bir noktaya yakınlaştığını kanıtlamışlardır. Böylece yoğunluğun

modunu bulmayı ve uygulamalarını sağlamışlar ve bunu renkli görüntünün bölütlemesinde uygulamışlardır. [55], MS algoritmasının geliştirilmiş bir versiyonunu önermiş ve bu yöntemi kümelenme problemini çözmek için uygulamıştır.

Görüntü işleme analizi açısından bakıldığında, nesne tablı yaklaşım, mekansal bilginin dâhil edilmesi ile, tekil piksellerle mümkün olamayacak ek bilgilerin elde edilmesine olanak sağlar. Örneğin, çeşitli nesneler arasında, nesnelerin ayırt edilmesi için nesne boyutu, şekli ve dokusal özellikleri ek özellikler olarak kullanılarak sınıflandırma doğruluğu artırılabilir. Nesne tabanlı yaklaşımın piksel tabanlı yöntemle göre avantajları, yüksek çözünürlüklü görüntülerin analizi için bu yöntemi öne çıkarır. Bu nedenle, bu çalışma aynı zamanda yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçelerinin çıkarılması için nesne tabanlı bir yaklaşıma odaklanmıştır.

2.4 Uzaktan Algılama Verilerinin Sınıflandırmasında Makine Öğrenme Yaklaşımları

Makine öğrenme yaklaşımları, çeşitli algılayıcılardan elde edilen verilerden ağaç türlerinin sınıflandırılması için yeteneklerini kanıtlamışlardır. Son yıllarda çok çeşitli uzaktan algılama teknikleri kullanılmaya başlanmıştır. Veriler uydulardan, uçaklardan veya insansız hava araçlarından elde edilmektedir [35], [56]. Algılayıcı seçimi, çözülmesi düşünülen problemin türüne de bağlıdır. Bölgesel ve ulusal ölçekteki ormancılık veya tarım alanındaki uygulamalar için, hem uydulardan hem de uçaklarda bulunan algılayıcılardan elde edilen görüntüler kullanılmışlardır [35]. Makine öğrenme temelli yaklaşımlar genellikle verilerin ilgili sınıflara atanması için kullanılmaktadır.

Uzaktan algılama veri analizi için bir çok makine öğrenme (MÖ) yaklaşımı önerilmiştir. Bununla birlikte, en yaygın kullanılan MÖ yaklaşımları arasında SVM, YSA, RO, en çok benzerlik ve bulanık sınıflandırıcılar bulunmaktadır [3]. Örneğin, [57]'de yazarlar, kentsel ortamlardaki ağaç türlerini tespit edebilmek için farklı zamanlarda elde edilen ve bir hava aracından toplanan LIDAR nokta bulutu kullanmışlardır. İlk olarak, birbirine bağlı bileşenler (Connected Component-CC) benzer özelliklere sahip nesnelerin gruplarını bulmak için nokta bulutlarına uygulanmıştır. Bu işlem, tekil ağaç türlerinin birleşmesiyle sonuçlanmıştır. Bu nedenle, bir ağaç şekline dayalı olarak adaptive MS model geliştirilerek CC'leri bireysel ağaçlara ayırmak için uygulanmıştır. Daha sonra

ağaç parametreleri türetilmiş ve zaman içindeki değişiklikleri bulmak için farklı zamanlarda elde edilen veriler üzerinde karşılaştırılmıştır.

LIDAR nokta bulutundan özelliklerin sistematik bir şekilde çıkarılması için modüler bir yaklaşım, [58]'de önerilmiştir. Bu özellikler arasında nokta dağılımı, yoğunluğu ve ağaç dış yapısı bulunur. Daha sonra SVM, Picea Abies, Pinus Syvlestris ve Populus Tremula ağaç türlerinin sınıflandırılması için girdi verisi olarak kullanılmıştır. Benzer şekilde, [59]'da, önce baskın ağaç tepeleri LIDAR nokta bulutu verisinden elde edilmiş daha sonra ağaç tepelerini kendi sınıflarına ayırmak için açısız analiz yapılmıştır.

[26]'da düşük çözünürlüklü zaman serileri verileri ile yüksek çözünürlüklü çok bandlı verilerin özelliklerini birleştirerek ürün tipi belirleme doğruluğunu iyileştirmek için bir yöntem önerilmiştir. Oldukça ayırt edici özellikler çıkartılmış ve sınıflandırma için en çok benzerlik yöntemine aktarılmıştır. Lazer tarayıcıdan elde edilen ladin ve huş ağaçlarının sınıflandırılması için, Naive Bayes (NB) sınıflandırma yöntemi [60]'da kullanılmıştır. Giriş görüntüsü önce bölütlere ayrılmış daha sonra her bölütten özellikler elde edilmiştir. Bunlar dokusal, geometrik ve mekansal özelliklerdir.

Literatür taraması ayrıca, çeşitli ilgi çekici nesnelerin tanımlanması için farklı algılayıcılardan sağlanan verilerin birleştirildiği bazı yöntemlerin önerildiğini de göstermektedir. Örneğin, [61]'de kentsel ortamda binaların ve bitki örtüsü alanlarının sınıflandırılması için LIDAR nokta bulutu ve uçaklardan elde edilen RGB verileri bir araya getirmiştir. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI), RGB görüntüden kırmızı bandı ve LIDAR verilerinden döndürülen yoğunluk değeri kullanılarak elde edilmiştir. Bu teknik bitki örtüsü ile bitki örtüsü olmayan alanları ayırt etmeyi sağlamıştır. Savannalar' da LIDAR ve hiperspektral görüntü verilerinin birleştirilmesiyle oluşan büyük ölçekli veri setlerinden ağaçların ayırt edilebilmesi için [62]'de, bir yöntem önerilmiştir. Ayrıca, ağaç tepelerinin sınıflandırılması için bir SVM modeli kullanılmıştır.

[63]'te, hiperspektral ve LIDAR verilerini birleştirerek bitki türlerinin haritalandırılması için yeni bir yöntem önerilmiştir. Bu çalışmada, bitki boyu bilgisi LIDAR verileri ile elde edilirken, dokusal ve geometrik özellikler hiperspektral verilerden elde edilmiştir. Böylelikle farklı ürün türleri nesne tabanlı bölütleme kullanılarak sınıflandırılmıştır.

[19]'da, Landsat ve MODIS zaman serisi verilerinden ekin alanlarının haritalanması için nesne tabanlı bölütleme ve karar ağaçları kullanmışlardır. Özellik seçimi Sdom adım ayırma analizi - Stepwise Discriminant Analizi (SDA) ile gerçekleştirilmiştir. Bu iki konuda yardımcı olmuştur. İlk olarak hesaplama karmaşıklığını azaltmış sonrada genel bölütleme ve sınıflandırma doğruluklarını artırmıştır. Bölütleme için en uygun parametreleri bulmak için nicel ölçümler kullanılmış ve sonuçta karar ağaçları, tarım arazilerinin sınıflandırılması için kullanılmıştır. [64]'e benzer şekilde, yerel maksimum filtreleme kullanılarak ağaç türünü ve tepe büyüklüğünü LIDAR verilerinden , [65]'te, bulanık c-araçları sınıflandırıcısı kullanarak ekili ve nadasa bırakılmış alanları birbirinden ayırmak için kullanılan NDVI, MODIS zamansal verilerinden elde edilmiştir. [28]'de Bayes dönüşüm modeli, ağaç tepe konumunun, yüksekliklerinin ve şekil bilgisinin ALS verilerinden çıkarılması için kullanılmıştır.

Benzer şekilde, [66]'da Hindistan Uzaktan Algılama (IRS-1C) ve IKONOS görüntülerinden yüksek düzeyde ayırt edici özelliklerin çıkarılması için morfolojik dönüşümler kullanılmıştır. Jeodezik açma ve kapama, farklı bir morfolojik profil oluşturmak için kullanılmıştır. Dahası, özellik çıkarma teknikleri için ayırt etme analizi ve karar sınır analizi kullanılmıştır. Son olarak, sınıflandırma için yapay sinir ağları kullanılmıştır. [67]'de, hava araçlarından sağlanan lazer taraması verilerinden ağaç tespiti için Bayes sınıflandırma yöntemi kullanılmıştır. Ağacın yatay koordinatları, tepe çapı, tepe yüksekliği, tepe çapının alt sınırı ve ağaç tepesinin şekli gibi altı farklı parametre çıkartılmıştır.

[68]'de, ağaç türlerinin sınıflandırılması için nesne tabanlı bir teknikle çoklu kaynaklardan elde edilen verilerin birleştirilmesi araştırılmıştır. Sonuçlar önce multispektral ve hiperspektral veriler ile LIDAR verilerinin birleştirilmesiyle analiz edilmiştir. Yazarlar, sınıflandırma sonuçlarını söz konusu birleştirme olmaksızın da araştırmışlardır. Her iki kaynaktan elde edilen verileri birleştirerek sınıflandırma doğruluğunun önemli ölçüde arttığını bulmuşlardır. Ayrıca, [69]'da, toprak sınıflarının ve baskın ağaç türlerinin hava araçlarından elde edilen görüntü verilerinin sınıflandırılması için nesne tabanlı bir yaklaşım kullanılmıştır. İlk önce nesne tabanlı bir bölütleme gerçekleştirilmiş ve daha sonra her bir nesne için spektral, mekansal ve

LIDAR tabanlı özellikler çıkarılmıştır. Bu özellikler, nesnelerin ilgili sınıflara ayrıştırılması için karar ağacı sınıflandırıcısı destekleyici veri olmuştur.

[70]'te yazarlar, karışık nesnelerin ağaç türleri üzerindeki eğitim ve sınıflandırma doğruluklarına olan etkisinin karşılaştırmalı bir analizini yapmışlardır. Kullanılan yöntem, sınıflandırıcısını eğitmek için hem saf nesneleri (yalnızca saf sınıfları temsil eder) hem de karışık nesneler (birden fazla sınıf arasında çakışmayı temsil eder) kullanılmıştır. Son sınıflandırma için gizli katmanı bulunmayan YSA ve en çok benzerlik yöntemiyle genelleştirilmiş doğrusal model kullanılmıştır. Sınıflandırma doğruluklarının, sınıflandırıcısı karışık nesnelerle eğitmekten fazla etkilenmediği bulunmuştur.

[39]'da, hiperspektral görüntülerin sınıflandırılması için spektral ve uzaysal özelliklerden faydalanmak için çoklu Kernel öğrenme yöntemi önerilmektedir. Genişletilmiş morfolojik profiller oluşturmak için çoklu yapı elemanlarının ve görüntülerin sınıflandırılması için SVM'nin kullanılması önerilmiştir. Genişletilmiş profiller ağaç türlerinin dokusal ve mekansal bilgilerini ellerinde tutmaktadır. Ölçeği ve yapısını bağımsız hale getirmek için çeşitli boyutlarda yapı elemanları kullanılmış ve çeşitli ölçekler tanıtılmıştır.

[71]'de, NDVI profilleri ve Random Forest sınıflandırma yöntemi vejetasyon değişiminin zamansal analizi için kullanılmıştır. Ayrıca, hem bölgesel hem de yerel düzeyde vejetasyon değişikliklerini etkileyen temel faktör, otomatik analiz ve sınıflandırma yoluyla belirlenmiştir. [72]'de Mean Shift algoritması, hiperspektral görüntülerden nesnelerin tanımlanması için kullanılmıştır. Meran Shift bölütlemesi, nesnelerin nesne yönelimli bir temsilini elde etmek için kullanılmış ve daha sonra sınıflandırma sonuçlarının elde edilmesi için SVM sınıflandırıcısı uygulanmıştır. Geliştirilmiş kontrollü sınıflandırıcılar kullanılarak hiperspektral verilerin sınıflandırılmasına yönelik yeni yaklaşımlar [12]'de detaylı olarak gözden geçirilmiştir.

2.5 Çoklu Sınıflandırıcı Yöntemleri

Birçok araştırmacı, farklı sınıflandırıcıların birleştirilmesinin, uzaktan algılama verileri için daha yüksek sınıflandırma doğrulukları ile sonuçlandığını ileri sürmüştür. Örneğin, [73]'te yazarlar, yüksek çözünürlüklü hiperspektral algılayıcılardan Boreal ormanların

sınıflandırılması için üç farklı sınıflandırıcının sonuçlarını karşılaştırmışlardır. Bunlar arasında SVM, RF ve En Çok Benzerlik sınıflandırma yöntemleridir. [74]'te görüntü analizi için yüksek çözünürlüklü hiperspektral görüntüler LIDAR verileriyle karşılaştırılmıştır. Bu çalışmada çok bandlı veriler, ağaç türlerini sınıflandırmak için LIDAR verileriyle de birleştirilmiştir. Son olarak, sınıflandırma için SVM ve Random Forest yöntemleri kullanılmıştır. Benzer şekilde, k-NN, multinom dağılımı ve SVM sınıflandırıcısı, [75]'te LIDAR verilerinden elde edilen tek ağaçların sınıflandırması için karşılaştırılmıştır.

Nesne tabanlı bir görüntü bölütleme tekniği kullanılarak yüksek çözünürlüklü görüntü sınıflandırması için dört makine öğrenme temelli sınıflandırıcının karşılaştırmalı analizi [76]'da yapılmıştır. Bunlar arasında; SVM, Bayes, Sınıflandırma ve Regresyon Ağacı ve K-NN vardır. Yazarlar, her bir sınıflandırıcının sınıflandırma doğruluğunun, parametrelerin seçiminden ve eğitim veri boyutundan etkilendiğini belirtmişlerdir. Veri setlerindeki tüm denemeler için SVM sınıflandırıcısı, küçük bir eğitim örneği ile bile ümit verici sonuçlar vermiştir.

Benzer bir yaklaşım, WORLDVIEW-2 verilerinden ağaç türlerinin sınıflandırılması için [28]'de de izlenmiştir. Nesneye dayalı bir yaklaşım benimsenmiş ve ardından En Çok Benzerlik (Maksimum Likelihood), Mahalanobis Uzaklığı, Sinir Ağları ve Spectral Angle Mapper (SAM) gibi dört sınıflandırıcı karşılaştırılmıştır. Sınıflandırma doğrulukları veri seti için her bir sınıflandırma yöntemi için raporlanmıştır.

[20]'de moso bambu ormanının SPOT-5 uydu görüntülerinden haritalanması için nesne tabanlı bir yaklaşım geliştirilmiştir. Nesneleri oluşturmak için gereksinim duyulan homojen bölgeleri bulmak için ilk önce çok ölçekli bir nesne bölütlemesi gerçekleştirilmiş ve daha sonra CART ve NN algoritmaları sınıflandırma için uygulanmıştır.

[77]'de, hiperspektral verinin sınıflandırma analizleri için SVM, regularized radial basis fonksiyonu (R-RBF), kernel fisher discriminant analizi (KFDA) ve regularized Adaboost gibi dört yöntem karşılaştırılmıştır. Yazarlar, SVM'nin standart durumda diğer yöntemlerden daha iyi performans gösterdiği sonucuna varmışlardır. Ayrıca, SVM'nin

hesaplama karmaşıklığı ve işlem süresi, hiperspektral verilerin sınıflandırılması için diğer üçüyle karşılaştırıldığında daha kısadır.

[10]'da destek vektör makineleri (SVM) ve Random Forest yönteminin bir kombinasyonu kullanılarak beş baskın kentsel ağaç türünün sınıflandırılması için bir nesne yönelimli teknik önerilmiştir. WORLDVIEW-2 ve WORLDVIEW -3 ten elde edilmiş zamansal veriler, ağaç türü bilgisinin türetilmesi için kullanılmıştır. Dahası, yazarlar iki-zamanlı görüntülerde yakalanan fenoloji varyasyonlarının çeşitli ağaç türlerinin tanımlanması için yararlı bir ipucu olduğunu da göstermiştir.

Benzer şekilde, [75]'te yersel lazer tarayıcı verilerinden otomatik olarak ağaç türlerini doğru olarak tanımak için yeni bir yöntem sunulmuştur. Ağaç türlerini sınıflandırmak için ağaçların ağaç yapısına (yapı, geometri ve hacim) dayalı nicel özellikleri kullanılır. Sınıflandırma için yazarlar, k-en yakın komşuluk, multinomiyal regresyon ve SVM ile test etmişlerdir. Denetimli sınıflandırıcıları kullanarak uzaktan algılama verilerinin sınıflamasındaki son gelişmeler kapsamlı olarak [78] 'de yer almaktadır.

2.6 Detay Çıkarma

Yüksek çözünürlüklü algılayıcıların geliştirilmesi ile, görüntülerin daha küçük detaylarla elde edilmesi mümkün olmuştur. Böylelikle ağaç türlerinin yüksek doğrulukla ayırtedilebilme olanağı da ortaya çıkmıştır. Bunun yanında, bu durum, çeşitli ağaç türleri arasındaki spektral yansımadaki benzerlikler nedeniyle görüntü analizi için karmaşıklıkların ortaya çıkmasına da sebep olabilmektedir. Bu sorunu belli oranda ortadan kaldırabilmek için, yüksek ayırım gücüne sahip özellikler çıkarılmalı ve sınıflandırma sonuçlarını iyileştirmek için bir özellik seçimi yaklaşımı izlenmelidir [79].

Geleneksel olarak, spektral özellikler, ağaç türlerinin sınıflandırması için yaygın olarak kullanılmaktadır. Ancak, spektral bilgiye dayanan özellikler, çeşitli türlerin spektral imzasındaki benzerlikler nedeniyle tatmin edici sonuçlar vermeyebilmektedir. Oysa, dokusal, spektral ve mekansal özelliklerin tamamlayıcı bilgi sağladığı bilinmektedir [3]. Bu nedenle, daha doğru sınıflandırma sonuçları elde etmek için bu özellikleri birleştirmek zorunludur. Dahası, çeşitli çalışmalar farklı alanlardaki özelliklerden yararlanmıştır. Örneğin, [50]'de, doku özellikleri, Gri Seviyede birlikte ortaya çıkma

Grey-Level Co-occurrence (GLCM) ve Gri Seviye Fark Vektörü (Gray-Level Difference Vector) (GLDV) özellik vektörlerini içeren Haralick's algoritması kullanılarak hesaplanmıştır. Pohutukawa ağaçlarının sınıflandırılması için tek tek ağaçların tepelerinden ve aralarından geri yansıyan lazer dönüşleri kullanılarak göreceli yükseklik yüzdeleri hesaplanmıştır. [75]'te, ağaç türlerinin sınıflandırması için geometri ve topolojiye dayanan özellikler kullanılmıştır. Benzer şekilde, [28]'de, gölge indeksi, NDVI ve doku bilgileri gibi özellik çıkarma teknikleri ağaç türlerinin sınıflandırılması için kullanılmıştır.

[20]'de, GLCM ve mekansal ilişkilerin yerel göstergeleri (LISA), SPOT-5 uydu görüntülerinden moso bambu ormanlarının sınıflandırılması için mekansal özelliklerin kaynağı olarak kullanılmıştır. Gölge alanlarını tespit etmek için daha fazla bağlamsal özellik göz önüne alınmıştır. [34]'te, arazi örtüsünün kentsel yeşil alan veya kentsel olmayan yeşil alan sınıflarına ayırmak için NDVI, Normalleştirilmiş Fark Su İndeksi (NDWI) ve Modifiye Toprak Düzeltilmiş Bitki Örtüsü İndeksi (MSAVI) kullanılmıştır. Benzer şekilde, [69]'da, spektral, mekansal ve LIDAR tabanlı özellikler, sınıflandırma için her nesneden elde edilmiştir. [80]'de, ayrıca kentsel alanlardan ağaç çıkarımı için spektral ve mekânsal özellikler kullanılmıştır. Koşullu varyans algoritması dokusal özellikler çıkarmak için kullanılmıştır.

[39]'da, Morfolojik profiller, çoklu yapı elemanları kullanılarak ağaç türlerinin doku ve mekansal bilgilerini elde etmek için kullanılmıştır. Hiperspektral görüntülerden özellik çıkarılması için histogram bazlı öznitelik profilleri (Attribute Profile-AP) ise [81]'de kullanılmıştır. Benzer şekilde, [82]'de, ağacın tepe genişliği (Tree Crown Coverage-TCC), ağaç kümelenme indeksi (Trees Cluster Index TCI) ve gölge ve ağaçların oranı (Ratio of Shadow and Trees-RST), QuickBird görüntü verilerinden çeşitliliği, boyutu ve mekansal dağılım bilgilerini gösteren özellik vektörleri olarak kullanılmıştır.

Ağaç türlerinin sınıflandırılması için yapısal özelliklerin diğer özelliklerle birleştirilmesi üzerine birçok araştırma yapılmıştır. Örneğin, [33]'de, istatistik, geometrik, şekil ve dokuları içeren girdi verilerinden çeşitli özellikler elde edilmiştir. [13]'de hiyerarşik renkli ikili yapılar kullanılarak yüksek çözünürlüklü uydu görüntülerinin sınıflandırması için renk-doku-yapı tanımlayıcısı (Color-Texture-Structure Descriptor-CTS) olarak

bilinen yeni bir tanımlayıcı kullanılmıştır. Her iki doku ve renk bilgisi, ele alınan nesneleri tanımlamak için birleştirilmiştir. Önerilen yöntemde ilk olarak görüntü pikselleri süper piksellere ayrılmış ve son sınıflandırma için ayırmacı özellikler çıkarılmıştır.

Daha fazla sayıda özelliğin çıkarılması, boyutsallık problemi olarak adlandırılan bir soruna neden olabilir [83]. Ayrıca, hesaplama karmaşıklığı da artmaktadır. Bu sorun, özellik seçimi yaklaşımı ile çözülebilir. Özellik seçiminin mantığı, belirli bir veri kümesinden en çok göze çarpan özellikleri seçmektir [74]. Bu, en iyi sonuçları üretebilecek özellikleri tanımlamak için kapsamlı bir araştırma stratejisi gerektirir.

[47]'de, veri sınıflandırması için türetilmiş spektral-mekansal bilgi ile kenar filtre kullanılmıştır. Sınıflandırılmış görüntü olasılık haritası olarak kabul edilmiş ve daha yumuşak nesne sınırlarını elde etmek için kenar koruyucu filtre uygulanmıştır. Yükseklik, spektral ve geometrik tutarlılık bilgisi gibi özellikler, piksel tabanlı bir yaklaşım kullanılarak türetilmiş ve sonra SVM sınıflandırma yöntemi zamansal analiz için kullanılmıştır. Benzer şekilde şekil özellikleri, birinci ve ikinci dereceden istatistikler [84]'de ağaç tepe çaplarının betimlenmesi için QuickBird görüntü verisinden türetilmiştir.

[85]'de, kompakt hava spektrografik görüntüleyiciden (Employed Stepwise Discriminant Analysis-CASI) ağaç tepeleri/kümelerinin tanımlanması için adım adım diskriminant analiz yöntemi kullanılmıştır. Her bir görüntü için piksel gri değerleri, ortalama kanal değeri ve bant oranları gibi çeşitli özellikler türetilmiştir. Son olarak, ağaç türlerinin sınıflandırması gerçekleştirilmiş ve her sınıf için tematik haritalar oluşturulmuştur.

[86]'da, değişen ölçeklerde doku özelliklerinde varyasyonları ölçmek için bir yöntem önerilmiştir. Farklı ölçeklerde ortalama, entropi ve daha az korelasyonun olduğu, kontrast ve farklılıkların çeşitli ölçeklerde tutarlı olduğu ve iyi sınıflandırma sonuçları ürettiği gözlenmiştir. Benzer şekilde, karar ağacı sınıflandırma yöntemi olan uzunlamasına profiller, uçaklardan elde edilmiş görüntülerden üretilen tek tek ağaçların sınıflandırılması için kullanılmıştır [87].

[33]'te, girdi görüntüsünden her bir nesne için türetilen istatistiksel, geometrik, şekil ve doku özellikleri gibi çeşitli özellikler önerilmiş ve daha sonra temel bileşenler analizi(Principle Component Analyse-PCA), özellik seçimi için kullanılmıştır. Bu teknik, işlem süresini artırmış ve aynı zamanda kural tabanlı bir yöntem kullanılarak sınıflandırma için yüksek oranda ayırt edici özellik seçildiğinden, sınıflandırmanın da geliştirildiği belirtilmiştir. Hiperspektral görüntülerin sınıflandırılması için histogram bazlı öznitelik profilleri (APs) önerilmiştir [81]. İlk aşamada öznitelik filtreleri kullanılarak profiller oluşturulmuştur. İkinci aşamada, her bir yerel AP için histogramlar hesaplanmıştır. Son olarak AP ler SVM kullanılarak sınıflandırılmıştır. Uzaktan algılama verilerinin sınıflandırması için AP ler hakkında detaylı bilgi [88] 'de sunulmuştur.

[89] bölütleme için nesne tabanlı bir yaklaşım önermiş ve daha sonra spektral ve mekansal bilgileri içeren çeşitli özellikler nesnelerden çıkarılmış ve sınıflandırma için en yakın komşuluk sınıflandırıcı kullanılmıştır. Ayrıca, [4]'te, spektral olarak homojen yerel bölgelerin şeklini tanımlayan yüksek çözünürlüklü görüntülerin sınıflandırılması için Mean-Shift vektör tabanlı şekil özelliklerini (MSVSF) önermiştir. Bu, benzer spektral yansıma değerleri olan farklı iki boyutlu objeleri ayırmak için kullanılmıştır.

Ayrıca [90]'da orijinal görüntü verilerinin yanı sıra düşük geçişli filtreleme, IHS transformasyonu ve Haralick'ten detay özellikleri elde etmek için doku özellikleri kullanılarak ek bantlar üretilmiştir. Daha sonra, nesne tabanlı bir bölütleme, yetiştirme orman alanının sınıflandırılması için denetimli bir sınıflandırma yöntemi ile yapılmıştır.

Bu, hem doku hem de mekansal/spektral özelliklerin ilgi sınıfları hakkında yararlı bilgiler elde etmede önemli rol oynadığını göstermiştir. Bu özellikler, bir sonraki alt bölümde tarif edilen arama ve seçim kriterlerini tanımlanarak için bir seçim prosedürüne tabi tutulur.

2.7 Özellik Seçimi

Genel olarak, herhangi bir sınıflandırıcının doğruluğu, bazı iç ve dış faktörlere bağlıdır. Sınıflandırma parametreleri gibi iç faktörler genellikle eğitim veri kümesini kullanarak yapılırken, sınıflandırma için kullanılan özelliklerin kalitesi gibi dış etkenler de

sınıflandırıcının doğruluğunu etkiler. Bu nedenle, yüksek ayırım gücüne sahip detaylar arzu edilir. Bu nedenle, özellik sınıfları arasında ayırım yapabilmek için değerli bir bilgi sunup sunmadıklarını değerlendirmek önemlidir.

Özellik seçimi, son derece ayrılabilir özelliklerin bir alt kümesini bulmak olarak değerlendirilebilir, ancak boyutsallığı azaltarak gereksiz olanları da ortadan kaldırabilir. Her ne kadar boyutsal indirgeme arzu edilse de, her bir detayın ayırt etme gücünü azaltmamalıdır.

Özellik seçimi yaklaşımı, büyük hacimli verilerle ilgili iki önemli özel avantaj sağlar. Birincisi, sınıflandırma doğruluğu yüksek ayırt edici özellikler seçerek geliştirilebilir. İkincisi, hesaplama süresi azalır, böylece daha az sayıda detay işleme tabi tutulur [33]. Bu, genellikle büyük boyutlu olduğu için uzaktan algılama verileriyle çalışırken özellikle önem kazanmaktadır.

Özellik seçim teknikleri, bir arama stratejisi ve ayrılabilirlik ölçütünden oluşur [74]. Literatürde çeşitli arama algoritmaları sunulmuştur. Örneğin, [66]'da, morfolojik profilin (Derivative Morphological Profile-DMP) türevlerinin sınıflandırılmasına dayanan bir özellik seçim yöntemi kullanılmıştır. [91]'de, belirli ikili uzayda kısıtlı yerel uçlara dayalı bir arama algoritması önerilmiştir. Önerilen yöntemin etkileri, klasik sıralı ileriye doğru seçim ve sıralı ileriye doğru kaydırma seçimi alt-teknikleri ile karşılaştırılarak gösterilmiştir. [92]'de, alt-optimal özellik setinin hızlı seçimi için sıralı ileri kayan seçim (Sequential Forward Floating Selection -SFFS) algoritması olarak bilinen yeni bir arama algoritması önerilmiştir. Temel olarak geri adımın eklenmesiyle sıralı ileriye doğru seçim algoritmasının bir uzantısıdır [74]. Benzer şekilde, yüksek çözünürlüklü görüntü verileri özellik seçimi için [33]'de PCA kullanılmıştır. [93]'te, iki detay arasındaki benzerliği ölçmek için Jaffrey-Matusita (JM) mesafesi kullanılmıştır.

[35]'de basamaklı ileriye doğru seçme temeline dayanan bir özellik seçim yaklaşımı kullanılmıştır. [33]'de özellik seçimi için PCA kullanılmıştır. Bu teknik, işlem süresini artırmış ve ayrıca sınıflandırmanın iyileştiği belirtilmiştir.

Bazı detayların özellik setinden düşürülmesi bazı yararlı bilgilerin kaybolmasına neden olabilir. Bununla birlikte, verilerin boyutsallığı ve sınıflandırma yönteminin sınıflandırma doğruluğu arasında bir uyumsuzluk vardır. Bu nedenle, birçok araştırmacı,

özellikle boyut algılamalarının önüne geçmek ve genel sınıflandırma doğruluğunu geliştirmek için özellikle uzaktan algılama verileri için özellik seçimi stratejisinin kullanılmasını savunmaktadırlar.

2.8 Özet

İncelenen çalışmalardan, uzaktan algılama verilerinin, yararlı bilgileri büyük ölçekte elde etmenin alternatif bir yolu olarak kullanılabileceği kısaca söylenebilir. Bu bilgileri elde etmek için, spektral, mekansal ve doku alanlarını kapsayan özellikler yaygın olarak kullanılmaktadır. Her nesnenin kendine has özellikleri olduğundan, değişen dalga boylarındaki elektromanyetik radyasyona maruz kaldığında farklı yansımalar üretir. Bu özellikler farklı nesneler arasında ayırım yapmak için kullanılabilir. Ayrıca, verilerin büyük boyutlarıyla ilgilenmek için, nesne tabanlı yaklaşımlar yaygın olarak kullanılmaktadır. Bu yaklaşımlar büyük boyutlu veriler için daha uygundur ve geleneksel piksel tabanlı yaklaşımların ortaya çıkarttığı boşlukları kapatmaktadır.

Literatür taraması ayrıca, makine öğrenme yöntemlerinin, test örnekleri ile karşılaştırıldığında eğitim verileri çok az bile olsa, uzaktan algılama verilerini sınıflandırmak için kullanılabilecek en etkili araç olduğunu göstermiştir. Denetimli öğrenme temelli yaklaşımlar arasında, SVM'ler, YSA'lar, RF, karar ağaçları (Decision Tree-DT), artırılmış DT'ler ve k-en yakın komşuluk (k-NN), uzaktan algılama veri sınıflandırmasında yaygın olarak kullanılmaktadır. Ek olarak, farklı sınıflandırma yöntemlerinin birleştirilmesiyle sınıflandırıcıların ağaç türlerinin sınıflandırılmasında önemli gelişmeler elde ettikleri görülmüştür. Belirli bir sınıflandırıcı seçmek için belirli bir kural olmamasına rağmen, yüksek sınıflandırma doğruluğu sağlayan sınıflandırıcılar tavsiye edilmektedir.

ÖNERİLEN YÖNTEM

3.1 Giriş

Bu bölümde, yüksek çözünürlüklü dijital ortofoto haritalardan çay bahçelerinin çıkarılması için önerilen yöntemi kapsamlı bir şekilde açıklanmıştır. Çay bahçelerinin otomatik olarak bölütlenmesine yönelik nesne tabanlı teknikle önerilen çoklu sınıflandırıcı yöntem entegre edilmiştir. Bu bölümde çalışma alanı ve kullanılan verilerin özellikleri detaylı olarak açıklandıktan sonra nesne tabanlı Mean-Shift bölütleme yöntemi ile Destek Vektör Makinaları, Yapay Sinir Ağları ve Rastgele Ormanlar yöntemlerinin matematiksel temelleri açıklanmıştır.

3.2 Çalışma Alanı

3.2.1 Başlıca Özellikler

Türkiye, Hindistan, Çin, Kenya ve Sri Lanka'nın ardından dünyanın en büyük 5. çay üreticisidir [94]. Türkiye çay üreticisi olmanın yanı sıra ülkede kişi başına düşen çay tüketimi de yüksek orandadır. Öyle ki üretilen çayın sadece %4' ü ihraç edilebilmekte, geri kalanı iç piyasada tüketilmektedir. Bu yüzden çay ihracatı düşük orandadır. Türkiye' de Türk çayı olarak da bilinen yüksek kaliteli siyah çay Rize ili ve civarında üretilmektedir. Bu nedenle Rize ili sunulan tezde çalışma alanı olarak seçilmiştir. Türkiye' nin toplam çay üretiminin % 60-65'i Rize ili ve çevresinde üretilmektedir. Bunu Trabzon, Artvin, Ordu ve Giresun illeri izlemektedir [95].

3.2.2 Coğrafya ve İklim

Rize, Türkiye'nin Doğu Karadeniz bölgesinde yer almaktadır. Arazi, çay ağacı türlerini yetiştirmek için daha uygun olan vadiler ve dik dağ sıralarına sahiptir. Bölge, tarım ve ormancılık için uygun bir doğal yapıya sahiptir. Bölgede ılıman iklim hüküm sürmektedir. Yılın her diliminde yağmur alan bölgede kışın nispeten daha soğuk bir iklim söz konusudur. Ayrıca, toprak çok verimli ve tarım için uygundur. Bundan dolayı üretilen çay kalitesi yüksektir. Tez çalışmasında kullanılan ortofoto haritalar yoğun çay bahçeleri, diğer bitki türleri ve orman alanları ile kaplıdır. Alan çoğunlukla çay tarlaları ve diğer bitki örtüsü türleri, insan yapısı objeleri içermektedir. Şekil. 3.1' de çalışma alanı verilmiştir. Şekil. 3.1-a) Türkiye haritası üzerinde Rize ilinin konumu, b) Rize ili ve ilçelerini, c) görünür bölgeye ait örnek görüntüyü, d) Google Earth üzerinde eğitim verilerinin seçildiği alanları göstermektedir.



(a)



(b)



(c)



(d)

Şekil 3.1 a) Çalışma alanının Türkiye haritasında gösterimi. b) Rize ili ve ilçeleri. c) Çalışma alanına ait dijital ortofoto örneği d) Google Earth üzerinde eğitim verilerinin seçildiği alanlar


3.3 Veri Seti

EMI Grup Bilgi Teknolojileri A.Ş. tarafından üretilen ve tez çalışması için temin edilen 1:5000 ölçekli (30 cm yer örneklem aralıklı) ortofoto haritalarının üretildiği yüksek çözünürlüklü multispektral görüntüler UltraCam-X dijital kamera ile elde edilmiştir. Rize ili ve çevresinde 27- 28 Mart 2013 tarihinde gerçekleştirilen uçuşlar yaklaşık 4200 m den yapılmış ileri ve yan bindirmeler sırasıyla % 70 ve % 30 olarak belirlenmiştir (Çizelge 3.1). Üretilen dijital ortofoto haritalar dört bantlıdır (Kırmızı, Yeşil, Mavi ve Yakın kızılötesi).

Sunulan tez çalışmasında yirmi beş adet dijital ortofoto görüntü kullanılmıştır. Doğruluk analizi için EMI Grup Bilgi Teknolojileri A.Ş. tarafından fotogrametrik olarak sayısallaştırılan çay bahçelerinin sınırları referans veri olarak kullanılmıştır. Vektör formatta üretilen referans verileri ikili kodlanmış (binary) görüntüye dönüştürülerek tez kapsamında üretilen sonuçlar ile karşılaştırılmıştır. Buna ilişkin örnek Şekil 3.2'de sunulmuştur. Şekilde beyaz pikseller çay bahçelerini, siyah pikseller diğer objeleri göstermektedir. Sunulan tez çalışmasında 15 eğitim verileri 15 görüntü kullanılarak seçilmiş, önerilen yöntem tüm görüntülere uygulanmıştır.

Çizelge 3.1 Kamera ve uçuş bilgileri

Parametre Adı	Detaylar
Kamera Modeli	Ultracam-X
Yer Örnekleme Aralığı	30 cm
Uçuş tarihi	27,28-03-2013
Enine bindirme	30%
Boyuna bindirme	70%
Uçuş yüksekliği	4200 m



Şekil 3.2 Örnek ortofoto (a) RGB kompozit, (b) Referans ikili kodlanmış görüntü

[96]'ya göre, Ultracam-X dijital kameranin bazı teknik özellikleri Çizelge 3.2'de gösterilmiştir. Ultracam-X, pankromatik, kırmızı, yeşil, mavi ve yakın kızılötesi bantlarda algılama yapabilen metrik, CCD algılayıcıya sahip bir kameradır. Kamera 8 bitlik radyometrik çözünürlüğe sahiptir.

Çizelge 3.2 Ultracam-X metric kamerasının bazı teknik özellikleri


Parametre Adı	Detaylar
Görüntü formatı	JPEG; TIFF
Radyometrik çözünürlük	8 bit
Bantlar	kırmızı, yeşil, mavi ve yakın kızılötesi
Pankromatik görüntü boyutu	14,430 x 9420 pixels
Pankromatik piksel boyutu	7.2 μ m
Görüntü hacmi	418 Mega Bytes
Mercek sistemi	Linor Vexcel Apo-Sironar digital HR

3.4 Önerilen Yöntem

Dijital ortofoto görüntülerinden otomatik olarak çay bahçelerinin bölütlenmesine yönelik önerilen yöntem beş ana aşamadan oluşmaktadır. Bunlar: i) Ön işleme, ii) görüntü bölütleme, iii) görüntü filtreleme, iv) özellik çıkarma ve v) sınıflandırma. Önerilen yönteme ilişkin akış diyagramı Şekil 3.3'te sunulmuştur.


3.4.1 Ön-işleme

Gürültü görüntü işleme uygulamalarında öncelikle üstesinden gelinmesi gereken bir sorundur. Birçok nedeni olmakla birlikte genel olarak algılayıcıdan ya da yansıma farklılıklarından kaynaklanır. Dolayısı ise öncelikle görüntülerdeki gürültünün elimine edilmesi gerekir. Sunulan tez çalışmasında kullanılan ortofoto görüntüler üretilmiş olarak temin edilmelerine rağmen gürültünün etkisini daha da azaltmak için, Gauss yumuşatma filtresi uygulanmıştır. Gauss filtresi görüntüdeki yüksek frekanslı bileşenleri filtreler. Söz konusu filtre yumuşatma filtresi olarak da anılır. Filtre parametrelerinden sigma, bulanıklık miktarını kontrol eder. Daha yüksek sigma değerleri yoğun bulanıklaşmaya neden olurken, daha düşük değerler nispeten daha az bulanıklaştırma



Şekil 3.3 Önerilen yöntemle ait akış diyagramı

etkisi oluřturur. Sunulan tez alıřmasında farklı sigma deęerleri kullanılarak Gauss filtresi uygulanmıřtır. řekil 3.4' te filtre sonuları ve bunların etkileri gsterilmiřtir. Sunulan tez alıřmasında sigma=1 seilerek elde edilen sonular kullanılmıřtır.



řekil 3.4 RGB grntye farklı sigma deęerleri seilerek Gauss yumuřatma filtreis uygulanması a) Orijinal grnt b) sigma =1 c) sigma = 3 d) sigma =5

3.4.2 Grnt Bltleme/Mean-Shift Yntemi

Grnt bltleme ile grnt homojen obje gruplarına ayrılır. Nesne tabanlı grnt analizi iin bltleme temel adımdır. Birincil ama, grnt piksellerinin spektral benzerliklerine dayanarak homojen bltlere ayırmaktır. Birok alıřma, nesne tabanlı yntemlerin yksek znrlkl grnt iřleme ve analizi iin geleneksel piksel tabanlı yntemlere kıyasla daha bařarılı sonular rettięini gstermiřtir [97]. Bltleme

işleminin kalitesi yüksek doğrulukta sınıflandırma sonucu elde edilmesinde hayati öneme sahiptir.

Görüntü bölütleme teknikleri genel olarak dört ana kategoriye ayrılabilir. Bunlar: eşik değer tabanlı, kenar tabanlı, bölge tabanlı ve karma yaklaşımlardır [97]. Eşik değer tabanlı yöntemler, görüntünün bölütlenmesi için en uygun eşik değerinin seçimine dayanır. Yüksek çözünürlüklü görüntülerde yöntem ile doğru sonuçlar elde edilmesi neredeyse olanaksızdır. Kenar tabanlı yöntemler, gri değer geçişlerinin yoğun olduğu bölgelerin ayırt edilmesi temeline dayanır. Benzer şekilde, bölgeye tabanlı yaklaşımlar da bir pikselin yerel komşuluklarını göz önünde bulundurarak benzer yoğunluk değerine sahip pikseller gruplanarak bölütler oluşturulur. Son olarak, hibrid yaklaşımlar farklı kategorilere giren algoritmaların bir birleşimini kullanır.

Bölge tabanlı yaklaşımlar gürültüye karşı çok güçlüdür; Bu nedenle, uzaktan algılama görüntülerinin bölütlemesinde yaygın olarak kullanılırlar. Sunulan çalışmada, parametrik olmayan Man-Shift algoritması seçilmiştir. Aşağıdaki bölümde Mean-Shift yönteminin matematiksel modeli sunulmuştur.

Mean-Shift yöntemi parametrik yoğunluk kestirim yöntemi olup, mod arama, kümeleme, görüntü bölütleme, görsel nesne izleme , vb. gibi çeşitli alanlarda uygulanmaktadır. İlk kez [54] tarafından tanıtılmıştır. [53], Mean-Shift yöntemini geliştirerek mod kullanılarak yoğunluk kestiriminin daha doğru bir şekilde yapılabildiğini kanıtlamıştır. Yöntem; özellik uzayının olasılık yoğunluk fonksiyonu olduğu ve yoğun alanların yerel maksimumu sağladığı (mod) fikrine dayandırılarak geliştirilmiştir [53]. Verilen $n \in R^d$, $\{x_i\}$, $i = 1,2,3 \dots n$ için çekirdek yoğunluk kestirim fonksiyonu aşağıdaki şekilde tanımlanır:

$$f(x) = \frac{c}{nd^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (3.1)$$

Burada $K(x)$ çekirdek fonksiyonu olup, $\{x_i\}$ ile x ortalama arasındaki korelasyonu ölçer. h bant genişliği parametresi ve c de normalleştirme sabitidir.


Görüntü, p adet pikselden oluşan 2 boyutlu bir matristir. x_s piksel boyutu ve x_r pikselin gri değerini ifade etmek üzere, [53]' e göre çok değişkenli çekirdek aşağıdaki şekilde modellenebilir:

$$f(x) = \frac{c}{nh_s^{2h_r^p} d^d} \sum_{i=1}^n K \left(\left\| \frac{x_s - x_{si}}{h_s} \right\|^2 + \left\| \frac{x_r - x_{ri}}{h_r} \right\|^2 \right) \quad (3.2)$$

Burada h_s ve h_r spektral ve mekânsal alandaki bant genişliğini, p spektral bant sayısını ifade eder.

Mean-Shift yöntemi mod belirlenmesi için güçlü bir algoritmadır ve yalnızca bant genişliği parametresinin belirlenmesi gereklidir. Parametrenin uygun olmayan seçimi, kümelerin birleştirilmesine neden olabilir veya bazen ek mod lar oluşturur. Sunulan çalışmada, Mean-Shift yöntemi uygulanarak ve çıktıları görsel olarak yorumlayarak parametre değerleri deneysel olarak belirlenmiştir.

Şekil 3.5, Mean-Shift yönteminin çalışma ilkesinin temsilini göstermektedir. Verilen veri noktalarının dağılımı ve pencerenin başlangıç pozisyonu (a) 'da gösterilmiştir. Açık mavi daire, dairesel pencerenin başlangıç merkezidir ve kırmızı daire, ortalama kayma iterasyonundan sonra yeni hesaplanan merkezi gösterir. Mevcut pencere için, algoritma, verilen yarıçaptaki veri noktalarının ortalamasının hesaplanmasıyla başlar ve ortalama kayma vektörü hesaplanır. Ortalama kayma vektörü kayma büyüklüğünü ve yönünü verir. Ardından, pencerenin merkezini yeni hesaplanan ortalama (b) taşır. İşlem sabit bir noktaya ulaşana kadar tekrarlanır. Birkaç iterasyondan sonra pencerenin son konumu, (c) 'de gösterilmektedir, burada, veri noktasının yoğunluğunun, pencerenin diğer konumuna kıyasla daha yüksek olduğu gözlemlenebilir.



Şekil 3.5 Rastgele bir veri kümesi için Mean-Shift yönteminin çalışma ilkesi
(a) pencerenin başlangıç konumu (b) pencerenin yeni hesaplanan moda kaydırılması
(c) iterasyonların ardından pencerenin kaydırıldığı son konum


Mean-Shift yöntemi, K-Means gibi diğer parametrik kümeleme algoritmalarına göre çeşitli avantajlar sunar. Mean-Shift yöntemi, kümelenmelerin sayısının önceden tanımlanmasına gerek yoktur. Aksine, verileri mekânsal ve spektral benzerliklerine dayalı olarak kümeler. Tanımlanması gereken tek parametre, pencere boyutudur (h_s , h_r). Bununla birlikte, pencere boyutunun belirlenmesi zordur ve uzun hesaplama zamanı gerektirebilir. Pencerenin çok büyük seçilmesi hesaplama süresini arttırır ve küçük parçaları birleştirir. Çok küçük boyutlarda ise daha izole bölgeler ortaya çıkabilir.

Çay bahçelerinin otomatik olarak bölütlenmesi için çok bantlı dijital ortofoto görüntülere Mean-Shift yöntemi uygulanmıştır. Algoritma tek bant veya üç bantlı görüntüler ile çalıştığından RGB bantları girdi veri olarak kullanılmıştır.

Mean-Shift yöntemi, açık kaynak kodlu EmguCV kütüphanesi kullanılarak [98] uygulanmıştır. Söz konusu kütüphane OpenCV kütüphanesinin .NET ortamındaki versiyonudur [99]. Uygulamada bant genişliği dışında iterasyon sayısı ve minimum bölüt boyutu parametreleri de kullanılmıştır. Minimum bölüt boyutu bir eşik değerdir ve bu eşikten daha küçük bölütler atılır. Tez çalışmasında deneysel olarak tüm görüntüler için minimum bölüt boyutu 50 ve iterasyon sayısı 10 olarak belirlenmiştir. 10 un üzerindeki iterasyon sayısının bölütleme sonuçlarını etkilemediği gözlemlenmiştir. Öte yanda bölüt boyutunun 50 seçilmesinin nedeni bu değerin görüntüdeki en küçük çay bahçesi alanına karşılık gelmesidir.

Daha yüksek sayıda yineleme, kümelenme çıktısını etkilemediğinden, daha küçük bir değere ayarlanmıştır. Öte yandan, 50'ye ayarlanmış bölüt büyüklüğü için nispeten daha küçük bir değer seçildi. Her ne kadar ana amaç, diğer nesnelerle karşılaştırıldığında nispeten daha büyük olan çay bahçesi objelerini çıkarmak olsa da, Mean-Shift yöntemi bölütleme yöntemi kullanılarak mümkün olduğunca fazla bilgi elde etmek için bu değer seçilmiştir. Minimum bölüt parametresinin büyük seçilmesi farklı obje bölütlerinin birleştirilmesi gibi bir problem yaratacağından optimum büyüklük yapılan deneyler sonucunda 50 olarak belirlenmiştir.

Şekil 3.6, h_s ve h_r parametrelerinin farklı seçimlerin bölütlemeye etkisini göstermektedir. Şekilde h_s parametresi için 5, 9, 15 ve 30; her bir h_s parametresi için h_r parametresi de 5, 15 ve 30 olarak seçildiğinde elde edilen sonuçlar verilmiştir. h_s ile h_r



Şekil 3.6 Bant genişliği parametrelerinin bölütlemeye etkisi

karşılaştırıldığında h_s nin daha az etkisi olduğu görülmektedir. Sunulan tez çalışmasında her iki parametre de 5 olarak seçilmiştir. Bunun iki nedeni söz konusudur: Birincisi, bant genişliği parametresine küçük değerler verildiğinde küçük alanların birleştirildiğinde elde edilen bölütlerin spektral olarak benzer fakat aynı olmayan bölütleri oluşturmadığı görülmüştür. Burada amacın mümkün olduğunca çok orijinal bilgiyi muhafaza etmek olduğu için küçük değerlerin seçilmesinin faydalı olduğu görülmüştür. Daha sonra çay bahçeleri olmayan küçük yalıtılmış bölgeleri kaldırmak

için geometrik kısıtlamaların uygulanmasına da olanak sağlar. İkinci olarak, daha küçük bir bant genişliği seçimi ile bölütlemenin işlem süresini azaltmıştır. Mean-Shift itearatif ve karmaşık bir süreç olduğundan, yoğun bellek ve işlem gücü gerektirmektedir. Büyük hacimli görüntüler için işlem süresi, artan bant genişliği parametreleri ile katlanarak artar. Ayrıca daha küçük bant genişliği seçimi ile bölütlemenin doğru sonuçlar ürettiği de gözlenmiştir.

Mean-Shift yöntemi ile bölütler üretilmiştir. Tez çalışmasında pikseller yerine üretilen bölütler kullanılarak nesne tabanlı yaklaşım uygulanmıştır. Böylelikle sınıflandırma için özellikler bölütler kullanılarak seçilmiştir.

3.4.3 Görüntü Filtreleme


Bölütleme aşaması ile bitki örtüsü sınıfına dâhil edilebilecek obje gruplarının belirlenmesine yönelik nesnelerin oluşturulması sağlanmıştır. Bu nesneler, hem aday çay bahçesi hem de diğer bitki örtüsü türlerini içermektedir. Bunun dışında tüm bölütler salt bitki örtüsünü değil aynı zamanda yollar, binalar gibi insan yapısı objeleri de içermektedir. Dolayısı ile, bölütleme sonucunda elde edilen bitki örtüsü olmayan alanları elemek için filtreleme uygulanmıştır. Bitki olmayan ve gürültülü öğelerin görüntüden uzaklaştırılmasının iki avantajı vardır: Birincisi, sonraki süreç sadece bitki örtüsü alanlarında yapılacak olduğundan, işlem süresini kısaltır. İkinci olarak, sınıf karışıklığı problem ortadan kaldırılarak daha yüksek doğrulukta sınıflandırma sonuçları elde edilebilir. Vejetasyon alanlarının diğer alanlardan ayrılması ile çay bahçeleri ve diğer vejetasyon alanları olmak üzere eğitim verilerinin seçilmesi olanaklı olmuştur. Bu amaç için Normalleştirilmiş Fark Bitki Örtüsü İndeksi (Normalized difference vegetation index-NDVI) hesaplanmış ve daha sonra bitki örtüsü olmayan alanları filtrelemek için hem morfolojik filtreler hem de geometrik kısıtlamalar uygulanmıştır.

NDVI, çok bantlı veya hiperspektral görüntülerde bitki örtüsünün elde edilmesine yönelik bir indekstir. Görüntülerin kırmızı (R) ve yakın kızılötesi (NIR) bantlarının farkına toplamalarının oranı alınarak elde edilir. Matematiksel tanımı aşağıda verilmiştir.

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad (3.3)$$

NDVI'in çıkış değerleri genellikle $[-1, +1]$ arasında bulunur. $+1$ 'e yakın değerler daha yüksek bitki örtüsüne işaret ederken, -1 'e yakın değerler ise bitki örtüsü olmayan alanları (bitki örtüsü yok) göstermektedir. Mevcut çalışma için NDVI değerleri filtrelenmiş ve sadece $NDVI > 0$ içeren değerler ileri işleme için seçilmiştir. Ayrıca, NDVI için spektral değerler normalize edilmiştir $[0 - 1]$. Elde edilen ikili görüntü, bitki örtüsü olmayan alanları filtrelemek için maske olarak kullanılmıştır.

Şekil 3.7, veri kümesinde bulunan çeşitli arazi örtüsü sınıfları için rastgele seçilmiş örneklerle ait NDVI profillerini göstermektedir. Her bir sınıf için NDVI profilleri, bitki örtüsünün NDVI sonuçlarına eşik değer uygulanarak sınıfın geri kalanından ayrılabilceğini göstermiştir. Bitki örtüsü olmayan alanlar (geçirimsiz yüzeyler, çıplak topraklar, su kütlesi) için NDVI değerleri sıfırdan azdır. Bu yüzden NDVI sonuçlarından yararlanılarak orijinal görüntüden vejetasyon olmayan alanlar elimine edilebilmiştir. Bununla birlikte, salt NDVI ile çay bahçelerinin ve diğer vejetasyon türünden ayrılması olanaksızdır. Aslında, bu iki sınıf için spektral yansıtma bilgileri bir ölçüt olsa da sadece spektral bilgiye dayanan özelliklerin kullanılması, bu objelerin ayrılması için yeterli olmayabilir. Bu zorlukla başa çıkmak için, tez çalışmasında mekânsal ve dokusal özelliklerin içerildiği için makine öğrenme temelli sınıflandırma algoritmaları uygulanmıştır.



Şekil 3.7: Çay bahçeleri, diğer vejetasyon, insan yapısı objeler, çıplak arazi ve su kütlelerini temsil eden örnek sınıflar için NDVI profilleri

Morfoloji operatörleri bölge sınırlarının tanımlanmasında yaygın olarak kullanılır. Bu işlem yapı taşı elemanı (YTE) ve uygun morfoloji operatörü uygulanarak gerçekleştirilebilir. YTE'nin boyutu ve şekli özel şekillere duyarlıdır.

İki ana matematiksel morfoloji operatörü vardır. Bunlar genişleme ve erozyon operatörleridir. Her iki operatör de tanımlanan YTE ile çalışır. Genişleme ile nesnelerin sınırlarına pikseller eklenerek obje genişletilirken, erozyon ile sınırlar boyunca pikseller çıkartılır. Şekil 3.8, morfolojinin temel işlemlerine ilişkin bir örneğini göstermektedir. (a) ve (b) 'de soldaki pikseller, ortada gösterilen 3 x 3 YTE elemanı kullanılarak morfolojik filtrelenmiştir. Şekilde, sağ tarafta, erozyon ve genişleme operasyonları uygulandıktan sonra elde edilen sonuçlar verilmiştir. [100]'e göre, A ile B kümesinin matematiksel olarak genişlemesi ve erozyonu aşağıdaki şekilde matematiksel olarak tanımlanmıştır:

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (3.4)$$

$$A \ominus B = \{z | (B)_z \cap A^c \neq \emptyset\} \quad (3.5)$$


$\oplus$ sembolü genişleme ve $\ominus$ sembolü erozyon operatörünü temsil eder. A ikili kodlanmış bir görüntüyü ve B ise YTE'yi temsil eder.

Bazen temel morfoloji operatörlerini (genişleme ve erozyon) birleştirmek faydalı olabilir. Bunun için açılış ve kapanış operatörleri kullanılır. Açılış işlemi, aynı yapılandırma elemanı kullanılarak genişleme ardından erozyon gerçekleştirir. Benzer şekilde, kapanış, aynı yapılandırma elemanı kullanılarak erozyon işleminin ardından genişleme gerçekleştirir. Açma ve kapama işlemleri ile objenin şekli korunabilir ve etkisi, temel morfolojik operasyondan daha az deforme edicidir. Bu nedenle, ikili görüntülerde morfolojik işlemler için açma veya kapama işlemleri oldukça sık kullanılır.

Sunulan tez çalışmasında, nesneler içindeki küçük boşlukları gidermek ve sınırlarını yumuşatmak için bölütlenmiş görüntülere morfolojik açma işlemi 5 x 5 boyutunda bir kare YTE kullanılarak gerçekleştirilmiştir.

Çay bahçelerine ait bölütler, diğer nesnelerle (örneğin, izole edilmiş ağaçlara) kıyasla daha büyük olduğu için, bu gibi nesneleri çıkarmak için bir dizi geometrik kısıtlama da oluşturulmuş uygulanmıştır. Bağlı bileşenler (connected components) hesaplanarak her

bir bölüt için sınırlayıcı kutular (bounding box) elde edilmiştir. Alan ve büyüklük ölçütleri belirlenerek çay bahçesine ait olmayan nesneler elenmiştir. Bu işlem için eşik değerler deneysel olarak saptanmıştır. 500 pikselden az olan ve sınırlama kutusunun minimum genişliği ve yüksekliği 200 pikselden az olan nesneler elenmiştir.



Şekil 3.8 3x3 lük yapı taşı elemanı için morfoloji operatörlerinin sonuçları (a) Erozyon (b) Genişleme

Görüntülerde, genellikle çay bahçelerine ait bölütler spektral olarak homojen dağılımda olmasına karşılık farklı spektral özelliklere sahip bölütler de söz konusudur. Bu nedenle boşluklar oluşmuştur. Morfolojik operatörler ile elimine edilemeyen bu objeler için tekrar bağlı bileşenler hesaplanarak alanları 100 pikselden az olan küçük nesneler çıkartılmıştır. Çay bahçeleri sınıfına aday pikseller beyaz ve art alan siyah olmak üzere ikili kodlanmış görüntü tekrar üretilmiştir.

3.4.4 Özellik Çıkartma

Modern algılayıcılar, ayrıntılı konumsal bilgi sağlayan yüksek geometrik çözünürlüğe sahip görüntüler sağlar. Böylelikle, sınıflandırma doğruluğunu etkin bir şekilde artıracak ek bilgiler elde edilebilir. Mekânsal bilgileri birleştirmenin bir yolu, dokusal

özellikleri türetmektir. Böylelikle objelerin yapısal özellikleri de ek bilgi olarak kullanılarak sınıflandırmanın doğruluğunun artırılması olanaklıdır.

Piksel tabanlı yaklaşımlar için yaygın olarak kullanılan geleneksel hareketli pencere yönteminden farklı olarak, bu çalışmada dokusal özellikler elde etmek için tek tek nesneler kullanılmıştır. Bu özellikler nesneye özgü doku olarak da adlandırılabilir. Nesne tabanlı doku özelliğinin türetilmesinin en önemli avantajı, geleneksel yaklaşımlardan farklı olarak yöntemin pencere boyutundan bağımsız hale getirilmesidir.

Uzaktan algılama verilerinin analizi için doku analizi (Gray-Level Co-Occurrence Matrix-GLCM [101] yaygın olarak kullanılmaktadır. Yöntem çeşitli yönlerde tekraralama sıklığını tanımlayarak dokudaki tekrarlanan kalıpları bulur. Bu amaçla en çok kullanılan doku yakalama özellikleri şunlardır: kontrast, korelasyon, enerji, homojenlik, entropi, ortalama, standart sapma. Ayrıca, atalet veya varyans olarak bilinen kontrast, komşu pikseller arasındaki yoğunluk değerlerinde bir kontrast ölçüsü sağlar, korelasyon, nesnedeki pikseller arasındaki korelasyonun ölçüsüdür. Aynı zamanda açılal ikinci momentum olarak da bilinen enerji veya monotonluk GLCM' nin karesel elemanlarının toplamını hesaplar. Homojenlik pikselin GLCM'nin diyagonaline ne kadar yakın olduğunu, ortalama değer ve standart sapma ortalamadaki gri değerlerin dağılımının ölçüsünü verir. Çizelge 3.3'te bu sekiz doku özelliklerine ilişkin formülasyon verilmiştir.

Doku özelliklerinin çıkarılması, spektral veya uzaysal filtrelere kıyasla daha karmaşıktır. GLCM doku özelliklerinin gri düzeyli iki boyutlu görüntüler şeklinde tanımlanması gerekir. Nesne tabanlı yaklaşımlarda nesneler gri değerleri ile temsil edilmelerine karşılık iki boyutlu matris yapısında değildir. Dahası, Mean-Shift yöntemi, nesnedeki her bir pikselin değerlerinin mod değeriyle değiştirildiği görüntü nesneleri üretir. Bununla birlikte, görüntüdeki birçok nesne diğer nesneler ile spektral benzerliklerine bağlı olarak aynı mod değerine sahip olmalarına karşın görüntüde bu objelerden uzak konumda olabilirler. Bu nedenle, mod değeri, bölütlere ayrılmış her bir nesneyi özgün şekilde temsil etmek için kullanılamaz. Uygulama açısından, her nesne sonraki işlem ve sınıflandırma için görüntüde özgün bir değerle temsil edilmelidir.

Sunulan tez çalışmasında özellik çıkartma işleminden önce söz konusu problem çözülmüştür. Bölütlenmiş nesnelerin iki boyutlu bir temsilini elde etmek için, her bir nesnenin sınırlayıcı kutusu (bounding box) kullanılmıştır. Sınırlama kutusu, nesneyi örtebilecek en küçük olası dikdörtgendir. Tüm nesnelerin mükemmel kareler veya dikdörtgenler olmadığı, ancak sınırlayıcı kutu içindeki nesnenin kapladığı alanın dışında kalan alanın art alan olduğu açıktır. Bu nedenle, sınırlayıcı kutu içindeki daha küçük arka plan alanının, nesneden çıkarılan dokusal özellikler üzerinde çok az etkisi olacağı varsayılmıştır. Böylelikle Mean-Shift yöntemi ile elde edilen nesnelere ilişkin gri düzeyli dokusal özelliklerin GLCM için tanımlanması olanaklı hale gelmiştir.

Çizelge 3.3 Dokusal Özellikler

Özellik adı	Matematiksel form
Entropy	$-\sum_{i=1}^m \sum_{j=1}^n P \times \ln(P_{ij})$
Mean Gradient (μ)	$\frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n G(i,j)$
Standard Deviation(σ)	$\left[\frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n (G(i,j) - \mu)^2 \right]^{\frac{1}{2}}$
Homogeneity	$\sum_{i=1}^m \sum_{j=1}^n \frac{G(i,j)}{1 + (i - j)^2}$
Energy	$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} [G(i - j)]^2$
Contrast	$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} (i - j)^2 G(i,j)$
Correlation	$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} \frac{G(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$

Her bir nesneyi temsil eden tek özellik vektörü oluşturmak için doku ve spektral özellikler birleştirilerek sonlandırılmış özellik vektörleri daha sonra sınıflandırıcının eğitim ve test aşamalarında kullanılmıştır. Sonuçta çay bahçesi ve diğer ağaç türlerine ait sınıflar elde edilmiştir.

Özellik çıkartma ve özellik seçimi sınıflandırmada önemli bir role sahiptir. Nesnelere ilişkin ayırt edici özellikler doğru belirlenmez ise bu durum doğrudan eğitimin kalitesini belirler ve sınıflandırma doğruluğunu azaltır. Bu nedenle, sunulan tez çalışmasında spektral özellik analizi yapılmıştır. Özellik analizinin detayları aşağıdaki bölümde sunulmuştur.

3.4.4.1 Özellik Analizi

Herhangi bir sınıflandırıcının sınıflandırma doğruluğu, kullanılan özelliklerin kalitesine bağlıdır. Sınıflandırmada hem doku hem de spektral / mekânsal özelliklerin kullanımının sınıflandırmanın doğruluğunu artırdığı kanıtlanmıştır [3]. Dolayısı ile sınıflandırmada seçilen özelliklerin birbirlerinden ayrılabilir olması gereklidir. Özellik analizinin amacı, farklı sınıfları ayırt etmek için özelliklere ait alt kümelerin seçilmesidir.

Özellik seçiminde arama stratejisi ve ayırt edici ölçütlerinin belirlenmesi olmak üzere iki ana adım söz konusudur. Arama stratejisi, özelliklerin seçilmesi ve seçilen özelliklerin ileri işleme için belirli ölçütlere uyup uymadıklarının ve dolayısı ile uygun aday olup olamayacaklarının belirlenmesidir. Literatürde önerilen çeşitli arama stratejileri vardır [102]. Sıralı arama stratejisi en yaygın kullanılan yaklaşımdır. Sıralı arama yaklaşımında her seferde bir özelliğin eklenmesi ve eklenen özelliğin tanımlanan ölçütlerin karşılayıp karşılamadığının belirlenmesi esasına dayanır. Ölçütleri karşılayan tüm özellikler yüksek düzeyde ayırt edici olarak kabul edilir ve seçilen özellik kümesinin alt kümesine eklenir.

Sunulan çalışmada, Jeffries-Matusita (JM) istatistiksel mesafesi, özelliklere ilişkin ayırt edici ölçütün bulunması amacı ile kullanılmıştır [74]. Bu ölçüt, özelliklerin ilgili iki sınıfın ayrılabilmesi için yeterli olup olmadığını bulmak için kullanılır. JM, iki yoğunluk fonksiyonu arasında ortalama mesafe ölçüsü sağlar. Bhattacharyya (B_{ij}) ile tanımlanan JM mesafesi aşağıda verilmiştir:

$$JM_{ij} = \sqrt{2\{1 - \exp[-B_{ij}]\}} \quad (3.6)$$

Benzer olarak, B_{ij} , şartlı olasılık olarak ω_i and ω_j sınıflarının dağılımlarına bağlı olarak aşağıdaki şekilde tanımlanır.


$$B_{ij} = -\ln \left\{ \int \sqrt{p(x/\omega_i)p(x/\omega_j)} dx \right\} \quad (3.7)$$

Burada $p(x/\omega_i)$ ve $p(x/\omega_j)$ sırasıyla ω_i ve ω_j sınıfları için koşullu olasılık yoğunluk fonksiyonlarını temsil eder [93].


Genellikle, JM istatistiksel mesafe ölçümü değerleri [0-2] aralığındadır. Daha yüksek JM değerleri yüksek ayrışmayı temsil eder ve bu özellikler seçim için potansiyel adaylardır. Düşük değerler ise sınıflar arasında düşük spektral ayırt edilebilirliği temsil eder [44] ve kullanılmaz.

Çay bahçelerinin bölütlenmesine yönelik, çay bahçeleri ve diğer ağaç türleri arasında ayırım yapmak için kullanılabilecek olası ayırt edici özellikleri bulmak için özellik analizi yapılmıştır. Çünkü bilindiği gibi, bitki örtüsü sınıflandırması, sınıflar arası benzerlikler nedeniyle oldukça zordur. Bu nedenle, yüksek düzeyde ayırt edici bir özellik vektörünün elde edilmesi önemlidir. Her nesne farklı yansıma yapabildiği için obje yakalama problemlerinde spektral yansıma değerleri özellik kümesinin önemli bir bileşeni olarak kullanılır. Şekil 3.9, ortofoto görüntülerinde mevcut her olası sınıf için ortalama yansıma değerlerini göstermektedir. Spektral bilginin ilgili sınıfa ilişkin iyi bir ipucu sağladığı açıktır. Bu nedenle, bu sınıfların ayırt edilebilirliği artırmaya yönelik özellikler oluşturulurken hem spektral hem de dokusal özellikler birleştirilir.

Şekil 3.10' te örnek ortofoto görüntüye ait her bir bant için ortalama ve standart sapma değerlerine ilişkin grafik verilmiştir. Şekilden görülebileceği gibi, kırmızı, yeşil ve mavi bantlardaki spektral değerler nispeten benzer ortalama değerlere sahipken, yakın kızılötesi bant daha yüksek gri tonlamalı değerleri yakalamıştır. Şekil 3.11 çay bahçeleri ve diğer ağaç türleri için sekiz farklı doku özelliğine ait grafiği göstermektedir.




Şekil 3.9 Farklı olası sınıflar için ortalama yansıma bilgileri




Şekil 3.10 Her bir bant için ortalama ve standart sapma

Her bant için sınıfların spektral ayırt edilebilirliklerinin de ölçülebiliyor olması önemlidir. Seçilen dört sınıfa ait spektral varyans değerlerinin her bir bant için dağılımı Şekil 3.12'de gösterilmiştir. Her sınıf için yansıma değerlerinin çıkışıyor şaşırtıcı değildir. Özellikle, çay bahçeleri ve diğer ağaç türleri için R, G ve B bantlarında daha fazla spektral benzerlik gözlenmektedir. Bununla birlikte, NIR bantta bu sınıflar için spektral yansımalar farklılaşmaktadır. Ayrıca, insan yapısı objeler sınıfı için NIR bandında ortalama değişkenlik genellikle daha yüksektir.




Şekil 3.11 Çay bahçeleri ve diğer ağaç türleri için sekiz normalleştirilmiş dokusal özelliğe ait grafik 1- contrast, 2- correlation, 3- dissimilarity, 4- homogeneity, 5- mean, 6- entropy, 7- standard deviation, 8- energy



Şekil 3.12. Örnek eğitim verilerinden elde edilen, her bant için minimum, maksimum ve ortalama yansıma değerini gösteren grafik

Şekilil 3.13’ den görüleceği gibi çay bahçesinin dört bantta spektral yansımaların diğer ağaç türlerine göre daha homojen bir şekilde dağılmaktadır. Diğer ağaçlar sınıfının çay bahçesi sınıfına göre karışık yansıma ürettiği yine şekilden görülmektedir.



Şekil 3.13 Çay bahçeleri ve diğer ağaç türleri sınıflarının kırmızı, yeşil, mavi ve NIR bantlarında spektral değişimleri

Sunulan çalışmada, başlangıçta 31 özellik çıkartılmıştır. Bu özellikler JF mesafe ölçümü kullanılarak ileri besleme seçimi uygulandıktan sonra, iyi sınıflandırma sonuçları üreten sadece 17 optimum özelliğe indirgenmiştir. Bunun tüm bantlar kullanılarak, her nesne için sekiz mekânsal ve sekiz doku özelliği elde edilmiştir. NDVI profillerinden de bir ek özellik elde edilmiştir.

3.4.4.2 Özelliklerin Normalizasyonu

Denetimli sınıflandırmada, sınıflandırıcının eğitilmesi ve test için özellik vektörlerinin normalleştirilmesi gerekir. Özellik normalizasyonu için çeşitli yöntemler önerilmiştir. Bununla birlikte, en yaygın kullanılan normalizasyon yöntemleri, min-max ve z-skoru normalleştirmesidir. Tez çalışmasında için min-max normalizasyon yöntemi kullanılmıştır. Özellikler kullanılmadan önce, çapraz doğrulama veya sınıflandırma için, [0, 1] arasında normalleştirilmiştir. Matematiksel olarak, min-max özellik ölçeklendirme aşağıdaki şekilde ifade edilir:



$$X_{Norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.8)$$

Burada, X_{Norm} min-max yöntemine göre normalleştirilmiş özelliği, X_{min} ve X_{max} özellik vektörünün minimum ve maksimum değerlerini göstermektedir. Çizelge 3.4' te çay bahçesi bölütlenmesi için kullanılan özellikler sunulmuştur.

Çizelge 3.4 Çay bahçesi bölütlenmesi için kullanılan özellikler.

Tip	Kaynak	Açıklama
Spektral, Mekansal	Kırmızı bant Yeşil bant Mavi bant Kızılötesi bant NDVI	Tüm bantların ortalaması Tüm bantların standart sapması Ortalama NDVI
Doku	Grey-level co-occurrence matrix	Contrast Correlation Dissimilarity Homogeneity Mean Entropy Standard Deviation Energy

Şekil 3.14, verilerin normalizasyonundan önceki ve sonraki genel dağılımını göstermektedir. Hem normalleştirilmemiş (a) hem de normalleştirilmiş (b) dağılım görülmektedir. Şekilden dağılımın normalleştirme sonrası da aynı kaldığı görülmektedir. (a) kırmızı bantta örnek bir görüntüden seçilen orijinal gri tonlama değerlerini gösterirken (b) [0, 1] arasında ölçeklenen aynı verileri göstermektedir.



Şekil 3.14. Özellik normalizasyonu a) Orijinal gri değerler b) [0, 1] aralığında normalleştirilmiş veriler

3.4.5 Sınıflandırma

Sınıflandırmanın amacı, bir görüntü içindeki her piksel / nesneye doğru bir etiket atamaktır. Sunulan tezde, nesneye dayalı bir görüntü sınıflandırmasına odaklanılmış, girdi görüntüye Mean-Shift bölütleme yöntemi uygulanarak bölütler elde edilmiştir. Her nesneye ait özellikler (spektral, mekânsal ve dokusal) bölütleme sonuçlarından yararlanılarak üretilmiştir. Son olarak, özellik seti kullanılarak sınıflandırma gerçekleştirilmiştir.

Literatür araştırması, farklı sınıflandırıcıların kombinasyonunun sınıflandırma doğruluğunu artırabileceğini göstermiştir [3], [12]. Her bir tekil sınıflandırıcı özellik iyi eğitilemeyebilir. Farklı sınıflandırıcıların kombinasyonu ile, her bir sınıflandırıcının güçlü yanlarından yararlanılarak sınıflandırıcının çıktılarının birleştirilmesi ile sınıflandırma doğruluğu artırılabilir.

Her ne kadar sınıflandırıcı seçimine yönelik genel bir kural olmasa da, öğrenme temelli algoritmalara dayalı sınıflandırıcıların daha doğru sonuçlar üretmektedir [103]. Bu nedenle, sunulan çalışmada analiz için üç farklı öğrenme temelli sınıflandırıcı seçilmiştir: SVM, YSA ve RF. Otomatik çay bahçesi bölütleme yöntemine ilişkin uygulama detayları açıklamadan önce, her bir sınıflandırıcının matematiksel ayrıntıları aşağıda sunulmuştur.

3.4.5.1 Destek Vektör Makinası (SVM)

SVM sınıflandırma yöntemi karmaşık desene sahip görüntülerin sınıflandırılmasında oldukça etkili bir yöntemdir. Uzaktan algılama verilerinin sınıflandırılmasında az sayıda eğitim verisi ile sınıflandırmanın gerçekleştirilebilmesine olanak sağladıkları için büyük eğitim grupları ile çalışma zorunluluğunu ortadan kaldırmıştır. Bu nedenle yaygın olarak kullanılan bir yöntemdir [39]. SVM yönteminde optimize edilmiş hiper düzlemler yardımı ile iki sınıfın ayırt edilebilirliği maksimize edilir. Sunulan tez çalışmasında çay bahçesi bölütlenmesi amacıyla kullanılan sınıflandırıcılardan biri olan SVM yöntemine ilişkin temeller [104] 'te bulunabilir.

İki doğrusal olarak ayrılabilir sınıf için bir ikili sınıflandırma sorunu için $\{X_i, Y_i\}_{i=1}^N$ eğitim verilerini temsil etsin. Burada N eğitim verisi sayısı ve $Y_i = \{-1, +1\}$ ilgili sınıfların

hedef değerleri olsun. Temsil edilebilecek iki sınıf arasındaki mesafeyi en üst düzeye çıkararak, en uygun hiper düzlem aşağıdaki şekilde bulunur.

$$W^T X + b = 0 \quad (3.9)$$

Burada X giriş vektörü, W ağırlık vektörü ve b bias değerini ifade etmektedir. $Y_i = +1$ pozitif sınıfı temsil eder ve $Y_i = -1$ negatif sınıfı temsil eder. Optimal hiper düzlemi bulmak için W ve b parametrelerinin doğru şekilde tahmin edilmesi gerekir.


$$W^T X_i + b \geq +1 \quad \text{for } y_i = +1 \quad (3.10)$$

$$W^T x_i + b \leq -1 \quad \text{for } y_i = -1 \quad (3.11)$$

Bu iki eşitlik kombine edilerek aşağıdaki sonuç elde edilir:

$$y_i (w^T x_i + b - 1) \geq 0 \quad \text{for } i=1,2,3,\dots, N \quad (3.12)$$

Geometrik olarak, en yakın veri noktası ve hiper düzlem arasındaki mesafe optimum mesafe (margin) olarak adlandırılır. Şekil 3.15' de hiper düzlem ile destek vektörü adı verilen veri noktası arasındaki ayırma çizgisi gösterilmiştir. $w / \|w\|$ başlangıç ile hiper düzlem arasındaki geometrik uzaklıktır.



Şekil 3.15 SVM sınıflandırıcı için hiper düzlem gösterimi

En uygun mesafeyi bulmak için, destek vektör setinden alınan ve marjın sınırında yer alan pozitif örnek noktası ve negatif örnek noktası (Şekil 3.15) için önce $x_+ - x_-$ vektörü hesaplanır ve optimum mesafe aşağıdaki şekilde tanımlanır.

$$\text{Margin} = (x_+ - x_-) \cdot \left(\frac{w}{||w||} \right) \quad (3.13)$$

x_+ pozitif örneği temsil ettiğinden $Y_i = +1$ olur. Bu değer eşitlik (3.12)' de yerine konulacak olursa $\bar{w} \cdot \bar{x}_+ = 1 - b$ elde edilir. Benzer şekilde x_- için $Y_i = -1$ olur ve eşitlik (3.12)' den $\bar{w} \cdot \bar{x}_- = -1 - b$ elde edilir. Eşitlik (3.13) yeniden yazılacak olursa:

$$\text{Margin} = (\bar{w} \cdot \bar{x}_+ - \bar{w} \cdot \bar{x}_-) \cdot \left(\frac{1}{||w||} \right) \quad (3.14)$$

Yukarıdaki değerler eşitlik (3.13)' de yerine yazılırsa eşitlik (3.14) elde edilir.

$$\text{Margin} = (1 - b + 1 - b) \cdot \left(\frac{1}{||w||} \right) \quad (3.15)$$

$$\text{Margin} = \left(\frac{2}{||w||} \right) \quad (3.16)$$

Bu nedenle, iki sınıf arasındaki ayırma marjını en üst düzeye çıkarmak için, $\frac{2}{||w||}$ faktörünün maksimize edilmesi gerekir. Matematiksel kolaylık açısından eşitlik bazen $\frac{1}{2} ||w||^2$ şeklinde de ifade edilir. Optimal hiper düzlemin elde edilmesi için ağırlık vektörünün Öklid normunun minimize edilmesi gerekir. Bu durumda amaç fonksiyon aşağıdaki şekilde tanımlanır.

$$\text{Minimize } \frac{1}{2} ||w||^2 \quad (3.17)$$

$$y_i(w^T x_i + b - 1) \geq 0 \quad \text{for } i=1,2,3,\dots, N \quad (3.18)$$

Optimizasyon probleminin çözümü Lagrange çarpanları kullanılarak gerçekleştirilir.

$$L(w, x, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i \{y_i(w^T x_i + b) - 1\} \quad (3.19)$$

α_i değişkenleri Lagrange çarpanları olarak adlandırılır ve N, destek vektörleri olarak adlandırılan sıfır olmayan Lagrange çarpanlarına karşılık gelen eğitim örneklerinin sayısıdır. w ve x değişkenleri için (3.19) eşitliği minimize edilmelidir. Buradan

$$L(w, x, \alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j Y_i Y_j X_i^T X_j \quad (3.20)$$

Optimum çözüm için (3.20) eşitliğinin maksimize edilmesi gerekir. Doğrusal olarak ayrılabilir sınıflandırma problemi için, verilen kısıtlar altında genel bir optimum çözümün söz konusudur.

Genelde , tüm problemler doğrusal olarak ayrılabilir değildir ve eşitlik (3.20) bu tür karmaşık problemlerin çözümünde kullanılamaz. Alternatif bir çözüm, giriş verisini çekirdek fonksiyonu ile daha yüksek bir boyuta dönüştürmek olabilir. Böylelikle dönüştürülen verilerin doğrusal olarak ayrılabilir olması ve SVM sınıflandırıcısının verileri ayırmak için bir hiper düzlem oluşturması beklenir. Eşitlik (3.20), çekirdek fonksiyonu ile yeniden aşağıdaki şekilde düzenlenebilir.

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.21)$$

$$K(x_i, x_j) = \phi(x_i) \phi(x_j) \quad (3.22)$$

K, çekirdek fonksiyonu olarak adlandırılır. Çekirdek seçimi için çeşitli seçenekler mevcuttur. Sunulan tez çalışmasında radyal temel fonksiyonu (RBF) çekirdeği kullanılmıştır [12]. RBF matematiksel olarak aşağıdaki şekilde ifade edilebilir:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (3.23)$$

3.4.5.2 Yapay Sinir Ağları

Biyolojik sinir ağları, yapay sinir ağlarının (YSA) temelini oluşturur [104]. Bugün çeşitli YSA modelleri mevcuttur. Ancak, desen tanıma problemlerinde en çok katmanlı algılayıcı olarak da bilinen ileri beslemeli sinir ağları kullanılır [105].


Çok katmanlı ileri beslemeli sinir ağlarının temel yapı taşları tam bağlı çoklu nöron ve doğrusal olmayan aktivasyon fonksiyonlarıdır. Nöronlar, giriş, gizli ve çıkış katmanlarından oluşan çoklu katmanlar halinde düzenlenir. Giriş katmanı giriş verilerini, gizli katmanlar karmaşık doğrusal olmayan hesaplamaları gerçekleştirir ve

çıkı katmanı ağı sonu çıkıısını üretir. Doğrusal olmayan aktivasyon fonksiyonları, girişler verilerine uygulanır ve çıkı sinyalinin üretilmesini sağlar.

Sinir ağı eğitimi karmaşık bir süreçtir. YSA'yı eğitmek için çeşitli algoritmalar vardır, fakat geri yayılım, YSA'yı eğitmek için yaygın olarak kullanılan en popüler yöntemdir. Geri yayılım yoluyla YSA eğitim süreci iki aşamadan oluşur:

İleri Evre (Forward Phase): Giriş bilgisi giriş katmanlarından ileri yönde geçirilir ve çıkı katmanına doğru itilir. Her katmanda, giriş sinyali her bir katmanın ağırlıkları ile çarpılır, bias eklenir ve daha sonra çıkı üretmek için aktivasyon fonksiyonu uygulanır.

Geriye Dönük Evre (Backward Phase): Eğitim aşamasında, ileri aşamadaki ağıdan elde edilen çıkı, hata sinyalini bulmak için gerçek etiketle karşılaştırılır. Bu hata sinyali daha sonra tabakalar boyunca geriye doğru yayılır ve karşılık gelen ağırlıklar ağı eğitim hatasını azaltmak için güncellenir. Şekil 3.16 örnek bir tam bağı çok katmanlı ileri beslemeli sinir ağıının mimarisini göstermektedir. Belirli bir katmandaki bir nöronun, önceki tabakadaki tüm nöronlara bağıdır [106].



Şekil 3.16 Örnek bir çok katmanlı ileri beslemeli yapay sinir ağı

$X = x_1, x_2 \dots x_D$. girdi verisi için temel bir YSA modeli oluşturulabilir. Matematiksel model [105]' e göre açıklanmıştır. Aktivasyon aşağıdaki şekilde tanımlanabilir:

$$a_j = \sum_{i=1}^D w_{ji}^{(1)} x_i + b_j^{(1)} \quad (3.24)$$

a_j aktivasyon olmak üzere, $w_{ji}^{(1)}$ katman 1'deki j.inci bağlantının ağırlığı ve $b_j^{(1)}$ katman I nin bias değeridir. Doğrusal olmayan aktivasyon fonksiyonu her nörona çıkış için aşağıdaki şekilde uygulanır:

$$z_k = h(a_j) \quad (3.25)$$

Burada z_i giriş katmanındaki her bir nörona ait çıktı ve $h(.)$ Sigmoid fonksiyonu gibi doğrusal olmayan aktivasyon fonksiyonudur. Benzer şekilde, gizli katmandaki nöronlar için aktivasyonlar aşağıdaki şekilde belirlenebilir:

$$a_k = \sum_{i=1}^D w_{ki}^{(2)} x_i + b_j^{(2)} \quad (3.26)$$

Ağın son çıktısı, sınıflandırma problem bağlamında sigmoid fonksiyonu gibi bir dönüşüm fonksiyonu uygulanarak elde edilebilir.

$$y_k = \sigma(a_k) \quad (3.27)$$

Burada $\sigma(a)$ aşağıdaki şekilde tanımlanır:

$$\sigma(a) = \frac{1}{1 + e^{-a}} \quad (3.28)$$

Geri yayılma aşamasında, çıkış hatası, (y_k) ağının çıktısının yer gerçeği etiketi ile karşılaştırarak elde edilebilir. Bu hata, daha sonra, ağırlık vektörlerini güncellemek için kullanılır. Tatmin edici sonuçlar elde edilinceye kadar işlem birkaç kez tekrarlanır.

3.4.5.3 Rastgele Orman (Random Forest)

Rastgele orman (RF), Tek bir karar ağacı üretmek yerine her biri farklı eğitim kümeleriyle eğitilen çok sayıda, çok değişkenli ağacın kararlarının birleştirilmesini

öngören bir yöntemdir. Özellikle uzaktan algılama verilerinin sınıflandırılmasında yaygın olarak kullanılmaktadır.

Bu yöntem, birbirinden farklı alt eğitim kümelerinin oluşturulması işleminde önyükleme tekniğini ve ağaçların geliştirilmesi aşamasında da rastgele özellik seçimini kullanır. Torbalama yönteminden farkı, torbalama yöntemindeki gibi ağaç gelişimi aşamasında veri kümesindeki tüm değişkenleri kullanmak yerine her bir düğümde rastgele olarak seçilen değişkenler arasından en iyisini kullanarak her bir düğümü dallara ayırmasıdır. Yani ağaçlar rastgele seçilen değişkenlere göre oluşturulur. Oluşturulan yeni veri setlerinden ağaç gelişimi işlemi de CART algoritmasına göre yapılır. Bir piksel her bir bağımsız ağaca göre sınıflandırılır ve sınıflandırma sonuçlarında o pikselin atandığı sınıflar toplanır. Söz konusu piksel, ağaçların çoğunda hangi sınıfa atanmışsa o sınıfa dahil edilir [107].


[11]' e göre RF' nin hesaplama karmaşıklığı tahmini aşağıdaki eşitlikte verilmiştir.

$$\text{Time Complexity} = T\sqrt{M \times N \times \log(N)} \quad (3.29)$$

Burada T rastgele ağaç sayısını, M değişken sayısını ve N ise eğitim verisi sayısını ifade etmektedir. RF optimal sayıda ağaç elde etmek için eğitilir. İlk olarak eğitim veri setinin 2/3'ünden önyükleme örnekleri oluşturulur. Outof-bag (OOB) verisi olarak da adlandırılan, eğitim veri setinin 1/3'lük geri kalan kısmı hataları test etmek için kullanılır. Sonra her bir önyüklemeli örnekten budama olmadan ağaç geliştirilir. Her bir düğümde m değişkenleri tüm değişkenler arasından rastgele olarak seçilir ve bu değişkenler arasından en iyi dal belirlenir. Toplam M adet değişken sayısının kare köküne eşit alınan m değişken sayısı genel olarak optimum sonuca en yakın sonucu verir [11].

RF sınıflandırıcısı ağaç sayısı (N) ve kullanılan değişken sayısı (M) olmak üzere iki parametre gerektirir. Literatürde, N = 500 seçiminin uygun olduğu ve bu limite ulaşmadan önce hatanın sabit olduğu belirtilmiştir [11]. M'nin değerleri genellikle kullanılan bant sayısının karekökü alınarak belirlenir [108]. Sunulan tez çalışmasında, otomatik çay bahçesi bölütlenmesi için MATLAB 2017b platformunda SVM, YSA ve RF sınıflandırıcıları kullanılmıştır. Her bir sınıflandırıcı için gerekli parametreler, ayrıntılı

olarak Bölüm 4'te açıklanan grid arama yöntemi kullanılarak deneysel olarak hesaplanmıştır.



Şekil 3.17 Örnek RF ağaç modeli

3.4.5.4 Otomatik Çay Bahçesi Bölütlenemsi için Kullanılan Sınıflandırıcılar

Makine öğrenme temelli sınıflandırıcıların sunulan tez çalışmasında seçilmesinin nedeni, sınıflandırıcıların eğitilerek büyük veri gruplarının yüksek doğrulukta sınıflandırılmasını gerçekleştirmektir. Burada her sınıflandırıcının en güçlü yönü göz önünde bulundurularak hibrid bir sınıflandırma gerçekleştirilmiştir. Literatürde makine öğrenme temelli sınıflandırıcıların çok farklı kullanım alanı olduğu da belirtilmiştir. Fakat tekil olarak makine öğrenme temelli sınıflandırıcıların aynı zamanda farklı problemlerde beklenen sonucu üretemediği de belirtilmiştir [78].

Sunulan tez çalışmasında , en yaygın kullanılan üç öğrenme temelli sınıflandırıcı (SVM, ANN ve RF) seçilmiştir ve sonuçları maksimum oylama yöntemi ile birleştirilmiştir. Böylelikle sınıflandırma topluluğu kullanılarak çoklu sınıflandırıcılar birleştirilmiş,

sınıflandırma için gerekli olan parametreler önce eğitim verileri ve çapraz doğrulama tekniği kullanılarak belirlenmiştir.

Sınıflandırıcıların eğitilmesi için çay bahçeleri ve diğer ağaç türleri sınıflarına ait örnek eğitim verileri seçilmiştir. Gerekli her bir sınıflandırıcı parametreler daha için önceden tanımlanmış bir aralıkta grid arama algoritması uygulanarak belirlenmiştir. Çay bahçelerinin bölütlenmesi için belirlenen özellik vektörleri her bir sınıflandırıcı için kullanılmıştır. Her bir sınıflandırıcının ürettiği sonuçlara maksimum oylama sistemi uygulanıp sonuçlar birleştirilerek çay bahçeleri için sonuç çıktı üretilmiştir.

Elde edilen özellikler (önceki bölümde açıklanmıştır), sınıflandırmaya yönelik sınıflandırıcı tarafından kullanılacak şekilde hazırlanmıştır. N etiketli k-boyutlu özellikler göz önüne alındığında, eğitim veri kümesi, her özellik vektörünün karşılık geldiği etiket ile $((X_i, Y_i), X \in \mathbb{R}^N \text{ and } Y \in [-1, +1])$ eşleştirilmesiyle oluşturulmuştur. Bu çalışmada, diğer ağaç türleri -1 olarak etiketlenmiş, çay bahçeleri ise +1 olarak etiketlenmiştir. Sınıflandırma yönteminin amacı, Y'de tanımlanan etiketlerden birini test verilerine atamaktır.

Tez çalışması kapsamında belirlenen tüm sınıflandırma yöntemleri MATLAB 2017b'de uygulanmıştır. SVM sınıflandırıcı için LIBSVM kütüphanesi [109], YSA ve RF için MATLAB platformunun sınıflandırıcı kütüphaneleri kullanılmıştır.

SVM doğrusal olarak ayrıştırılabilir verilerin sınıflandırılması için tasarlanmıştır. Bununla birlikte, doğrusal olmayan ayrıştırılabilir karmaşık verilerin sınıflandırılmasında da kullanılmaktadır. Bu amaç için verilerin öncelikle doğrusal olarak ayrılabilir olması beklenen bir çekirdek fonksiyonu uygulayarak daha yüksek boyutlu bir özellik uzayına dönüştürülmesi gereklidir. Başka bir deyişle, doğrusal olmayan ayrılabilir problem, doğrusal olarak ayrılabilir bir probleme dönüştürülerek basitleştirilmelidir. Bu çalışmada verilerin daha yüksek boyutlu bir özellik uzayına dönüştürülmesi için radyal temel fonksiyonu kullanılmıştır. RBF çekirdeği olan SVM sınıflandırıcı, iki parametre gerektirir: bir grid arama yöntemi uygulayarak elde edilen maliyet (C) ve çekirdek parametresi (γ).

Benzer şekilde, YSA için çok katmanlı ileri beslemeli ağ yapısı kullanılmıştır. Ağın parametreleri momentum ve öğrenme oranıdır. Her parametre için grid araması

yöntemi uygulanmıştır. Literatürde için çok katmanlı ileri beslemeli ağ parametrelerinin deneysel olarak belirlenmesi önerilmiştir. Çalışmada yineleme sayısı 1000'e, gizli tabakaların sayısı 1 ve aktivasyon fonksiyonu olarak log-sigmoid seçilmiştir.

RF sınıflandırıcı için karar ağaçları sayısı (NT) ve kullanılacak prediktör sayısı olmak üzere iki parametre tanımlanmıştır: Bu iki parametre de deneysel olarak belirlenmiştir.



SONUÇ VE ÖNERİLER


Bu bölümde , önerilen yöntem ile yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçesi çıkartılmasına ilişkin elde edilen sonuçlar ve doğruluk analizi sonuçları değerlendirilmiştir. Tez kapsamında, makine öğrenme temelli üç temel sınıflandırıcı (SVM, ANN ve RF) görüntü sınıflandırma problemlerindeki başarıları dolayısıyla seçilmiştir. Bu bölümde her bir sınıflandırıcı için eğitim verisi seçimi süreci ve her bir sınıflandırıcıdan elde edilen sonuçların bütünleştirilmesinde kullanılan oylama yaklaşımı sonuçlarına ilişkin değerlendirmelere yer verilmiş ve bölüm sonunda doğruluk analizi sonuçları ilişkin ayrıntılar verilmiştir.

4.1 Eğitim Verilerinin Hazırlanması

Eğitim örnekleri hem çay bahçesi hem de diğer ağaç sınıfları için eğitim verisi amaçlı kullanılan görüntülerin içinden seçilmiştir. Çay bahçelerinin homojen spektral özellikler göstermesine karşın, diğer ağaç türlerinin değişen spektral ve dokusal özelliklere sahip olduğu belirlenmiştir. Bu nedenle, çay bahçeleri ile karşılaştırıldığında kullanılan veri kümesinde mevcut olan tüm ağaç türlerini seçmek daha uzun bir zaman almıştır. Mean-Shift algoritması uygulanarak elde edilen bölütlenmiş nesneler kullanılarak eğitim veri seti oluşturulmuştur. Dolayısı ile piksel tabanlı değil, obje tabanlı bir yaklaşım uygulanmıştır.

Sunulan tez çalışmasında toplam 25 ortofoto görüntünün 15' i eğitim verilerinin seçilmesi amacıyla kullanılmıştır. Dolayısı ile kullanılan toplam görüntünün %60' ı eğitim veri seti elde edilmesinde kullanılmıştır. Bu çalışmada analiz ve değerlendirme için toplam 25 görüntü kullanılmıştır. Doğruluk analizi eğitim verisi seçiminde

kullanılmayan 10 görüntüden elde edilen sonuçlar kullanılarak yapılmıştır. Eğitim verilerinin doğru ve hedeflenen sınıfı tam anlamı ile tanımlayacak şekilde seçilmesi sınıflandırma doğrulunda önemli bir rol oynar. Bu nedenle, eğitim örnekleri görüntülerden dikkatlice seçilmiştir. Şekil 4.1 çay bahçesi ve diğer ağaçlar için seçilen bazı örnekleri göstermektedir.




Şekil 4.1 Her bir sınıf için seçilen örnek eğitim verileri (a) çay bahçeleri (b) diğer ağaçlar


Her bir sınıf için özellikler (önceki bölümde tarif edilmiştir) elde edilmiş ve her bir vektöre karşılık gelen etiketleri işaretlenmiştir. N etiketli k -boyutlu özellikler göz önüne alındığında, eğitim veri kümesi oluşturulurken, her özellik vektörüne karşılık gelen etiket (X_i, Y_i) işaretlenmiştir. Burada $(X_i, Y_i) \in [-1, +1]$. Bu çalışmada, diğer ağaç

türleri -1 olarak etiketlenmiş, çay bahçeleri ise +1 olarak etiketlenmiştir. Böylelikle Y' de tanımlanan etiketlere bağlı olarak sınıflandırma işlemleri gerçekleştirilmiştir.

Sunulan tez çalışmasında dört bantlı ortofoto görüntülerden bitki indeksi bandı üretilerek çoklu sınıf problemi çay bahçeleri ve diğer ağaçlar olmak üzere ikili sınıf problemine indirgenmiştir. Burada NDVI profili, bitki örtüsü olmayan alanları çıkarmak için maske olarak kullanılmıştır. Tez çalışmasında sadece çay bahçelerinin ortofoto görüntülerden çıkartılması problemine odaklanılmıştır. Dolayısı ile bitkisel alanların dışındaki verilerin elimine edilmesi NDVI profili ile olanaklı olmuştur. Buna ek olarak ikinci olarak, denetimli sınıflandırma açısından bakıldığında, sınıflandırıcıları eğitmek için tüm ilgi alanlarını tanımlamak önemlidir. Bu çalışmada, bitki örtüsü olmayan alanlar dikkate alınmadığından, sadece çay bahçeleri ve diğer ağaç türleri için yeşil alanlardan eğitim örnekleri seçilmiştir. Bu yaklaşım sadece eğitim verisi seçimini azaltmakla kalmayıp, aynı zamanda işlem süresini de azaltmıştır.

NDVI girdi görüntülerde insan yapısı objelerin elenmesi amacıyla maske olarak kullanılmıştır. İnsan yapısı objelere ilişkin piksel NDVI değerleri sıfır olarak belirlenmiştir. Şekil 4.2, bitki örtüsü olmayan alanları çıkarmak için NDVI maskesini ve giriş görüntüsündeki uygulamasını göstermektedir.





(c)


Şekil 4.2 Bitki örtüsü olmayan alanları elimine etmek için NDVI maskesi uygulaması
(a) Girdi görüntü (b) NDVI maskesi (c) Girdi görüntüde maske uygulaması

Kullanılan görüntülerin hemen tümünde mevcut alanların çoğunda yoğunlukla çay bahçeleri bulunduğundan, çay bahçeleri için nispeten daha yüksek sayıda örnek seçilmiştir. Çay bahçesi alanlarından 1420 (~ 57%), diğer ağaç türleri için 1070 (~% 43) olmak üzere toplam 2490 nesne seçilmiştir. Çizelge 4.1, deneylerde kullanılan eğitim ve test örneğinin istatistiklerini özetlemektedir.


Çizelge 4.1 Eğitim ve test verisi istatistikleri

S.No.	Sınıflar	Eğitim verisi sayısı	Test verisi
1	Çay bahçesi	1,420	Eğitim verisi dışındaki tüm objeler
2	Diğer ağaçlar	1,070	Eğitim verisi dışındaki tüm objeler


Şekil 4.3' te özellik çıkarma için eğitim örneklerinin seçimi gösterilmiştir. Yeşil ve kırmızı çokgenler, bölütlenmiş görüntüden seçilen çay bahçesi ve diğer ağaç örneklerini temsil etmektedir. Her bir poligondan bir dizi spektral ve dokusal özellikler türetilmiş ve her bir sınıf için karşılık gelen etiketler, daha sonra eğitim amaçlı, sınıflandırıcı tarafından kullanılmak üzere bir metin belgesine atanmıştır. Şekil 4.3 (d)' de örnek bir dosya verilmiştir. Özellik vektörleri örnek satır biçiminde yazılmıştır, bu da dosyadaki her satırın giriş görüntülerinde çokgenlere karşılık geldiği anlamına gelir. Eğitim örnekleri için, farklı görüntülerden elde edilen ve çıkartılan özellikler tek bir metin dosyasına yazılmıştır. Ancak, test amacıyla, her bir görüntü için ayrı dosyalar oluşturulmuştur.



(a)



(b)



(c)

+1,96.83,113.99,102.02,150.04,4.176,3.838,3.709,4.922,0.354,8.603,2.113
+1,94.02,106.59,93.74,137.38,4.677,3.69,4.581,5.635,0.2956,13.86,2.724,
+1,96.63,108.82,94.05,150.22,4.68,4.325,4.595,4.162,0.2861,15.47,2.849,
+1,93.72,105.87,91.22,142.86,6.884,5.681,6.857,5.605,0.2643,27.41,3.478
+1,85.8,99.6,85.39,146.58,4.907,4.32,5.569,5.276,0.2516,21.25,3.284,5.3
+1,94.46,106.95,88.3,150.65,6.647,5.601,7.843,5.848,0.2162,41.98,4.565,
+1,84.5,93.86,79.17,132.26,3.189,3.178,3.967,4.019,0.3544,8.492,2.122,4
+1,53.66,63.47,51.81,108.82,15.39,14.68,18.07,9.8,0.07129,262.49,12.93,
+1,84.45,96.64,74.5,140.38,5.146,4.376,6.433,6.84,0.2523,20.65,3.312,5
+1,87.02,95.98,77.62,137.77,4.742,4.737,6.31,4.282,0.262,20.01,3.137,5
-1,91.6,101.43,101.15,108.9,10.29,8.935,10.32,8.189,0.1806,34.48,4.554,
-1,92.84,97.02,98.73,114.64,10.79,9.536,10.68,12.84,0.1477,77.5,6.49,7
-1,90.34,87.8,88.75,85.46,14.39,12.53,11.71,14,0.1278,69.45,6.538,7.258
-1,103.29,112.36,105.78,118.2,11.44,9.637,11.3,9.112,0.1658,41.82,5.02,
-1,83.08,88.26,90.62,90.23,11.27,10.94,11.27,10.56,0.1395,53.96,5.826,7
-1,82.62,92.5,83.9,110.82,13.62,12.14,15.56,12.27,0.1338,76.67,6.587,7
-1,80.48,90.09,90.84,111.77,12.88,11.18,12.72,12.5,0.1157,89.7,7.42,7.3
-1,89.83,95.69,97.16,104.38,11.18,9.866,10.61,9.64,0.1594,47.55,5.309,6
-1,87.27,95.68,93.9,107.2,12.18,10.07,10.89,12.33,0.1673,44.17,5.061,6

+1 Çay Bahçesi -1 Diğer Ağaçlar

(d)

Şekil 4.3 Eğitim verisi seçim örnekleri (a) Girdi görüntü (b) Bölütlenmiş görüntü (c) referans ikili görüntü (d) eğitim verilerinden türetilen son özellik vektörleri. -1 diğer ağaçları, +1 çay bahçelerini temsil eder.

4.2 Sınıflandırıcı Konfigürasyonları


Denetimli sınıflandırma paradigmasında, sınıflandırıcı, yüksek sınıflandırma doğruluğunun elde edilmesinde anahtar rol oynayan bazı dış ve iç parametrelere bağlıdır. Bu nedenle, her bir sınıflandırıcı için en uygun parametre değerlerinin elde edilmesi çok önemlidir. Her bir sınıflandırıcı için parametreler, eğitim örnekleri kullanılarak elde edilmiştir. Ayrıca, eğitim verisinin %15' i doğrulama ve %85' i sınıflandırma parametrelerinin hassas bir şekilde belirlenmesi için kullanılmıştır. Kullanılan denetimli sınıflandırıcılar birbirinden bağımsızdır, bu nedenle, her bir sınıflandırıcı için optimal değerler elde etmek için ayrı deneyler gerçekleştirilmiştir. Aşağıdaki bölümlerde, her bir sınıflandırıcı için yapılandırma ayarlarını açıklanmıştır.

4.2.1 SVM Konfigürasyonu

Sunulan tez çalışmasında SVM için Radyal temel fonksiyonu (Radial Base Function-RBF) çekirdeği seçilmiştir. Bir çok araştırmada, uzaktan algılama verilerinde SVM sınıflandırıcı için RBF çekirdeği kullanılarak iyi sınıflandırma sonuçlarının elde edildiğini gösterilmiştir [110]. SVM için iki parametrenin belirlenmesi gerekmektedir. Bunlar: (i) SVM için maliyet (C) ve (ii) RBF çekirdeği için gamma (γ) değerleridir. Bu parametreler, kapsamlı grid araştırması ve için on kat çapraz doğrulama (ten-fold cross validation) uygulanarak elde belirlenmiştir. Eğitim verisinde en yüksek sınıflandırma doğruluğunu rapor eden parametreler, test verilerini sınıflandırmak için son değerler olarak seçilmiştir. Her parametre için arama aralığı $\gamma = \{e^{-5}, e^{-4}, e^{-3} \dots e^3\}$ ve $C = \{e^{-3}, e^{-2}, e^{-1} \dots e^8\}$ olarak tanımlanmıştır. Çizelge 4.2' de arama için tanımlanan parametrelerin aralığını ve bu aralığa karşılık gelen optimal değerlerin özeti verilmiştir. Ayrıca, Şekil 4.4' te her bir C ve γ çifti için elde edilen parametre aralığı aramasının görsel bir temsili ve karşılık gelen doğruluklar gösterilmektedir.

Çizelge 4.2 SVM ve RBF çekirdek parametreleri

Parametre	Minimum	Maksimum	Optimal Değerler
Gamma (γ)	0.0067	20.0855	0.04978
Cost (C)	0.0498	2.9810e+03	50.0067



Şekil 4.4 RBF çekirdeği ile SVM için elde edilen optimal parametrelerin görsel temsili


4.2.2 Yapay Sinir Ağları (YSA) Konfigürasyonu

YSA'nın en yaygın kullanılan mimarisi olan çok katmanlı geriye yayılma (multilayer perceptron-MLP), birçok farklı parametreye gereksinim duyar. Bunlardan en temel iki parametre olan öğrenme oranı ve momentum grid arama ile belirlenir. Sunulan tez çalışmasında optimum öğrenme oranı parametresi için 0.001 ile 0.5 aralığı , momentum ise 0 ile 0.9 aralığı belirlenmiştir. Elde edilen optimal değerler sırasıyla öğrenme oranı ve momentum için 0,1 ve 0,8'dir. Topolojik parametreler olarak da bilinen MLP için diğer parametreler, genellikle veri bağımlı olmadıkları için tüm deneyler için sabit olarak seçilmiştir. İterasyon sayısı 1000 olarak seçilmiştir. Yapılan deneyler, modelin eğitim sürecinde belirlenen iterasyon sayısı sınırına ulaşılmadan eğitimin sonlandığı gözlenmiştir. Ek olarak, log-sigmoid fonksiyonu aktivasyon fonksiyonu olarak seçilmiştir. Gizli katmanların sayısının artırılması, sınıflandırma doğruluğunda önemli bir gelişme olmaksızın işlem süresini arttırmıştır. Bu nedenle 200 nöronlu sadece bir gizli katman kullanılmıştır. Gizli katmandaki nöronların sayısı da deneysel olarak belirlenmiştir. Benzer şekilde, giriş katmanındaki nöronların sayısı tez kapsamında belirlenen özellik sayısına (17) göre belirlenirken, çıkış nöronlarının sayısı 2 (çıkış sınıflarının sayısına göre) olarak seçilmiştir. Çizelge 4.3' de YSA sınıflandırıcı için parametre seçimleri özetlenmiştir.


Çizelge 4.3 YSA parametreleri

Parametre	Minimum	Maksimum	Optimal Değerler
Öğrenme Düzeyi	0.001	0.5	0.1
Momentum	0.1	0.9	0.8
Gizli Katmanlar	-		1
Gizli Nöronlar	-		200
Girdi Nöronlar	-		17
Çıktı Nöronlar	-		2
Aktivasyon Fonksiyonu	-		Sigmoid
İterasyon Sayısı	-		1000

Şekil 4.5 ve 4.6, MLP mimarisi için öğrenme oranı ve momentum için elde edilen doğruluğu göstermektedir. Şekil 4.5’ ten öğrenme hızı parametresinin 0.1'e kadar olan değerler için daha yüksek sınıflandırma doğruluğu ürettiği görülmektedir. Bu değer arttıkça, sınıflandırıcının doğruluğu yavaş yavaş azalmaya başlamıştır. Benzer şekilde, Şekil 64.6’ da görüleceği üzere, 0.2 civarında momentum değerlerinin çok marjinal sonuçlar verdiği, 0.3'ün ötesindeki değerlerin tutarlı hale geldiği görülmektedir. Bu çalışmada kullanılan veri setinde maksimum doğruluk sağlandığı için 0.8 değeri seçilmiştir.



Şekil 4.5 MLP için öğrenme doğruluğu (LR) ve genel doğruluk




Şekil 4.6 MLP için Momentum vs Genel Doğruluk

4.2.3 Rastgele Ağaçlar (Random Forest-RF) Konfigürasyonu


RF sınıflandırıcı da tahmin edicilerin (NP) sayısı ve rastgele ağaçların sayısı (NT) olmak üzere iki parametrenin belirlenmesini gerektirmektedir. Literatür taraması, girdi değişkenlerinin kareköküne eşit bir NP değeri seçiminin optimal sonuç verdiğini göstermiştir [11]. Bu nedenle, minimum ve maksimum arama aralığı sırasıyla 1 ve 5 olarak tanımlanmıştır. Ağaç sayısının artırılmasının sınıflandırıcıyı eğitmek için daha fazla zaman gerektirdiğinden [26]. Bu değer (NT) 50 ile 2000 arasında belirlenmiştir. Sunulan çalışmada NP için 2 ve NT için 200 değerleri belirlenmiştir. Çizelge 4.4' de her parametre için elde edilen arama aralığını ve optimal değerler özetlenmiştir. Şekil 4.7' de RF için farklı ağaç sayısı için elde edilen genel doğruluk verilmiştir. Benzer şekilde, Şekil 4.8' de çay bahçelerini diğer ağaçlardan ayrılmasında özelliklerin önemini göstermektedir. Şekilden 16 numaralı özellik olan korelasyon dokusu özelliğinin (correlation texture feature) diğer özelliklere göre daha belirleyici olduğu görülmektedir.

Çizelge 4.4 RF parametreleri için grid arama sonuçları

Parametre	Minimum	Maksimum	Optimal Değerler
NP	1	5	2
NT	50	2000	200



Şekil 4.7 NT için RF genel doğruluk



Şekil 4.8 RF sınıflandırıcı için özelliğin önemi

4.3 Sınıflandırıcıların Eğitimi

Parametrelerin her sınıflandırıcı için hesaplanmasının ardından ikinci aşama sınıflandırıcıların eğitimi olmuştur. Bir sınıflandırıcının eğitimi kapsamlı bir süreç olup oldukça uzun bir zaman gerektirmektedir. İşlem süresi, hem örnek sayısına hem de veri boyutuna bağlıdır.

Özelliklerin ölçeklendirilmesi, değerlerinde bir değişiklik olması nedeniyle, bir özelliğin bir başkasının baskınlığını azaltmak için iyi bir uygulama olduğundan, tüm özellik

vektörleri, min-max ölçekleme yöntemi kullanılarak ölçeklendirilmiştir. Eğitilen model daha sonra kaydedilerek test verilerine uygulanmıştır.

İdeal olarak, sınıflandırıcıyı eğitmek için dengeli bir eğitim verisi gereklidir. Yani her bir sınıf için seçilen eğitim verisi miktarı görüntüde kapladıkları alanla orantılı olmalıdır. Daha önce de belirtildiği gibi, çay bahçesi için toplanan eğitim örnekleri, görüntüdeki çay bahçelerinin daha geniş alanı kapsaması nedeniyle diğer ağaç türlerinden daha fazladır. Fakat her bir sınıfa ait eğitim miktarları kapladıkları alan göz önünde bulundurulduğunda orantılıdır. Yapılan çalışmalar, makine öğrenim yaklaşımlarının, diğer sınıflandırıcı türlerine göre hem teorik hem de pratik avantajlara sahip olduğunu gösterse de, dengesiz bir veri kümesi kullanıldığında optimal sonuçlar üretmektedir [70], [109]. Sunulan tez çalışmasında bu sorunun üstesinden gelmek amacı ile veri grupları ağırlıklandırılmıştır. Azınlık sınıfına (diğer ağaçlar) çoğunluk sınıfına (çay bahçesi) kıyasla nispeten daha fazla ağırlık verilmiştir.

4.4 Sınıflandırma ve Doğruluk Analizi

Sınıflandırıcılar eğitildikten sonra, test özellik vektörleri her bir sınıflandırıcıya girdi verisi olarak kullanılmıştır. Sınıflandırıcılar, her özellik vektörü için bir etiket (+1 veya -1) üretmiştir. Her bir sınıflandırıcıdan elde edilen sonuçları entegre etmek için maksimum oylama kullanılmıştır. Örneğin bir nesnenin (bölütün) bir çay bahçesi olarak kabul edilebilmesi için en az iki sınıflandırıcı tarafından çay bahçesi (+1) olarak oylanmış olması gerekmektedir. Aksi takdirde söz konusu nesne diğer ağaç nesnesi (-1) olarak kabul edilir.

Sınıflandırıcı kombinasyonundan elde edilen sonuç, çay bahçesine veya diğer tipteki ağaçlara karşılık gelen +1 veya -1 tahmin edilen etiketinden oluşan tek bir vektör olarak elde edilmiştir. Bununla birlikte, fotogrametrik olarak üretilen referans veriler vektör format yapısına sahipti. Doğruluk analizi amacı ile bu veriler ikili görüntü formatına dönüştürülmüştür. Elde edilen her bir bölüte bir nesne numarası (ID) atandığından sınıflandırma etiketleri kullanılarak, çay bahçeleri için sonuç ikili görüntü elde edilmiştir. Böylelikle doğruluk analizi yapılabilmektedir.

Doğruluk analizinin gerçekleştirilebilmesi için aşağıdaki metrikler kullanılmıştır [111]. Gerçek pozitif (true positives (TP)), yanlış pozitif (false positive (FP)), yanlış negatif (false negatives (FN)) ve doğru negatif (true negatives (TN)). Böylelikle hassasiyet.

Bu parametreler kullanılarak hassasiyet (precision), kesinlik (recall) a, f ölçüsü (f-measure) ve genel doğruluk hesaplanabilmektedir.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4.1)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4.2)$$

$$f - \text{Measure} = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (4.3)$$

$$\text{Overall Accuracy} = \frac{(TP + TN)}{N} \quad (4.4)$$

Yukarıdaki formüllerde N görüntüdeki toplam obje sayısını ifade etmektedir.

Çizelge 4.5' te önerilen yaklaşım ve her bir sınıflandırıcı için (SVM, YSA ve RF) yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçesi çıkartımı için elde edilen doğruluk analizi sonuçları özetlenmiştir. 25 ortofoto görüntüden oluşan kullanılmış veri seti için önerilen yöntem ile her bir sınıflandırıcıdan elde edilen sonuçlar karşılaştırıldığında, önerilen yöntem ile en yüksek doğruluk değerleri elde edildiği görülmektedir. Önerilen yöntem ile genel doğruluk % 89,52, hassasiyet % 88.42, kesinlik % 89.86 ve f ölçüsü % 89.09 oranlarında gerçekleşmiştir. Önerilen çoklu sınıflandırıcı yönteminin her bir sınıflandırıcıya göre genel doğrulukta yaklaşık % 4.5 bir iyileşme sağlandığı görülmüştür.

Her bir sınıflandırıcı için elde edilen sınıflandırılma doğrulukları da literatür ile uyumludur [26], [43]. Her bir sınıflandırıcı göz önünde bulundurularak doğruluk analizi sonuçları irdelendiğinde; YSA sınıflandırıcısının genel doğruluğunun SVM ve RF sınıflandırıcılarına göre % 87.02 ile daha yüksek doğruluğa sahip olduğu görülmüştür. Bunu % 86.19 ile SVM takip etmiştir. YSA ve SVM için f ölçüsü sırası ile % 87.36 ve % 87.26 olarak hesaplanmıştır. Öte yandan, RF sınıflandırıcısının doğruluğu % 85.02 ile diğer iki sınıflandırıcıya kıyasla en düşük oranda kalmıştır. Bununla birlikte, RF'nin

önerilen yöntemde çoklu sınıflandırıcı sistemin bir bileşeni olarak, önerilen yöntemin doğruluğun artışında etkisi olduğu düşünülmektedir.

Çizelge 4.5 Doğruluk Analizi Sonuçları

Method	Hassasiyet	Kesinlik	f-Ölçüsü	Genel Doğruluk
SVM	86.39	88.25	87.26	86.19
ANN	87.86	86.96	87.36	87.02
RF	85.92	86.77	86.31	85.02
Önerilen Yöntem	88.42	89.86	89.09	89.52


Şekil 4.9' te verilen örnek görüntü, otomatik çay bahçesi bölütlenmesine ilişkin elde edilen sonuç verilmiştir. Burada (a) ve (b) sırasıyla girdi görüntüsünü ve referans verilerini gösterir. (c), (d), (e) ve (f) sırasıyla SVM, YSA, RF ve önerilen çoklu sınıflandırıcı kombinasyonu için elde edilen sonuçları göstermektedir. Benzer şekilde, (g) girdi görüntünün üzerine yerleştirilmiş fotogrametrik yöntemle sayısallaştırılmış ver referans olarak kullanılan veri ve (h), girdi görüntüsü üzerine çakıştırılmış, önerilen yöntem ile elde edilen sonuçları göstermektedir. Ayrıca, Ek-A' da ve Ek-B' de kullanılan tüm görüntüler ve önerilen yöntemin kullanılan tüm görüntülere uygulanması ile elde edilen sonuçlar verilmiştir.



(a) Görünür bölgede örnek ortofoto görüntü




(b) Çay bahçelerinin fotogrametrik yöntemle sayısallaştırıldığı referans veri



(c) SVM sınıflandırma sonuçları



(d) YSA sınıflandırma sonuçları



(e) RF sınıflandırma sonuçları



(f) Önerilen yöntemle elde edilen sonuçlar



(g) Referans veri ile original görüntünün
çakıştırılması



(h) Önerilen yöntem ile elde edilen
sonuçların original görüntü ile çakıştırılması.


Şekil 4.9 Sınıflandırma sonuçlarının bir görüntü örneğinde gösterimi

Orijinal ortofoto görüntüler ve fotogrametrik sayısallaştırma sonuçları incelediğinde, toplanmış çay alanlarının da fotogrametri operatörü tarafından çay bahçesi olarak sayısallaştırıldığı görülmüştür (Şekil 4.10-a,b). Oysa sunulan tez çalışmasında sadece toplanmamış çay alanlarına odaklanılmıştır. Şekil 4.10-b' de, fotogrametrik olarak sayısallaştırılan referans veride, Şekil 4.10,a' da toplanmış çay alanlarının da çay alanı olarak içerildiği görülmektedir. Fotogrametri operatörleri sahaya hakim oldukları için bunu bilinçli olarak yapmışlardır.

Aşağıdada belirtildiği gibi, sunulan tez çalışmasında toplanmış çay bahçeleri kapsam dışında bırakılmıştır. Kullanılan referans veride ise toplanmış çay bahçeleri de çay bahçesi sınıfında yer aldığı için bu durumun doğruluğu ne oranda etkilediğine ilişkin bir öngörü oluşturmak amacıyla sadece üç ortofoto görüntüde referans veriden toplanmış çay bahçeleri çıkartılarak doğruluk analizi tekrarlanmıştır. Bu işlem sonunda önerilen yöntemin söz konusu üç görüntü için doğruluğunda % 2.4'lük bir artış olduğu gözlenmiştir.



(a)



(b)

Şekil 4.10. (a) Orijinal görüntüde toplanmış çay alanları (b) referans veride toplanmış çay alanları

Çizelge 4.6' da önerilen yöntemin doğruluk analiz sonuçları verilmiştir. Elde edilen sonuçlar toplanmış çay bahçelerinin referans veride de çay bahçesi olarak yer aldığı durum için söz konusudur. Çizelge daki $\pm$ işareti ile belirlenen rakam üç ortofoto için yapılan deney sonucunda, referans veriden toplanmış çay bahçelerinin çıkartılması durumunda doğruluğun artış oranını temsil etmektedir.

Çizelge 4.6 Önerilen yöntemin doğruluğu (%).

Method	Precision	Recall	f-Measure	Overall Accuracy
Proposed	88.42±2.4	89.86±2.4	89.09±2.4	89.52±2.4

Sonuç olarak, sunulan tez çalışmasında, nesne tabanlı görüntü analizi yönteminin, çoklu sınıflandırıcı kombinasyonu ile entegrasyonunun, yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçesi çıkartılması için kullanılan sınıflandırıcıların sınıflandırıcısının tekil performansına kıyasla yaklaşık% 2.5-% 4.5 daha yüksek genel sınıflandırma doğruluğu ürettiği gözlenmiştir.


4.5 Parametre Duyarlılık Analizi

Daha önce de belirtildiği gibi, tez çalışmasında kullanılan sınıflandırıcıların (SVM, YSA, RF) sınıflandırma doğrulukları bazı iç ve dış parametrelere bağlıdır. İçsel parametrelerin sınıflandırıcılar üzerindeki etkisinin analizi Bölüm 4.3' te kullanılan eğitim ve doğrulama veri seti kapsamında açıklanmıştır. Sınıflandırıcıların sınıflandırma doğruluğunu ciddi biçimde etkileyen bir dış faktör de eğitim örneklerinin büyüklüğüdür. Sınıflandırıcıları eğitmek için uygun miktarda eğitim verisi seçimi, sınıflandırıcıların genelleme yeteneğini geliştirmenin yanı sıra, yetersiz veya aşırı uyumsuzluk sorunlarından kaçınmak için önemlidir. Bu nedenle, eğitim örneklem büyüklüğünün sınıflandırıcılar için sınıflandırma doğruluğu üzerindeki etkisini analiz etmek için farklı deneyler gerçekleştirilmiştir.

4.5.1 Örneklem Eğitim Verisi Seçimi

Çay alanları ve diğer ağaç türleri için eğitim örneklem büyüklüğü 25 ile 500 arasında değişmektedir. Şekil 4.11'de görüldüğü gibi, kullanılan her bir sınıflandırıcının genel davranışı seçilen eğitim verisi sayısı açısından aynı kalmıştır. Örneklem sayısının nispeten küçük bir miktarı (<100) için, tüm sınıflandırıcılar için doğruluk düşük kalmıştır. Bununla birlikte, her bir sınıf için 100 örnekten daha fazla eğitim verisi seçilmesi durumunda sınıflandırma doğruluğu önemli ölçüde artmıştır.

Şekilden RF yönteminin doğruluğunun eğitim verisi sayısından çok büyük oranda etkilendiği görülmektedir. Şekil 4.8'de gösterildiği gibi, 25 örnek için bile % 74.23 oranında ve 100 örnek için % 89.52 genel doğruluk elde edilmiştir. Bu, RF yönteminin eğitim örneği boyutuna daha az duyarlı olduğunu göstermektedir. Ayrıca, RF yönteminde çok sayıda karar ağacı olduğundan, makina öğrenme temelli yöntemlerde en önemli sorunlardan biri olan ezberleme (overfitting) problem riskinin indirildiği anlamına gelir. YSA'nın eğitim örneklerinin miktarı duyarlılığı yüksektir. Şekil 4.11' den de görüleceği üzere, 25 eğitim verisi için en düşük genel doğruluk elde edilirken (% 35.60), eğitim verisi sayısının artırılmasıyla daha iyi sonuçlar elde edilmeye başlanmıştır. 200 den daha fazla eğitim verisi için tüm sınıflandırıcıların genel doğruluğu neredeyse sabit kalmıştır. Bu nedenle, sunulan tez çalışmasında, bu örneklem büyüklüğü örneklem seçimi için eşik olarak kabul edilmiştir.



Şekil 4.11 Eğitim verisi büyüklüğünün, her bir sınıflandırıcı ve önerilen yöntemin sınıflandırma doğruluğuna etkisinin analizi

4.5.2 Mean-Shift Yönteminin Analizi

Bir bölütleme yönteminin doğruluğunu ölçmek için standart bir yaklaşım olmamakla birlikte [112], sunulan tez çalışmasında, bölütlemenin önerilen yöntemin sınıflandırma doğruluğuna etkisini belirlemeye yönelik Mean-Shift yöntemindeki bant genişliği

parametresi kullanılmıştır. Tez çalışmasında görüntüler öncelikle Mean-Shift yöntemi ile bölütlenmiş, eğitim verileri piksel bazlı değil nesne bazlı olarak seçilmiştir. Dolayısı ile bant genişliği parametresinin değişimi bölütlemeye doğrudan etkilediğinden, bu parametrenin değişimine bağlı olarak sınıflandırma doğruluğundaki değişim analizi alan bazlı bir yaklaşım kullanılarak gerçekleştirilmiştir.


Bant genişliği seçiminin etkisini test etmek için farklı bant genişliği parametreleri (h_s, h_r) seçilerek bölütleme işlemi gerçekleştirilmiştir. Her bir parametre için $h_r = \{(5,5), (5,9), (5,15), (5,30)\}$ ve $h_s = \{(5,5), (9,5), (15,5), (30,5)\}$ aralıkları belirlenmiştir. Şekil 4.12' de elde edilen sonuçlara ilişkin grafik verilmiştir.

Sonuçlar, h_s 'nin bölütlemeye etkisinin h_r ye göre daha az olduğu, dolayısı ile sınıflandırma doğruluğu üzerinde daha az etkiye sahip olduğunu göstermektedir. Bununla birlikte, h_r parametresi her farklı parametreler için farklı sonuçlar üretmiştir. Dolayısı ile bölütlemeye etkisinin çok olduğu gözlemlenmiştir. Daha büyük değerler için bölütlerin büyüdüğü ve farklı özellikteki arazi özelliklerinin bir bölüt içinde birleştirildiği görülmüştür. Bu da karışık sınıflandırmaya neden olmuştur. Örneğin h_r nin 30 olarak alınması durumunda sınıflandırma % 52 olarak gerçekleşmiştir. Bu nedenle, 30'dan daha büyük değerler için hiçbir deney yapılmamıştır. Çalışmada işlem süresini azaltmak için h_s nin alabileceği en küçük değer 5 olması gerektiği görülmüştür. Bu değer doğruluğu etkilemediği görülmüştür.

Emgu CV kütüphanesinin Mean-Shift bölütleme işlemi için gerektirdiği diğer iki parametre iterasyon sayısı ve bölüt büyüklüğüdür. İterasyon sayısının bölütleme üzerine çok az etkisi olduğu belirlenmiş ve optimum değer olan 10 iterasyon deneysel olarak seçilmiştir. Benzer şekilde, bölüt boyutu da mümkün olduğunca fazla nesne elde edebilmek için yapılan deneyler sonucunda 50 olarak belirlenmiştir. Algoritma seçilen bölüt büyüklüğü parametresine bağlı olarak belirlenen bölüt boyutunun altındaki değerlere sahip bölütleri en yakın büyük bölütlerle birleştirir.

Sonuç olarak, sunulan tez çalışmasında, önerilen nesne tabanlı, çoklu sınıflandırıcı yönteminin yüksek çözünürlüklü dijital ortofoto haritalarından bitki örtüsü bilgilerinin sınıflandırılmasında etkin olarak kullanılabileceği görülmüştür. Tez çalışmaları kapsamında çay alanları otomatik olarak çıkartılmıştır. Girdi görüntüleri ilk önce

Gaussian filtre ile düzeltilmiş ve daha sonra Mean-Shift yöntemiyle bölütlenmiştir. Her bölüt için özellikler (spektral, mekansal ve doku) çıkarılmıştır. JM mesafe ile sıralı besleme ileri seçimi (sequential feed forward selection) ölçütleri optimal bir özellik kümesi elde etmek için kullanılmıştır. En yaygın olarak kullanılan üç makine öğrenme temelli sınıflandırıcı (SVM, RF ve ANN) kullanılarak sonuç sınıflandırma, her bir sınıflandırıcıdan elde edilen değerlere maksimum oylama yöntemi uygulanarak uygulanarak elde edilmiştir. Önerilen yöntemin doğruluk analizi için fotogrametrik yöntemle üretilen çay alanları referans veri olarak kullanılmış ve doğruluk analizi alan bazlı yapılmıştır.



Şekil 4.12 Bant genişliği parametresinin önerilen yöntemin sınıflandırma doğruluğuna etkisi

Önerilen yöntem ile tez çalışmasında kullanılan her bir makine öğrenme temelli sınıflandırıcıya oranla daha yüksek doğrulukta sonuçlar üretmiştir. Ancak, yöntemin doğruluğu kullanılan sınıflandırıcıların performanslarına bağlıdır. Ancak, çoklu sınıflandırma yaklaşımı ile her bir sınıflandırıcının zayıf yönleri elimine edildiği alternatif bir yöntem önerilmiştir.

TARTIŞMA VE SONUÇLAR

5.1 Giriş

Son yıllarda uzaktan algılama verilerinden ağaç türlerinin sınıflandırılması çalışmalarında çok fazla ilerleme kaydedilmiştir. Bu durum, daha küçük objelerin ayırt edilebilmesine olanak sağlayan yüksek çözünürlüklü algılayıcıların geliştirilmesiyle ilişkilendirilebilir. Yeryüzündeki elektromanyetik ışınım ve objeler arasında, özellikle de ağaç türleri arasındaki etkileşimler o kadar karmaşıktır ki, bu durum kapsamlı araştırmaların en önemli konularından birisidir. Sunulan tez çalışması, uçak üzerindeki bir algılayıcıdan (Ultracam-X) elde edilen yüksek çözünürlüklü dijital ortofoto haritalardan çay bahçelerinin çıkarılmasına odaklanmıştır.

Bölüm 2'de ortaya konan teorik temeller, makine öğrenme yaklaşımlarının, yüksek çözünürlüklü uzaktan algılama verilerinin sınıflandırılması için ümit verici sonuçlar verdiğini göstermiştir. Bununla birlikte, tek bir sınıflandırıcının tüm özellik boyutlarında iyi bir şekilde eğitilemeyeceğine inanılmaktadır. Spektral imzalar birbirine yakın olabildiğinden dolayı sınıflandırıcıların farklı sınıfların özelliklerini öğrenmesi gerçekten zor bir görev haline gelmektedir. Sunulan tezin odak noktası olarak geliştirilen alternatif bir çözüm, tek tek sınıflandırıcıların sorunlarını çözmek için çok sayıda sınıflandırıcının birleştirilmesidir. Bu, aynı zamanda, bir sınıflandırıcının çıktısının diğer sınıflandırıcı çıktılarıyla karşılaştırıldığı ve nihai sonuçların tüm yöntemler tarafından maksimum oylama ile üretildiği bir doğrulama adımı olarak da kullanılmıştır. En az iki sınıflandırıcının elde edilen nesneyi çay bahçesi olarak kabuetmesi durumunda ilgili nesne çay bahçesi olarak sınıflandırılmıştır.

Bu çalışmada en yaygın olarak kullanılan üç adet denetimli öğrenme sınıflandırıcısı kullanılmıştır. Bunlar; destek vektör makinesi, yapay sinir ağları ve rastgele ağaçlar yöntemidir. Yöntemlerin seçimi için genel bir kural olmamakla birlikte, sınıflandırma doğruluğu yüksek olan yöntemler oldukça ilgi görmektedir. Ayrıca, farklı istatistiksel öğrenme gruplarından seçilen sınıflandırıcılar, özelliklerin çok farklı yollarla öğrenilmesini sağlamaktadır.

Bu bölüm, Bölüm 1'de belirtilen amaca ilişkin olarak elde edilen temel bulguları özetleyerek tez çalışmasını sonuçlandırmaktadır. Bu araştırmanın temel amacı, çeşitli istatistiksel öğrenme yöntemlerini bir obje tabanlı bölütleme tekniği ile birleştirilerek yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçelerinin çıkarılmasıdır.

Bu amaçlara ulaşmak için öncelikle bu araştırma için kullanılabilecek potansiyel yaklaşımları tanımlamak amacıyla ayrıntılı bir literatür araştırması yapılmıştır. Literatür çalışmasının sonucunda çoklu sınıflandırıcıların nesne tabanlı bir yaklaşımla bütünleştirilerek çay bahçelerinin çıkarılmasına odaklanmış hiçbir çalışma ile karşılaşmamıştır. Bu çalışmada, çay bahçelerinin tanımlanması için nesne tabanlı bölütleme yönteminin çoklu sınıflandırıcılarla birleştirilmesi yaklaşımına odaklanan yeni bir yöntem önerilmiştir.

5.2 Tezin katkıları ve Uygulamaları

Sunulan yöntemin, büyük ölçekli yüksek çözünürlüklü dijital ortofoto haritalarından ağaç türlerinin çıkarılması için kullanılabilirliği tez çalışmasında kanıtlanmıştır. Çeşitli istatistiksel öğrenme gruplarından çoklu sınıflandırıcıların birleştirilerek, çay bahçelerinin yüksek doğruluklu çıkartılması mümkün olmuştur. Tez çalışması ile hiper spektral verilere göre daha kısıtlı spektral çözünürlüğe sahip verilerin kullanımı ile de yüksek doğrulukta sonuçların elde edilebileceği görülmüştür. Ağaç türleri sınıflandırması için yapılan çalışmalar incelendiğinde, tez çalışmasında önerilen yöntem ve elde edilen sonuçların yüksek doğruluğa sahip olduğu görülmüştür. Elde edilen sonuçlar, çay bahçelerinin, çalışma alanından (Rize ili) elde edilen veri seti için 89 ± 3.0 yüksek bir genel doğrulukla çıkarılabileceğini göstermiştir.

Çay bahçesi çıkarımı için otomatik yöntem kullanmak hem maliyet hem de işlem süresi açısından ekonomiktir. Genellikle, tek bir ortofoto haritadan çay bahçelerinin sınırlarının bir fotogrametri uzmanı tarafından elle çizilmesi için en az sekiz saat gibi bir süre gerekmektedir. Bu işlem süresi, çay bahçelerinin 8 GB RAM ve 2.5 GHz'lik bir işlemci ile otomatik çıkartılması için gerekli zaman maksimum beş dakika olarak belirlenmiştir. Ayrıca, bu işlem süresi, kullanılan sistemin donanımına bağlı olarak daha da azaltılabilir. Örneğin, 32 GB RAM ve 3.0 GHz Dört Çekirdek bir sistemde işlem süresi 1,35 saniye olarak hesaplanmıştır.

Bu çalışma ortofoto görüntülerinden çay bahçesi çıkarımına odaklanmış olsa da, diğer ağaç türlerini sınıflandırmak için de kullanılabilir. Bu durumda, her sınıf için uygun eğitim örneklerinin çıkarılması ve sınıflandırıcıların eğitilmesi gerekir. Ayrıca kullanılan özellikler sınıfları ayırt etmek için, yüksek ayırım gücüne sahip olmalıdır. Aksi takdirde işlem daha yüksek oranda yanlış sınıflandırmayla sonuçlanabilir.

Hem tarım hem de ormancılıkla ilgili özel ve kamu kurumları, il, ilçe ve hatta ülke düzeyinde karar vermeye yönelik yönetsel süreçlerde bu çalışmada geliştirilen yöntemden yararlanabilirler. Çalışma alanı, ulusal düzeydeki orman veya tarım alanı ile karşılaştırıldığında küçük olmasına rağmen, diğer orman veya tarım alanları için de uygulanabileceğinden, önerilen yaklaşımın oldukça önemli bir katkı sağlayacağı açıktır.

Nesne tabanlı görüntü analizi, çay bahçelerinin sınıflandırılmasında hayati bir rol oynamıştır. İlk olarak, piksellerden çok nesnelere dayalı özelliklerin çıkarılmasıyla verilerin boyutunun azaltılmasına yardımcı olmuştur. İkincisi, sınıf içi benzerliklerin ve sınıflar arası varyasyonların çözülmesinde yardımcı olmuştur. Üçüncü olarak, yapısal ve doku özellikleri gibi piksel tabanlı yöntemler ile elde edilemeyen özelliklerin elde edilmesine yardımcı olmuştur. Nesne tabanlı yaklaşımın tüm bu özellikleri, tez çalışmasında kullanılan her bir sınıflandırıcı için artan genel bir sınıflandırma doğruluğu üretmiştir.

Tekil sınıflandırıcılar, uzaktan algılama verisinden elde edilen ağaç türlerini sınıflandırmak için yaygın olarak kullanılmıştır. Bununla birlikte, her bir yöntem çay bahçesi çıkarımı için iyi sonuçlar verebilse de, bir yöntemin bazı özellik alanlarında iyi performans gösterebileceği, ancak tüm özellik alanlarında en iyi sonuçlar

üretmeyebileceği de unutulmamalıdır. Tekil yöntemlerin bu dezavantajı farklı sınıflandırıcıların birleştirilerek kullanılmasıyla azaltılabilir. Bu yaklaşım, dijital ortofoto haritalarından çay bahçesi çıkarımı için genel sınıflandırma doğruluğunu artırmaya yardımcı olmuştur. Önerilen yöntem, geniş bir coğrafi alanda doğru ve güvenilir çay bahçesi bilgileri elde etmek için çok sayıda sınıflandırıcının birleştirilmesindeki başarıyı göstermiştir.

5.3 Gelecek Perspektifi

Sunulan tez çalışmasında, yüksek çözünürlüklü dijital ortofoto haritalarından çay bahçeleri elde etmek için nesne tabanlı bölütlemeye sahip çoklu sınıflandırıcıların bir kombinasyonu kullanılmış ve bu da önemli ölçüde iyileştirilmiş sınıflandırma doğruluğu ile sonuçlanmıştır. Edinilen tecrübeler gelecekteki araştırmalar için umut vericidir.

Mean-shift için bölütleme parametresi, sonuçların görsel olarak analizi yerine bir arama stratejisi uygulayarak otomatik olarak seçilebilir. Otomatik seçimle, manuel seçim yükünün azaltılabildiği diğer sınıflandırma problemleri için Mean-shift'in benimsenmesi de faydalı olabilir.

Büyük hacimli veriler için işlem süresi genellikle yüksektir. Birden fazla sınıflandırıcı kullanıldığında, her bir görüntüye her bir sınıflandırıcının ayrı ayrı uygulanması ve sonuçların bir araya getirilmesi gerektiğinden dolayı işlem süresinde birikimli bir artış söz konusudur. İşlem süresi birkaç optimizasyon stratejisi uygulanarak azaltılabilir. Örneğin, seri işlemlerin CPU yerine GPU gibi bir paralel işlemci ile gerçekleştirilmesi, işlem süresini potansiyel olarak azaltabilir. Diğer seçenekler, büyük görüntülerin Gauss piramitlerini üretmektir. Fakat burada indirgenen çözünürlüğün sınıflandırma sonucunu etkilemeyecek düzeyde olması gerekir. Her iki durumun sonraki çalışmalarda test edilerek sonuçlara etkisinin irdelenmesi hedeflenmektedir.

Sunulan tez çalışmasında bilinen üç istatistiksel öğrenme sınıflandırıcısı kullanmış ve iyi sınıflandırma sonuçları üretmiş olsa da, diğer sınıflandırıcıların da eklenerek çay bahçesi çıkarımı için yararlı olup olmadıklarının araştırılması hedeflenmektedir.

Manuel özellik çıkarma ve seçim, denetimli sınıflandırma problemlerinde en zor görevlerden biridir. Tüm temsili sınıfları tanımlamak ve her sınıf için uygun eğitim örneklerini seçmek oldukça dikkatli bir değerlendirme gerektirir.

Bunun yanında denetimsiz özellik öğrenme yaklaşımları ile özellik çıkarımı ve konvolisyonel sinir ağları (CNN'ler) da kullanımına yönelik çalışmalar hedeflenmiştir. Otomatik özellik çıkarma ile makine öğrenim sınıflandırıcılarının eğitimi için hızlı ve optimal özellikler elde edilebilir. Bu amaçla geleneksel sınıflandırıcıların kullanımı ile özellik çıkarma, dolayısı ile yüksek sınıflandırma doğruluğu üretilmesine yönelik çalışmaların yapılması öngörülmektedir.

Gelecekteki araştırmalarda ayrıca, uzaktan algılama verisinden ağaç türlerinin çıkarılması için CNN'ler gibi derin öğrenme temelli sınıflandırma yaklaşımlarının bütünleştirilmesine de odaklanılacaktır. Yeni paradigma, bilgisayar görüşü ve yapay zeka alanında büyük ilerlemeler kaydetmiştir. Derin öğrenme yaklaşımının kullanılmasının, geniş alanlarda multispektral ve yüksek spektral görüntü verisinden ağaç türlerinin haritalandırılması için sınıflandırma doğruluğunu önemli ölçüde artırabileceğine inanılmaktadır.

KAYNAKLAR

- [1] Majdar, R.S., ve Ghassemian, H., (2017). "A probabilistic SVM approach for hyperspectral image classification using spectral and texture features," *International Journal of Remote Sensing*, 38(15):4265–4284.
- [2] Zeggada, A., Melgani, F. ve Bazi, Y. (2017). "A Deep Learning Approach to UAV Image Multilabeling," *IEEE Geoscience and Remote Sensing Letters*, 14(5):694–698.
- [3] Jamil A. ve Bayram B., (2018). "Tree Species Extraction and Land Use/Cover Classification From High-Resolution Digital Orthophoto Maps," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(1): 89–94.
- [4] Qin, R., (2014). "A Mean Shift Vector-Based Shape Feature for Classification of High Spatial Resolution Remotely Sensed Imagery," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(5): 1974–1985.
- [5] Franklin, S.E. ve Ahmed, O.S., (2017). "Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data," *International Journal of Remote Sensing*, 00(00): 1–10.
- [6] Shi, D. ve Yang, X., (2017). "Mapping vegetation and land cover in a large urban area using a multiple classifier system," *International Journal of Remote Sensing*, vol. 38(16):4700–4721.
- [7] Cao, M. (2007). "An object-oriented approach to map wetland vegetation:a case study of yellow river delta," *IEEE International Geoscience and Remote Sensing Symposium*, 4585–4587.
- [8] Fauvel, M., Tarabalka, Y., Benediktsson, J.A., Chanussot, J., ve Tilton, J. C., (2013). "Advances in spectral-spatial classification of hyperspectral images," *Proceedings of the IEEE*, 101(3): 652–675.
- [9] Banzhaf , E., ve Kollai, H., (2015). "Monitoring the Urban Tree Cover for Urban Ecosystem Services - The Case of Leipzig, Germany," *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL-7/W3(May):301–305.

- [10] Li, D., Ke, Y., Gong, H. ve Li, X., (2015). "Object-Based Urban Tree Species Classification Using Bi-Temporal WorldView-2 and WorldView-3 Images," *Remote Sensing*, 7(12):16917–16937.
- [11] Belgiu M., ve Drăguț, L., (2016). "Random forest in remote sensing: A review of applications and future directions," *ISPRS Journal of Photogrammetry and Remote Sensing*, (114): 24–31.
- [12] Ghamisi, P., Plaza, J., Chen, Y., Li, J., ve Plaza, A. (2017). "Advanced Supervised Spectral Classifiers for Hyperspectral Images: A Review," *IEEE Geoscience and Remote Sensing Magazine*, 5(1): 8–32.
- [13] Yu, H., Yang, W., Xia, G., ve Liu, G. (2016). "A Color-Texture-Structure Descriptor for High-Resolution Satellite Image Classification," *Remote Sensing*, 8(1):1–24.
- [14] Chen, D., Peethambaran, J., ve Zhang, Z., (2018). "A supervoxel-based vegetation classification via decomposition and modelling of full-waveform airborne laser scanning data," *International Journal of Remote Sensing*, 39(9): 2937–2968.
- [15] Junior, C.A.daS., Nanni, M.R., Júnior, J.F.de.O., Júnior, E., Teodoro, P.E., Delgado, R.C., Shiratsuchi, L.S., Shakir, M., ve Chicati, M.L., (2018). "Object-based image analysis supported by data mining to discriminate large areas of soybean," *International Journal of Digital Earth*, 8947(January):1–23.
- [16] Jay, S., Gorretta, N., Morel, J., Maupas, F., Bendoula, R., Rabatel, G., Dutartre, D., Comar, A., ve Baret, F., (2017). "Estimating leaf chlorophyll content in sugar beet canopies using millimeter- to centimeter-scale reflectance imagery," *Remote Sensing of Environment*, 198(0): 173–186.
- [17] Hadavand, A., Saadatseresht, M., ve Homayouni, S., (2017). "Segmentation parameter selection for object-based land-cover mapping from ultra high resolution spectral and elevation data," *International Journal of Remote Sensing*, vol. 38(12) : 3586–3607.
- [18] Churches, C.E., Wampler, P.J., Sun, W., ve Smith, A.J., (2014). "Evaluation of forest cover estimates for Haiti using supervised classification of Landsat data," *International Journal of Applied Earth Observation and Geoinformation*, 30(1): 203–216.
- [19] Li, Q., Wang, C., Zhang, B., ve Lu, L., (2015). "Object-Based Crop Classification with Landsat-MODIS Enhanced Time-Series Data," *Remote Sensing*, 7 (12): 16091–16107.
- [20] Ning, H., HuaQiang, D., GuoMo, Z., XiaoYan, S., HongLi, G., ve XiaoJun, X., (2014). "Object-based classification using SPOT-5 imagery for Moso bamboo forest mapping," *International Journal of Remote Sensing*, 35(3): 1126–1142.
- [21] Waser, L.T., (2012) Airborne remote sensing data for semi-automated extraction of tree area and classification of tree species, Doktora Tezi, University of Zurich, Switzerland.

- [22] Santos, J. A., Gosselin, P.H., Foliguet, S.P., Torres, R.S., ve Falao, A.X., (2012). "Multiscale Classification of Remote Sensing Images," IEEE Transactions on Geoscience and Remote Sensing, 50(10):3764–3775.
- [23] Deventer, H.V., Cho, M.A., ve Mutanga, O., (2017). "Improving the classification of six evergreen subtropical tree species with multi-season data from leaf spectra simulated to WorldView-2 and RapidEye" International Journal of Remote Sensing, 38(17):4804–4830.
- [24] Yang, J., He, Y., ve Caspersen, J., (2016). "Region merging using local spectral angle thresholds: A more accurate method for hybrid segmentation of remote sensing images" Remote Sensing of Environment, 190(00): 137–148.
- [25] Adhikari, H., Heiskanen, J., Maeda, E.E., ve Pellikka, P.K.E., (2015). "Does topographic normalization of landsat images improve fractional tree cover mapping in tropical mountains?," ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-7/W3(May): 261–267.
- [26] Immitzer, M., Atzberger, C., ve Koukal, T., (2012). "Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data," Remote Sensing, 4(9): 2661–2693.
- [27] Shukla, G., Garg, R.D., Srivastava, H.S., ve Garg, P.K., (2017) "Implementation of random forest algorithm for crop mapping across an aridic to ustic area of Indian states" Journal of Applied Remote Sensing, 11(2): 026005.
- [28] Mustafa, Y.T. ve Habeeb, H.N., (2014). "Object based technique for delineation and mapping 15 tree species using VHR WorldView-2 (WV-2) imagery," Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI, vol. 9239, pp. 1–13.
- [29] Maulik, U. ve Chakraborty, D., (2017). "Remote Sensing Image Classification : A survey of support-vector-machine-based advanced techniques," IEEE Geoscience and Remote Sensing Magazine, vol. 5, no. 1, pp. 33–52.
- [30] Fernandes, J.L., Ebecken, N.F.F., ve Esquerdo, J.C.D.M., (2017). "Sugarcane yield prediction in Brazil using NDVI time series and neural networks ensemble," International Journal of Remote Sensing, 38(16): 4631–4644.
- [31] Sonobe, R., Tani, H., Wang, X., Kobayashi, N., ve Shimamura, H., (2014). "Parameter tuning in the support vector machine and random forest and their performances in cross- and same-year crop classification using TerraSAR-X," International Journal of Remote Sensing, 35(23): 7898–7909.
- [32] Wei, B., Yu, J., Wang, C., Wu, H., ve Li, J., (2014). "PolSAR image classification using a semi-supervised classifier based on hypergraph learning," Remote Sensing Letters, 5(4): 386–395.
- [33] Haque, M. E., Ramadan, B. A., ve Johnson, B. A., (2016). "Rule-based land cover classification from very high-resolution satellite image with multiresolution segmentation," Journal of Applied Remote Sensing, 10(3): 036004.

- [34] Sulma, Z. S., Yulianto, F., Nugroho, J.T., ve Sofan, P., (2016). "A support vector machine object based image analysis approach on urban green space extraction using Pleiades-1A imagery," *Modeling Earth Systems and Environment*, 2(54): 54.
- [35] Tigges, J., Lakes, T., ve Hostert, P., (2013). "Remote Sensing of Environment Urban vegetation classification : Benefits of multitemporal RapidEye satellite data," *Remote Sensing of Environment*, 136(0) : 66–75.
- [36] Alvarez, F., Catanzarite, T., Pérez, J.R.R., ve Nafría, D., (2010). "Radiometric calibration and evaluation of UltraCamX and Xp using portable reflectance targets and spectrometer data. Application to extract thematic data from imagery gathered by the National Plan of Aerial Orthophotography (PNOA)" *International Calibration and Orientation Workshop EuroCOW*, Jul 12, 2010, Germany,
- [37] Rafieyan, O., Darvishsefat, A.A., Babaii, S., ve Mataji, A., (2010). "Object-Based Classification Using Ultracam-D Images for Tree Species Discrimination (Case Study : Hyrcanian Forest-Iran)" *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVIII-4/C7 : 2–7.
- [38] Raczko, E. ve Zagajewski, B., (2017). "Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images," *Journal European Journal of Remote Sensing*, 50(1):144–154,.
- [39] Gu, Y., Liu T., Jia, X., Benediktsson, J. A., ve Chanussot, J., (2016). "Nonlinear Multiple Kernel Learning with Multiple-Structure-Element Extended Morphological Profiles for Hyperspectral Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, 54(6) : 3235–3247.
- [40] Wang, D., Cui, X., Xie, F., Jiang, Z., ve Shi Z., (2017). "Multi-feature sea – land segmentation based on pixel-wise learning for optical remote-sensing imagery," *International Journal of Remote Sensing*, 38(15): 4327–4347.
- [41] Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Queiroz, R., Feitosa M.F., Werff, H., Coillie, F., ve Tiede, D., (2014) "Geographic Object-Based Image Analysis – Towards a new paradigm," *ISPRS Journal of Photogrammetry and Remote Sensing*, 87:180–191.
- [42] Blaschke, T., Burnett, C., ve Pekkarinen, A., (2004). *Remote Sensing Image Analysis: Including The Spatial Domain*, vol. 5. Dordrecht: Springer Netherlands,.
- [43] Li, J., Hu, B., ve Woods, M., (2015). "A Two-Level Approach for Species Identification of Coniferous Trees in Central Ontario Forests Based on Multispectral Images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(4) :1487–1497.
- [44] González,I.L.C., Barragán, J.M., Expósito, M.J., Carrascosa, F.J., ve Granados, F. L., (2014). "Evaluation of pixel- and object-based approaches for mapping wild

- oat (*Avena sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific management,” *European Journal of Agronomy*, 59: 57–66.
- [45] Qin, R., (2014). “An object-based hierarchical method for change detection using unmanned aerial vehicle images,” *Remote Sensing*, 6(9):7911–7932.
 - [46] Wang, L., Sousa, W.P., ve Gong, P., (2004). “Integration of object-based and pixel-based classification for mapping mangroves with IKONOS imagery,” *International Journal of Remote Sensing*, 25(24):5655–5668.
 - [47] Kang, X., Li, S., ve Benediktsson, J.A., (2014). “Spectral-spatial hyperspectral image classification with edge-preserving filtering,” *IEEE Transactions on Geoscience and Remote Sensing*, 52(5):2666–2677.
 - [48] Deng, S., Katoh, M., Guan, Q., Yin, N., ve Li, M., (2014). “Interpretation of Forest Resources at the Individual Tree Level at Purple Mountain, Nanjing City, China, Using WorldView-2 Imagery by Combining GPS, RS and GIS Technologies,” *Remote Sensing*, 87–110.
 - [49] Hay, G.J., Marceau, D.J., Dubé, P., ve Bouchard, A., (2001). “A multiscale framework for landscape analysis: Object-specific analysis and upscaling,” *Landscape Ecology*, 16(1995): 471–490.
 - [50] Pham, L.T.H., Brabyn, L., ve Ashraf, S., (2016). “Combining QuickBird, LiDAR, and GIS topography indices to identify a single native tree species in a complex landscape using an object-based classification approach,” *International Journal of Applied Earth Observation and Geoinformation*, 50: 187–197.
 - [51] Ke, Y., Quackenbush, L. J., ve Im, J., (2010). “Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification,” *Remote Sensing of Environment*, vol. 114, no. 6, pp. 1141–1154.
 - [52] Tzotsos, A. ve Argialas, D., (2008). “Support Vector Machine Classification for Object-Based Image Analysis,” in *Object-Based Image Analysis*, Berlin, Heidelberg: Springer Berlin Heidelberg, 1: 63–677.
 - [53] Comaniciu, D. ve Meer, P., (2002). “Mean Shift: A Robust Approach Toward Feature Space Analysis,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5): 603–619.
 - [54] Fukunaga, K. ve Hostetler, L., (1975). “The estimation of the gradient of a density function, with applications in pattern recognition,” *IEEE Transactions on Information Theory*, 21(1): 32–40.
 - [55] Cheng, Y., (1995). “Mean Shift, Mode Seeking, and Clustering,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(8): 790–799.
 - [56] Xie, Y., Sha, Z., ve Yu, M., (2008). “Remote sensing imagery in vegetation mapping: a review,” *Journal of Plant Ecology-Uk*, 1(1): 9–23.
 - [57] Xiao, W., Elberink, S.O., ve Vosselman, G., (2016). “Individual Tree Crown Modeling and Change Detection From Airborne Lidar Data,” *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 12: 1–11.

- [58] Lin, Y. ve Hyyppä, J., (2016). "A comprehensive but efficient framework of proposing and validating feature parameters from airborne LiDAR data for tree species classification," *International Journal of Applied Earth Observation and Geoinformation*, 46: 45–55.
- [59] Paris, C., Valduga, D., ve Bruzzone, L., (2015). "A hierarchical approach to the segmentation of single dominant and dominated trees in forest areas by using high-density LiDAR data," in *International Geoscience and Remote Sensing Symposium*, 26-31 July 2015, Milan, Italy.
- [60] Vihlman, M., Hyyti, H., Kalmari, J., ve Visala, A., (2015). "Detection and species classification of young trees using machine perception for a semi-autonomous forest machine," *IEEE International Conference on Robotics and Automation (ICRA)*, 26-30 May 2015, WA, USA.
- [61] Bandyopadhyay, M., Aardt, N., ve Nicholson, K., (2013). "Classification and extraction of trees and buildings from urban scenes using discrete return LiDAR and aerial color imagery," in *Spie*, 2013, 8731: 873105-873105.
- [62] Colgan, M.S., Baldeck, C.A., Féret, J., ve Asner, G.P., (2012). "Mapping savanna tree species at ecosystem scales using support vector machine classification and BRDF correction on airborne hyperspectral and LiDAR data," *Remote Sensing*, 4(11): 3462–3480.
- [63] X. Liu and Y. Bo, (2015). "Object-Based Crop Species Classification Based on the Combination of Airborne Hyperspectral Images and LiDAR Data," *Remote Sensing*, 7(1): 922–950.
- [64] Xiang, H., Cao, C., Liu, J., ve Zhou, W., (2013). "The automatic tree detection and delineation from airborne LIDAR," in *International Geoscience and Remote Sensing Symposium*, 3:536–539.
- [65] Tong, X., Brandt, M., Hiernaux, P., Herrmann, S.M., Tian, F., Prishchepov, A.V., ve R. Fensholt, (2017). "Revisiting the coupling between NDVI trends and cropland changes in the Sahel drylands: A case study in western Niger," *Remote Sensing of Environment*, 191:286–296.
- [66] Benediktsson, J.A., Pesaresi, M., ve Arnason, K., (2003). "Classification and Feature Extraction for Remote Sensing Images From Urban Areas Based on Morphological Transformations," *IEEE Transactions on Geoscience and Remote Sensing*, 41(9):1940–1949.
- [67] Lahivaara, T., Seppanen, A., Kaipio, J.P., Vauhkonen, J., Korhonen, L., Tokola, T., ve Maltamo, M., (2012). "Bayesian Approach To Tree Detection With Airborne Laser Scanning" in *IEEE International Geoscience and Remote Sensing Symposium (Igarss)*, 22-27 July 2012, Germany.
- [68] Sugumaran, R. ve Voss, M., (2007). "Object-Oriented Classification of LIDAR-Fused Hyperspectral Imagery for Tree Species Identification in an Urban Environment," in *Urban Remote Sensing Joint Event*, 11-13 April 2007, France.

- [69] Sasaki, T., Imanishi, J., Loki, K., Morimoto, Y., ve Kitada, K., (2012). "Object-based classification of land cover and tree species by integrating airborne LiDAR and high spatial resolution imagery data," *Landscape and Ecological Engineering*, 8(2): 157–171.
- [70] Costa, H., Foody, G.M., ve Boyd, D.S., (2017). "Using mixed objects in the training of object-based image classifications," *Remote Sensing of Environment*, 190:188–197.
- [71] Leroux, L., Bégué, A., Seen, D.L., Jolivot, A., ve Kayitakire, F., (2016). "Driving forces of recent vegetation changes in the Sahel: lessons learned from regional and local level analyses," *Remote Sensing of Environment*, 191:18-25.
- [72] Huang, X.H. ve Zhang, L. Z., (2008). "An Adaptive Mean-Shift Analysis Approach for Object Extraction and Classification From Urban Hyperspectral Imagery," *IEEE Transactions on Geoscience and Remote Sensing*, 46(12): 4173–4185.
- [73] Dalponte, M., Orka, H.O., Gobakken, T., Gianelle, D., ve Naesset, E., (2013). "Tree species classification in boreal forests with hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, 51(5): 2632–2645.
- [74] Dalponte, M., Bruzzone, L., ve Gianelle, D., (2012). "Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data," *Remote Sensing of Environment*, 123:258–270.
- [75] Åkerblom, M., Raunonen, P., Mäkipää, R., ve Kaasalainen, M., (2017). "Automatic tree species recognition with quantitative structure models," *Remote Sensing of Environment*, 191:1–12.
- [76] Qian, Y., Zhou, W., Yan, J., Li, W., ve Han, L., (2015). "Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery," *Remote Sensing*, 7(1): 153–168.
- [77] Valls, G.C. ve Bruzzone, L., (2005). "Kernel-based methods for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, 43(6): 1351–1362.
- [78] Maxwell, A. E., Warner, T. A., ve Fang, F., (2018). "Implementation of machine-learning classification in remote sensing: an applied review," *International Journal of Remote Sensing*, 39(9): 2784–2817.
- [79] Zarea, A. ve Mohammadzadeh A., (2015). "A Novel Building and Tree Detection Method From LiDAR Data and Aerial Images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18(10): 1–12.
- [80] Zhang Y., (2001). "A spectral and spatial information integrated approach for tree extraction from high-resolution digital imagery" in *Second Digital Earth Conference*, 3 Jan 2001, China.
- [81] Demir, B. ve Bruzzone, L., (2015). "Histogram Based Attribute Profiles for Classification of Very High Resolution Remote Sensing Images" in *International*

Geoscience and Remote Sensing Symposium, 26-31 July 2015, Milan, Italy.

- [82] Huang, W., Li, H., ve Lin, G., (2015). "Classifying Forest Stands Based on Multi-Scale Structure Features Using Quickbird Image," in IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services (ICSDM), 8-10 July 2015, Fuzhou, China.
- [83] Hughes, G.F., (1968). "On the Mean Accuracy of Statistical Pattern Recognizers," IEEE Transactions on Information Theory, 14(1): 55–63.
- [84] Kim, C., Hong, S., ve Resources, F., (2008). "The characterization of a forest cover through shape and texture parameters from Quickbird imagery," in IEEE International Geoscience and Remote Sensing Symposium, 7-11 July 2008, USA.
- [85] Lucas, R., Bunting, P., Paterson, M., ve Chisholm, L., (2008). "Classification of Australian forest communities using aerial photography, CASI and HyMap data," Remote Sensing of Environment, 112(5): 2088–2103.
- [86] Laliberte, S. ve Rango, A., (2006). "Correlation of object-based texture measures at multiple scales in sub-decimeter resolution aerial photography," JIP, 1:10-20.
- [87] Zhang, K. ve Hu, B., (2012). "Individual urban tree species classification using very high spatial resolution airborne multi-spectral imagery using longitudinal profiles," Remote Sensing, 4(6):1741–1757.
- [88] Ghamisi, P., Member, S., Mura, M.D., ve Benediktsson, J.A., (2015). "A Survey on Spectral – Spatial Classification Techniques Based on Attribute Profiles," IEEE Transactions on Geoscience and Remote Sensing, 53(5):2335–2353.
- [89] Wei, W., Chen, X., ve Ma, A., (2005). "Object-oriented information extraction and application in high-resolution remote sensing image," in IEEE International Geoscience and Remote Sensing Symposium, 29 July 2005, South Korea.
- [90] Hájek F., (2006). "Object-oriented classification of Ikonos satellite data for the identification of tree species composition," Journal of Forest Science, 52(4): 181–187.
- [91] Serpico, S.B. ve Bruzzone, L., (2001). "A new search algorithm for feature selection in hyperspectral remote sensing images," IEEE Transactions on Geoscience and Remote Sensing, 39(7): 1360–1367.
- [92] Pudil, P., Ferri, F., Novovicova, J., ve Kittler, J., (1994). "Floating search methods for feature selection with nonmonotonic criterion functions," In Proceedings of the 12th IAPR International Conference on Pattern Recognition (Cat. No.94CH3440-5), 9-13 Oct. 1994, Israel.
- [93] Bruzzone, L., Roli, F., ve Serpico, S.B., (1995). "An Extension of the Jeffreys-Matusita Distance to Multi-class Cases for Feature Selection," IEEE Transactions On Geoscience And Remote Sensing, 33(6): 1318–1321.
- [94] Gebely, T., World of Tea, <https://worldoftea.org/tea-producing-countries>, 2017.
- [95] Chapedia, <http://www.alphainternationaltrade.gr>, 2015.

- [96] Imaging V., Microsoft Ultracam-X Specification, <http://www.vexcel-imaging.com/products/ultracam-eagle/ultracam-eagle-prime-technical-specs/>, 2017.
- [97] Liu, J., Li, P., ve Wang X., (2015). "A new segmentation method for very high resolution imagery using spectral and morphological information," *ISPRS Journal of Photogrammetry and Remote Sensing*, 101:145–162.
- [98] Corporation E., Emgu CV, http://www.emgu.com/wiki/index.php/Main_Page, 2018.
- [99] Garage, W. ve Itseez, OpenCV, <https://opencv.org>, 2018.
- [100] Rafael C. Gonzalez and Richard E. Woods, (2009). *Digital Image Processing*, 3rd ed. Pearson Prentice Hall,.
- [101] Haralick, R.M., Shanmugam, K., ve Dinstein, I., (1973). "Textural Features for Image Classification," *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3 (6): 610–621.
- [102] Ardila, J.P., Tolpekin, V. A., Bijker, W., ve Stein, A., (2011). "Markov-random-field-based super-resolution mapping for identification of urban trees in VHR images," *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6): 762–775.
- [103] Waske, B., Linden, S., Benediktsson, J. A., Rabe, A., ve Hostert, P., (2010). "Sensitivity of support vector machines to random feature selection in classification of hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, 48 (7):2880–2889.
- [104] Haykin, S., (2009). *Neural Networks and Learning Machines*, 3rd Edition, Pearson Prentice Hall, New Jersey.
- [105] Bishop, C. M., (2006). *Pattern Recognition and Machine Learning*, Springer, Singapore.
- [106] Abe, S., (2010). *Advances in Pattern Recognition*, vol. 6256., Springer, Berlin-Heidelberg.
- [107] Breiman L., (2001). "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32.
- [108] Gislason, P.O., Benediktsson, J.A., ve Sveinsson, J.R., (2006). "Random Forests for land cover classification," *Pattern Recognition Letters*, 27(4): 294–300.
- [109] Chang C.C. ve Lin, C.J., (2011). "LIBSVM : a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, 2(3): 1–27.
- [110] Baldeck, C., ve Asner, G., (2014). "Single-Species Detection With Airborne Imaging Spectroscopy Data: A Comparison of Support Vector Techniques," *Selected Topics in Applied Earth Observations and Remote Sensing*, *IEEE Journal of*, PP(99):1–12.

- [111] Marsland S., (2014). Machine Learning: An Algorithmic Perspective, Second Edition. CRC Press, New York.
- [112] Costa, H., Foody, G. M., ve Boyd, D. S., (2018). "Supervised methods of image segmentation accuracy assessment in land cover mapping," Remote Sensing of Environment, 205(December 2016): 338–351.



EK-A

ORİJİNAL GÖRÜNTÜ



**ÇAY ALANLARINA AİT İKİLİ GÖRÜNTÜNÜN ORJİNAL ORTOFOTO İLE
ÇAKIŞTIRILMASI**



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Akhtar Jamil
Doğum Tarihi ve Yeri : 18-Dec-1983, Pakistan
Yabancı Dili : English, Urdu, Turkish
E-posta : akh.jamil@yahoo.com

ÖĞRENİM DURUMU

Derece	Alan	Üniversite	Mezuniyet Yılı
Y. Lisans	Bilgisayar Mühendisliği	National University of Science and Technology	2011
Lisans	Bilgisayar Mühendisliği	Karachi University	2008

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2015 - 2016	Emi Group In. Turkey	Yazılım Mühendisliği
2011- 2014	COMSATS University of Information Technology, Pakistan	Öğretim Görevlisi
2010 – 2011	National University of Sciences and Technology, Pakistan	Araştırma Görevlisi
2009 – 2010	National University of Sciences and Technology, Pakistan	Asistan Öğretim Görevlisi

YAYINLARI

Makale

1. **Jamil, A.**, Bayram, B., (2018), "Tree Species Extraction and Land Use/Cover Classification From High-Resolution Digital Orthophoto Maps", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 11(1).
2. **Jamil, A.**, Bayram, B., Seker , D. Z.,(2018), "Mapping hazelnut trees from high resolution digital orthophoto maps: A quantitative comparison of an object and a pixel based approaches" Fresenius Environmental Bulletin, Volume xx-(x), 2018
3. Bayram, B., Seker, D.Z., **Jamil, A.**, Reis H. C., Demir, N., Bozkurt, S., Ince, A., Kucuk, T.,(2018), "Automatic extraction of sparse trees from high resolution ortho images", Arabian Journal of Geosciences, xx(xx):xx-xx
4. **Jamil, A.**, Azra Batool, Zumra Malik, Imran Siddiqi, (2016)," Multilingual Artificial Text Extraction and Script Identification from Video Images", International Journal of Advanced Computer Science and Applications 7(4).

Bildiri

1. **Jamil, A.**, Bayram, B., (2018), "Vegetation extraction from digital orthophoto maps using object-based segmentation and decision tree classifier", International Conference on Advanced Technologies, Computer Engineering and Science, Karabuk, May 11-13,.
2. **Jamil, A.**, Bayram, B., Seker, D.Z., Kucuk, T., (2017), "Spectral feature based tea-field extraction from digital orthophoto maps", International Cartographic Conference, USA
3. **Jamil, A.**, Bayram, B., (2017), "An object-based approach for tree species extraction from digital orthophoto maps", International Cartographic Conference, USA.
4. **Jamil, A.**, Siddiqi, I., Arif, F., Raza, A., (2011), "Edge-based Features for Localization of Artificial Urdu Text in Video Images", International Conference on Document Analysis and Recognition(ICDAR).
5. Niazi, W.L.K., Arif, F., Ahmad, F., **Jamil, A.**, (2011), "Service Oriented Architectural Framework for Pakistan's Disaster Emergency Response (in relation to floods)", IEEE 2nd International Conference on Software Engineering and Service Science, China.
6. Abidi, A., **Jamil, A.**, Siddiqi, I., Khurshid, K., (2012), "Word Spotting based Retrieval of Urdu Handwritten Documents", International Conference on Frontiers in Handwriting Recognition, Italy.