

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR BİLİMİ VE MÜHENDİSLİĞİ BİLİM DALI

ARAZİ ÖRTÜSÜ SINIFLANDIRMASI İÇİN MAKİNE
ÖĞRENMESİ YAKLAŞIMI

YÜKSEK LİSANS TEZİ

FATMA KİRAÇ

İstanbul
Haziran-2021

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR BİLİMİ VE MÜHENDİSLİĞİ BİLİM DALI

ARAZİ ÖRTÜSÜ SINIFLANDIRMASI İÇİN MAKİNE
ÖĞRENMESİ YAKLAŞIMI

YÜKSEK LİSANS TEZİ

Fatma KİRAC

Tez Danışmanı

Dr. Öğr. Üyesi Akhtar JAMIL

İstanbul

Haziran-2021

TEZ ONAY

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimi Ve Mühendisliği Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman Dr. Öğr. Üyesi Akhtar JAMIL

Üye Dr. Öğr. Üyesi Alaa Ali HAMEED

Üye Dr. Öğr. Üyesi Muhammad ILYAS

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof. Dr. Ali GÜNEŞ
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİMİ

Yüksek lisans tezi olarak hazırladığım “**Arazi Örtüsü Sınıflandırması İçin Makine Öğrenmesi Yaklaşımı**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Fatma KİRAÇ

ÖN SÖZ

Öncelikle, tez çalışmamın her anında bana bilgi ve tecrübeleriyle yol gösteren değerli danışmanım Dr. Öğr. Üyesi Akhtar JAMIL'e teşekkür ederim. Ayrıca hayatımın her anında yanımda olan, yüksek lisans eğitimim ve tez çalışmam sırasında da benden desteklerini esirgemeyen sevgili aileme teşekkür ediyorum.

Fatma KİRAÇ

İstanbul 2021



ÖZET
ARAZİ ÖRTÜSÜ SINIFLANDIRMASI İÇİN MAKİNE
ÖĞRENMESİ YAKLAŞIMI

Fatma KİRAC

Yüksek Lisans, Bilgisayar Bilimi ve Mühendisliği

Tez Danışmanı: Dr. Öğr. Üyesi Akhtar JAMİL

Haziran,2021- 84 Sayfa

Dünya yüzeyindeki arazi kullanımı ve arazi örtüsünün tespit edilmesi ve bu alanlar hakkında doğru ve kesin bilgiler elde edilmesi, insanların yaşadığı çevreyle nasıl bir etkileşimde olduğu hakkında önemli bilgiler sağlar. Uzaktan algılama verileri, arazi kullanımı / arazi örtüsü uygulamalarında hayati bir rol oynamıştır. Teknolojinin gelişmesiyle birlikte uzaktan algılama sistemleri tarafından alınan görüntülerin kalitesi de artmıştır. Bu görüntülerden yararlı bilgiler elde etmek için titiz bir şekilde işlenmesi gerekmektedir. Bu tezde, Türkiye'nin Doğu Karadeniz Bölgesi'nde yer alan ve çay üretiminde dünyanın önemli üretim yerlerinden biri olan Rize ilinin uzaktan algılanmış multispektral görüntülerinden arazi örtüsü sınıflandırılması yapılmıştır. Çalışmanın temel amacı makine öğrenmesi yöntemleri kullanılarak uzaktan algılanmış yüksek çözünürlüklü multispektral görüntülerden arazi örtüsü sınıflandırması yapmaktır. Bunun için nesne tabanlı bölümlenme ile Maksimum Olasılık, Destek Vektör Makinesi (DVM) ve Yapay Sinir Ağları (YSA) olmak üzere üç tane denetimli makine öğrenmesi sınıflandırıcısının yetenekleri araştırılmıştır. İlk olarak, orijinal görüntü piksellerini nesnelere ayırmak için grafik tabanlı minimal genişleyen ağaç segmentasyonu uygulandı. Her nesneden bir dizi spektral, uzamsal ve doku özelliği çıkarıldı. Bu özellikler daha sonra, Maksimum Olasılık, YSA ve DVM sınıflandırıcılarını eğitmek ve test etmek için kullanıldı. Önerilen yöntem, dört sınıflı (çay alanı, diğer ağaçlar, yollar ve yapılar, çıplak arazi) yüksek çözünürlüklü çoklu spektral görüntülerden oluşan bir veri seti üzerinde değerlendirilmiştir. Yapılan deneyler sonucunda ortalama doğruluk oranı YSA için 82,60%, DVM için 78,67% ve Maksimum Olasılık için 73,90% olarak elde edildi. Genel sonuçlar, YSA'nin arazi örtüsü sınıflandırması için DVM ve Maksimum Olasılık sınıflandırıcısına kıyasla daha etkili olduğunu göstermektedir. Benzer şekilde, her sınıf için YSA için elde edilen doğruluk daha

iyiydi. Bunun yanında sınıflandırılmış haritanın niteliklerini iyileştirmek için son işlem olarak Çoğunluk analizi uygulanmıştır. Çoğunluk analizinin temel amacı sınıflandırılmış haritadaki gürültüleri ortadan kaldırmaktır. Çoğunluk Analizi ortalama doğruluk oranını 86,18%'e çıkarmıştır.

Anahtar Kelimeler: arazi örtüsü sınıflandırma, uzaktan algılama, destek vektör makinası, maksimum olasılık, yapay sinir ağı



ABSTRACT
MACHINE LEARNING METHODS FOR LAND COVER
CLASSIFICATION FROM MULTISPEKTRAL IMAGES

Fatma KİRAC

Master of Science, Computer Science and Engineering

Advisor: Asst. Doc. Dr. Akhtar JAMIL

Haziran, 2021 - 84 Pages

Identifying land use and land cover on the earth's surface and obtaining accurate and precise information about these areas provides important information about how people interact with the environment they live in. Remote sensing data has played a vital role in land use / land cover applications. With the development of technology, the quality of images taken by remote sensing systems has also increased. These images must be handled meticulously in order to obtain useful information. In this thesis, land cover classification has been made from remotely perceived multispectral images of Rize, which is located in the Eastern Black Sea Region of Turkey and is one of the important production places in the world in tea production. The main purpose of the study is to classify land cover from high-resolution multispectral images that are remotely sensed using machine learning methods. For this, the capabilities of three controlled machine learning classifiers, namely, Maximum Probability with Object-based segmentation, Support Vector Machine (SVM) and Artificial Neural Networks (ANN) were investigated. First, graphics-based minimal expanding tree segmentation was applied to separate the original image pixels into objects. A number of spectral, spatial, and texture features were extracted from each object. These features were later used to train and test Maximum Probability, ANN and DVM classifiers. The proposed method has been evaluated on a data set consisting of high resolution multi-spectral images with four classes (tea field, other trees, roads and structures, bare land). As a result of the experiments, average accuracy rate was obtained as 82,60% for ANN, 78,67% for DVM and 73,90% for Maximum Probability. Overall results show that ANN is more effective for land cover classification compared to DVM and Maximum Likelihood classifier. Similarly, the accuracy obtained for ANN was better for each class. In addition, Majority analysis was applied as a final process to improve the

qualities of the classified map. The main purpose of majority analysis is to remove the noise in the classified map. Majority Analysis increased the average accuracy rate to 86.18%.

Keywords: land cover classification, remote sensing, support vector machine, maximum likelihood, artificial neural networks



İÇİNDEKİLER

TEZ ONAY	i
BİLİMSEL ETİK BİLDİRİMİ.....	ii
ÖN SÖZ.....	iii
ÖZET.....	iv
ABSTRACT.....	vi
İÇİNDEKİLER	viii
TABLO LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
KISALTMALAR	xiii
BÖLÜM 1	
GİRİŞ	1
1.1. Problemin Tanımı	4
1.2. Tezin Amacı.....	6
1.3. Tezin Genel Görünümü.....	6
BÖLÜM 2	
İLGİLİ ÇALIŞMALAR	7
BÖLÜM 3	
UZAKTAN ALGILAMA VE SINIFLANDIRMA YÖNTEMLERİ.....	14
3.1. Uzaktan Algılama.....	14
3.2. Sınıflandırma Yöntemleri	18
3.2.1. Piksel Tabanlı Sınıflandırma.....	19
3.2.2. Nesne Tabanlı Sınıflandırma.....	20

BÖLÜM 4

METODOLOJİ	39
4.1. Çalışma Alanı ve Veri Seti.....	39
4.2. Görüntü Segmentasyonu (Bölütleme).....	42
4.3. Özellik Çıkarımı ve Eğitim Verisi	44
4.4. Sınıflandırma Yöntemleri	47
4.4.1. Maksimum Olasılık.....	47
4.4.2. Destek Vektör Makineleri	48
4.4.3. Yapay Sinir Ağları	50
4.5. Değerlendirme Ölçütleri.....	51

BÖLÜM 5

DENEYSEL SONUÇLAR	53
--------------------------------	-----------

BÖLÜM 6

SONUÇ VE GELECEK ÇALIŞMALAR	60
------------------------------------------	-----------

KAYNAKÇA	63
-----------------------	-----------

ÖZGEÇMİŞ	69
-----------------------	-----------

TABLO LİSTESİ

Tablo 2.1: Literatür İncelemesinin Özeti 1	12
Tablo 2.2: Literatür İncelemesinin Özeti 2	13
Tablo 3.1: MO, DVM ve YSA formülize edilirken kullanılan bazı notasyonlar ve açıklamalarının listesi.....	23
Tablo 4.1: Kamera ve Uçuş Bilgileri Detayları	40
Tablo 4.2: Her piksel için çıkarılan özellikler.....	44
Tablo 4.3: Her sınıf için seçilen eğitim örnekleri	45
Tablo 4.4: SVM ve RBF çekirdek parametreleri ve detayları	50
Tablo 4.5: YSA sınıflandırıcısı için kullanılan parametrelerin detayları	51
Tablo 5.1: Kullanılan sınıflandırıcıların ve uygulanan Çoğunluk Analizinin doğruluk analizleri(%).....	56

ŞEKİL LİSTESİ

Şekil 1.1.1: Arazi örtüsü sınıflandırması için nesne tabanlı görüntü analizi akış diyagramı.....	5
Şekil 3.1.1: Pasif ve aktif sensör diyagramı.	15
Şekil 3.1.2: Elektromanyetik Spektrum.....	15
Şekil 3.1.3: Multispektral ve Hiperspektral Görüntülerin EMS deki gösterimi	16
Şekil 3.1.4: Farklı arazi örtüleri için spektral yansımaya varyasyonu (Kırmızı çizgi toprak, Yeşil çizgi bitki ve mavi çizgi suyun spektral yansımalarını göstermektedir. .	17
Şekil 3.2.1: (a) Saf uydu görüntüsünü gösterir. (b) Uydu görüntüsünün Nesne Tabanlı olarak sınıflandırılmasını gösterir. (c) Uydu görüntüsünün Piksel Tabanlı olarak sınıflandırılmasını gösterir.	21
Şekil 3.2.2: İki boyutlu (multispektral görüntü) düzlemde Gauss olasılık dağılımları ile temsil edilen spektral sınıflar(Su, Bitki ve toprak sınıfları).....	25
Şekil 3.2.3: DVM ile verilerin sınıflandırılması.....	28
Şekil 3.2.4: Doğrusal olmayan verinin kernel fonsiyonla boyutunun artırılması.....	31
Şekil 3.2.5: Bir YSA Yapısı	34
Şekil 3.2.6: Doğrusal fonksiyonun grafiksel gösterimi	35
Şekil 3.2.7: Sigmoid fonksiyonun grafiksel gösterimi	35
Şekil 3.2.8: Hiperbolik Tanjant fonksiyonunun grafiksel gösterimi	36
Şekil 3.2.9: ReLu Aktivasyon fonksiyonunun grafiksel gösterimi	36
Şekil 4.1.1: (a): Rize ilinin Türkiye haritası üzerindeki yeri. (b): Rize ilinin ilçeleri ile gösterimi. (c): Rize'nin UA sistemleri tarafından alınan görüntüsü. (d): (c)'de gösterilen görüntünün sarı renkle kare içine alınan bölgenin yakınlaştırılmış görüntüsü	42
Şekil 4.2.1: Normal görüntü kesiti.....	43

Şekil 4.2.2: Görüntü Segmentasyon haritası	43
Şekil 4.3.1: Girdi Görüntüsü.....	46
Şekil 4.3.2: Eğitim verisi seçim örnekleri (a):Girdi görüntüsü üzerinde işaretlenmiş örnek çay ve diğer ağaçlar. (b): İşaretlenmiş örnek insan yapımı yol-bina alanları ..	47
Şekil 5.1.1: DVM ve RBF için elde edilen maliyet(C) ve gama parametrelerinin görsel hali.....	54
Şekil 5.1.2: YSA için öğrenme oranı ve genel doğruluk grafiği	55
Şekil 5.1.3: YSA için momentum ve genel doğruluk grafiği	55
Şekil 5.1.4: Herhangi bir işlem uygulanmamış orijinal görüntü kesiti.....	57
Şekil 5.1.5: MO sınıflandırma sonucu oluşan harita	58
Şekil 5.1.6: DVM sınıflandırma sonucu oluşan harita	58
Şekil 5.1.7: YSA sınıflandırma sonucu oluşan harita.....	59
Şekil 5.1.8: Post-Procession Çoğunluk analizi sonucu oluşan harita	59

KISALTMALAR

UA:	Uzaktan Algılama
UAT:	Uzaktan Algılama Teknolojileri
DVM:	Destek Vektör Makinası
YSA:	Yapay Sinir Ağları
MO:	Maksimum Olasılık
MSG:	Multispektral Görüntü
HSG:	Hiperspektral Görüntü
CBS:	Coğrafi Bilgi Sistemleri
NDVI:	Normalize Edilmiş Fark Bitki Örtüsü Endeksi
RO:	Rastgele Ormanlar
GEOBIA:	Coğrafi Nesne Tabanlı Görüntü Analizi
OSRM:	Nesne Tabanlı Superresolution Mapping(Haritalama)
SRTM:	Shuttle Radar Topography Mission(Mekik Radar Topografya Misyonu)
GAN:	Generative Adversarial Networks (Çekişmeli Üretici Ağlar)
KNN:	K En Yakın Kmomşu
IKNN:	Iterative K Nearest Neighbor (Yinelemeli K en Yakın Komşu)
İHA:	İnsansız Hava Aracı
GA:	Genetik Algoritma
LR:	Lojistik Regresyon
SRC:	Sparse Representation Classification (Seyrek Temsili Sınıflandırma)
NN:	Neural Network (Sinir Ağı)
PF:	Polinom Fonksiyon
RBF:	Radial Base Function (Radyal Tabanlı Fonksiyon)
EKY:	En Küçük Kareler Yöntemi
MMS:	Minimum Mesafe Sınıflandırıcısı
PYS:	Paralel Yüzlü Sınıflandırma

BÖLÜM 1

GİRİŞ

Geçmişten günümüze kadar insanların yeni keşifler yapma, yaşam kalitesini artırma gibi istekleri sayesinde bilim ve teknoloji hızlı bir şekilde gelişmiştir şüphesiz bu gelişmeler gelecekte de devam edecektir. Yeryüzünü, dünyayı, uzayı izlemek için çeşitli araçlar, teknolojiler geliştirmişlerdir. İnsanlık büyük sınırları barındıran, büyük bilinmezlik içeren uzayı ve üzerinde yaşadığı yeryüzünün doğal kaynaklarını, bitki örtüsünü, yaşam alanlarını geliştirdikleri bu teknolojiler sayesinde bilgi sahibi olabilmektedir.

Yeryüzünü gözlemlemek için geliştirilen en önemli teknolojilerden birisi Uzaktan algılama teknolojileridir. UAT sayesinde, hemen hemen her gün üzerinde yaşadığımız yeryüzünün çeşitli nedenlerle nasıl hızla değiştiğini ve bu değişimin yerel ve bölgesel olarak insanlara, çevreye nasıl yansıdığını görebiliyoruz. Bu değişiklikleri daha iyi anlamak, analiz etmek ve tahmin etmek için UA verileri önemli bir bilgi kaynağıdır. UA verileri, bilim insanlarının Dünya yüzeyinin atmosferi, okyanusları, toprağı, bitki örtüsü, buzulları ve diğer çevresel yönlerini incelemesine etkin bir şekilde katkıları sunmaktadır. UA tanım olarak herhangi bir cisim ile temas olmadan yeryüzünden yayılan ve yansıyan enerjinin ölçülmesi olarak ifade edilebilir. Gözlerimiz UA cihazının mükemmel bir örneğidir(McHaffie, Hwang, & Follett, 2018). Ölçüm işlemi çeşitli araçlarla, uydularla sağlanmaktadır. UAT tarafından sağlanan veriler işlendikten sonra çeşitli alanlarda kullanılmaktadır. Yeryüzünün düzenli olarak izlenmesi, kontrolü ve ulaşımı zor coğrafi bölgelerde çalışabilme imkânı uzaktan algılama teknolojisinin önemli avantajları arasındadır(Yüksek, Enstitüsü, Mühendisliği, & Kocaeli, n.d.). CBS, jeomorfoloji, tarım, orman, şehircilik, askeriye alanları UAT verilerini kullanan başlıca yerlerdendir.

UA yapan sensörlerin gelişen teknoloji ile birlikte sürekli çoğalması ve iyileştirilmesi, zengin spektral bilginin yanı sıra yüksek mekânsal ve zamansal çözünürlüğe sahip çok büyük hacimde UA verisi sağlar. Son yıllarda, uzaktan algılama veri toplama teknolojilerindeki gelişmeler ve uzaktan algılama uygulamalarına yönelik artan talep ile birlikte, yüksek mekânsal çözünürlüklü uzaktan algılama verileri giderek daha yaygın hale gelmektedir(Belward & Skoien, 2015). Örneğin, uzaya gönderilen uydular

gelişmiş sensörleri sayesinde dünyanın etrafından görüntüler olarak insanlara önemli veriler sağlamaktadır. Bu veriler, doğal afetlerin izlenmesi, kentsel ortamların planlanması ve hassas tarım gibi çok çeşitli önemli uygulamalara kapı açan değerli bir bilgi kaynağı içerir. Bunun yanında UA, sağladığı kuşbakışı görünümü veya sinoptik(bir gözlem çeşidi) görünüm sayesinde, dünyanın geniş bir alanını kapsayan çevresel verileri anında yakalayabilir ve daha sonra harita benzeri ürünler oluşturarak CBS veri tabanı için çok bantlı ve çok ölçekli veriler sağlayabilmektedir(Sarath, Nagalakshmi, & Jyothi, 2014). UA da kullanılan uydular sahip oldukları sensörün tipine göre farklı konumsal ve spektral çözünürlüklerde yeryüzünü görüntülemektedir(Yüksek et al., n.d.). Sensörler tarafından ölçülen bant genişliği aralığı sayısı ve bantların darlığı veya genişliğine göre görüntüdeki ayrıntı ve çözünürlük farklılaşmaktadır. Yüksek çözünürlüklü sensörlerin geliştirilmesi ile, görüntüler daha küçük detaylarla elde edilebilir hale gelmiştir. Böylece arazi örtüsü türlerinin yüksek doğrulukla ayırt edilebilme olanağı da ortaya çıkmıştır. Uzaktan algılama alanında kullanılan en güçlü araçlar Hiperspektral görüntüleme (HSG) ve Multispektral Görüntüleme (MSG)'dir(Sarath et al., 2014). Multispektral görüntüler birkaç geniş banttan oluşur. Hiperspektaral görüntüler ise birçok dar banttan oluşur. Dolayısıyla hiperspektral bir görüntüdeki ayrıntı sayısı ve görüntü çözünürlüğü multispektral bir görüntüden yüksektir.

UAT tarafından sağlanan verileri kullanmak ve yararlı sonuçlar elde etmek için verilerin sağlıklı bir şekilde işlenmesi gerekmektedir. Hızla gelişen bilgisayar teknolojisinin paralelinde gelişen görüntü işleme teknolojisi, günümüzün popüler alanlarından biridir. Bunun bir sonucu olarak da uzaktan algılanmış görüntülerden arazi haritası çıkarma işlemi önemli bir araştırma konusu olmuştur. Bilgisayarların işleme ve depolama kapasitesindeki hızlı iyileştirmeler ve Yapay Zeka'daki evrim sonucunda arazi örtüsü ve arazi kullanımı sınıflandırması ve diğer zorlukları üzerindeki çalışmalar sürekli ve hızlı bir şekilde gelişmektedir(Vali, Comai, & Matteucci, 2020). Dünya üzerindeki arazi haritaları geleneksel olarak arazi kullanımı sınıflandırılması ve arazi örtüsü sınıflandırılması olarak iki kategoride incelenmektedir(Vali et al., 2020). Bu kavramlar sıklıkla karıştırılsa da aslında birbirinden farklıdır. Arazi örtüsü, toprak yüzeyindeki fiziksel alanlardır. Yani toprak üzerindeki ormanlar, sulak alanlar, akarsular, çıplak alanlar, geçirimsiz yüzeyler vb. alanlar arazi örtüsünü oluşturmaktadır. Arazi kullanımı ise insanların araziye nasıl

kullandığını, yeryüzü ile etkileşimlerini gösterir. Xu ve arkadaşları (2000) arazi kullanımının, arazideki insan faaliyetinin, arazinin sosyal ve ekonomik olarak kullanılması gibi durumu olduğunu, arazi örtüsünün ise arazinin doğal niteliği ve fiziksel özelliği anlamına geldiğini iddia etmiştir. Yine Xu (2000), arazi örtüsünün mevsimsel ve mekânsal olarak çeşitlilik gösterdiğini, arazi kullanımındaki değişikliklerin mevsime bağlı olmadığını, mutlak insana bağlı olduğunu söylemiştir. Her iki veri türü(arazi örtüsü ve arazi kullanımı) de çoğunlukla uydu ve hava görüntüleri analiz edilerek elde edilir. Her ne kadar tanım olarak farklı olsalar da aslında birbirleriyle ilişkili kavramlardır.

UA görüntülerinden arazi örtüsü haritalama için çeşitli yöntemler mevcuttur. Bitki örtüsü indeksleri(NDVI gibi) ve sınıflandırma bu yöntemlere örnek olarak verilebilir. Bitkinin canlılık özelliğini temel alan NDVI -1 ve 1 arasında değer alır. Bu değerler su, çorak toprak, hastalıklı bitki ve sağlıklı bitkiler için farklıdır. Bu farklılığa göre arazi örtüsü çıkarılır. Genel olarak görüntüler piksel ve nesne tabanlı olarak sınıflandırılır. Haliyle UA görüntüleri için de kullanılan bu iki yöntem sınıflandırma işlemi spektral özelliklerin gruplandırılmasıyla gerçekleşir. Görüntü sınıflandırmasının amacı, bir görüntüde meydana gelen özellikleri nesneye veya bu özelliklerin gerçekte zeminde temsil ettiği arazi örtüsüne göre benzersiz bir gri seviye (veya renk) olarak tanımlamak ve tasvir etmektir(Sarath et al., 2014). Her iki sınıflandırma tekniği için çeşitli yöntemler geliştirilmiştir. Makine öğrenmesi sınıflandırma için kullanılan başlıca yöntemlerdendir.

Makine öğrenme yaklaşımları, UAT tarafından elde edilen verilerden arazi örtüsü sınıflandırılması için yeteneklerini kanıtlamışlardır. Makine öğrenmesi yaklaşımları çeşitliliği ve sağlamlıklarından dolayı UA verilerinin sınıflandırmasında yaygın bir şekilde kullanılmaktadır(Jamil, Bayram, & Seker, n.d.). Makine öğrenmesi genel olarak denetimli öğrenme ve denetimsiz öğrenme kategorilerinde incelenmektedir. Denetimli öğrenme, uzaktan algılama görüntü verilerinin sayısal analizi için en sık kullanılan yöntemdir(Richards, 2013). Bu yöntem de sınıflandırma işlemi için bir görüntüdeki piksellerin veya nesnelerin belirli bir sınıfı temsil edecek şekilde etiketlenir. Etiketleme sonucu oluşan eğitim kümesi referans alınarak çeşitli algoritmalarla sınıflandırma işlemi gerçekleştirilir. Algoritmaların iyi bir performans göstermesi için eğitim verisi iyi seçilmelidir. Denetimsiz öğrenmede sınıflandırma

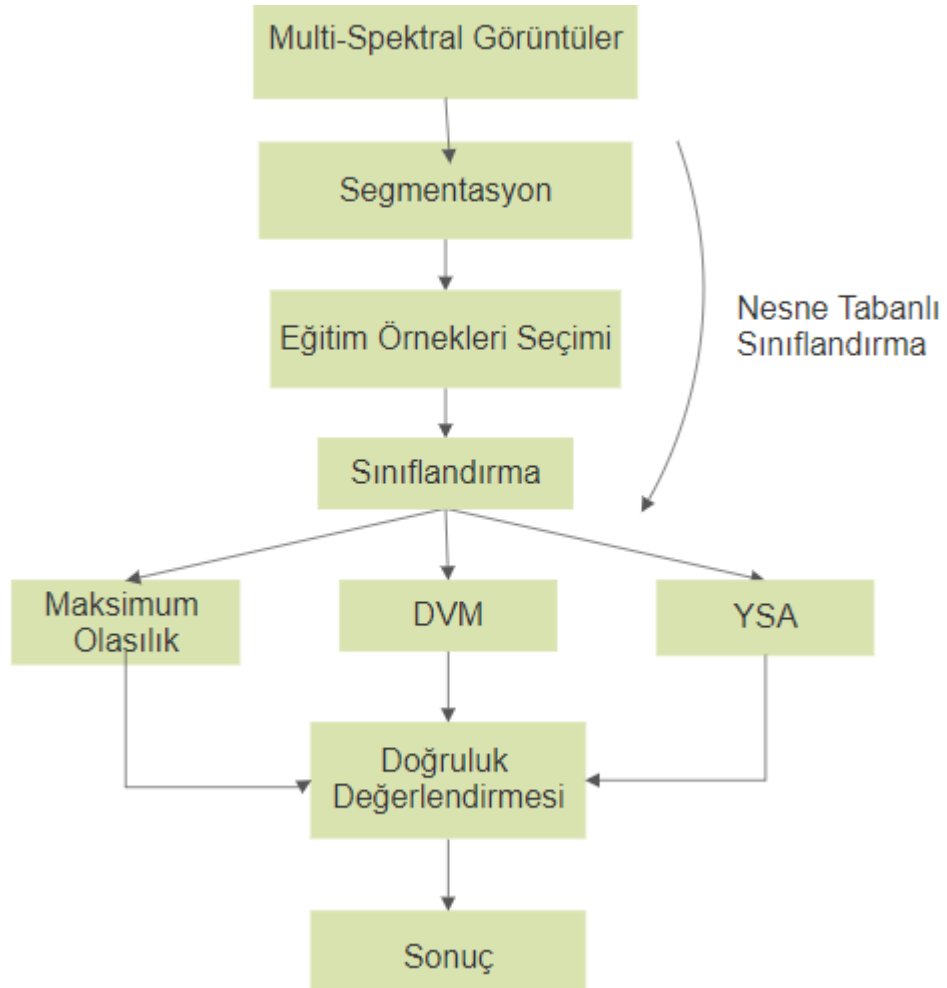
işlemi ise, bir görüntüdeki piksellerin veya nesnelerin, kullanıcının bu sınıfların varlığından veya adlarından önceden haberi olmadan spektral sınıflara atamasıyla gerçekleşir. Denetimsiz öğrenme genellikle kümeleme yöntemleri kullanılarak gerçekleştirilir. Denetimli öğrenme eğitilmiş verileri dikkate alarak sınıflandırma işlemini yaparken denetimsiz öğrenme genel olarak kümeleme işlemine göre sınıflandırma işlemi yapar. Her iki yöntemde UA verilerinin analizinde kullanılmaktadır. Uydu görüntülerinin sınıflandırılmasında denetimli sınıflandırma yöntemi yani eğitim alanlarıyla sınıflandırma metodolojisi sonuçların doğruluğu ve güvenilirliği açısından en çok tercih edilen yöntem olmuştur(Kavzoğlu & Çölkesen, 2010). Bizim yaptığımız literatür araştırmasında(Bölüm 2) eğitilmiş verileri kullanan denetimli öğrenme daha çok kullanılmıştır. Geçmişten günümüze kadar çok çeşitli uzaktan algılama teknikleri kullanılmıştır. Dolayısıyla çeşitli makine öğrenmesi yaklaşımları da önerilmiştir. Maksimum Olasılık(MO), Rastgele Ormanlar (RO), K-En Yakın Komşu (KNN), Destek Vektör Makineleri (DVM), Naive Bayes, Yapay Sinir Ağları (YSA), ISODATA, K-Means UA verilerini analiz etmek için kullanılan bazı denetimli ve denetimsiz öğrenme algoritmalarındandır.

Yaptığımız çalışma UA araçları tarafından Türkiye'nin Rize şehrinden alınmış görüntülerinden arazi örtüsü sınıflandırılması yapılmıştır. Görüntülerin sınıflandırılması çay alanları, diğer ağaçlar, çıplak araziler ve yol-bina olmak üzere dört sınıf temel alınarak yapılmıştır. Sınıflandırma işlemi için makine öğrenmesi kategorilerinden biri olan denetimli öğrenme yöntemleri kullanılmıştır. Maksimum Olasılık, Destek Vektör Makinesi ve Yapay Sinir Ağları arazi örtüsü için kullandığımız sınıflandırıcılardır. Geleneksel sınıflandırıcı olarak bilinen MO, arazi örtüsü ve arazi kullanımı sınıflandırmasında geçmişten günümüze kadar yaygın bir şekilde kullanılmıştır. Yine DVM ve YSA sınıflandırıcıları UA verilerinin analizinde yaygın bir şekilde kullanılmaktadır. Ayrıca bu iki popüler yöntemin, multispektral ve hiperspektral gibi yüksek boyutlu verilerin sınıflandırılmasında ve sınırlı sayıda eğitilmiş veri de iyi sonuçlar verdiği kanıtlanmıştır.

1.1. Problemin Tanımı

UA verilerden sağlıklı bir şekilde arazi örtüsü çıkarımı sayısal görüntü işleme alanının temel problemlerinden biridir. Bu problem çözümü için geçmişten günümüze pek çok çalışma yapılmıştır. Bu çalışmaların genel amacı arazi örtüsü ve arazi kullanımının

sınıflandırılması işlemidir. Örneğin, uzaktan algılamada, arazi örtüsü sınıflandırması genellikle çok sınıflı bir sorundur(Gualtieri & Chettri, 2000). Sınıflandırma bir karar verme işlemidir. Dolayısıyla arazi örtüsünün dağılımını bulmak, değişimini gözlemlemek, insanların nasıl kullandığını belirlemek, doğal afetlerden nasıl etkilendiği vb. birçok probleme sınıflandırma yöntemleri sayesinde çözümler üretilebilmektedir. Bizim çalışmamızda makine öğrenmesi yaklaşımları kullanılarak arazi örtüsü çay alanları, diğer ağaçlar, çıplak alanlar ve yol-bina sınıflandırılması yapılmıştır.



Şekil 1.1.1: Arazi örtüsü sınıflandırması için nesne tabanlı görüntü analizi akış diyagramı

1.2. Tezin Amacı

Tezin temel amacı uzaktan algılanmış görüntülerden arazi örtüsü sınıflandırması yapmaktır. Bu amaç doğrultusunda geleneksel yöntemlerden biri olarak bilinen MO ve popüler yöntemlerden olan DVM ve YSA yöntemleri kullanılmıştır. Bu yaklaşımlar karşılaştırılarak arazi örtüsü sınıflandırılması için en iyi yöntem belirlenecektir. Kullanılan uzaktan algılanmış görüntü temel olarak çay alanları, çay dışındaki diğer ağaçlar, yol-bina ve ekilmemiş çıplak alanlar olmak üzere dört sınıf üzerinden işlemlere tabii tutulacaktır. Tezin katkıları aşağıdaki gibi listelenebilir.

1. MO, DVM ve YSA gibi yöntemlerin doğruluk oranlarını karşılaştırarak arazi örtüsü sınıflandırması için en iyi yöntemi bulmak.
2. Sınıflandırma işlemi yapıldıktan sonra uzaktan algılanmış görüntülerden çay alanları çıkarımı için en iyi yöntemi bulmak.
3. Denetimli öğrenme algoritmaları için az eğitilmiş veri kullanarak arazi örtüsü sınıflandırması için en uygun algoritmayı tespit etmek.
4. Geleneksel (MO) ve popüler (DVM, YSA) yöntemleri karşılaştırmak.

Bu amaçlar doğrultusunda arazi örtüsü sınıflandırma problemlerine en iyi çözüm yöntemleri bulunacaktır.

1.3. Tezin Genel Görünümü

Bu çalışma altı farklı bölüme ayrılmıştır:

Bölüm 1: Bu bölümde tezin giriş ve amacı ele alınmıştır.

Bölüm 2: Bu bölüm önceden yapılmış ilgili çalışmalardan bahsedilmiştir.

Bölüm 3: Bu bölüm Uzaktan Algılama, Sınıflandırma Teknikleri ve Makine Öğrenmesi hakkında bilgi verilen bölümdür.

Bölüm 4: Bu bölümde tezde kullanılan metodoloji açıklanmıştır.

Bölüm 5: Test Sonuçlarının ele alındığı bölüm.

Bölüm 6: Son bölüm genel sonuç yorumu ve gelecekte yapılması planlanan çalışmaları içermektedir.

BÖLÜM 2

İLGİLİ ÇALIŞMALAR

Bu bölümde arazi örtüsünün sınıflandırılmasıyla ilgili yapılan çalışmalardan bahsedilmektedir.

Uzaktan algılama görüntüleri kullanılarak arazi örtüsü/arazi kullanımı haritalandırılması üzerine geçmişten günümüze kadar pek çok çalışma yapılmıştır. Geçmiş çalışmalar incelendiğinde, farklı UA uygulamaları için çeşitli görüntü elde etme algılayıcılarının kullanıldığı söylenebilir. Çalışmalarda veri seti olarak genelde yüksek çözünürlüklü multispektral ve hiperspektral gibi uydu görüntüleri kullanılmıştır. İHA, uydu, uçak gibi çeşitli araçlardan alınan UA verilerinin sınıflandırma problemleri için genel olarak makine öğrenmesi yaklaşımları kullanılmıştır. Yapılan çalışmalar incelendiğinde ilk zamanlar sınıflandırma için MO, RO gibi geleneksel yöntemlerin çokça tercih edildiği, teknolojinin gelişmesi ile birlikte geleneksel yöntemlerin yanında DVM, YSA gibi popüler yöntemlerin de sıklıkla kullanılmaya başlandığı görülmektedir. Tablo 2.1 ve Tablo 2.2 yaptığımız literatür incelemesinin özetini göstermektedir.

Ghamisi ve arkadaşları (2017) spektral verileri sınıflandırmak için kullanılan bazı denetimli öğrenme algoritmalarının(DVM, Random Forest, Logistic Regresyon vb.) hiperspektral veri üzerindeki doğruluk, konfigürasyon, hız ve kapasite oranlarını incelemişlerdir. DVM'nin hiperspectral veri üzerinde başarılı olduğu görülmüştür.

Jamil ve arkadaşları (2018) fındık ağaçlarının yüksek çözünürlüklü ortofoto haritalarından çıkarılması konusu üzerinde çalışma yapmıştır. Nesne ve piksel tabanlı sınıflandırma tekniklerini karşılaştırmışlardır. Nesne tabanlı sınıflandırma için kullanılan DVM algoritması, piksel tabanlı sınıflandırma için kullanılan maksimum olasılık algoritmasından daha başarılı sonuçlar üretmiştir. Genel doğruluk oranı DVM için %85.99, MO için %75.83 elde edilmiştir.

Yine Jamil ve arkadaşları (2018) toprak örtüsü(çay ağaçları, diğer ağaçlar, çıplak alanlar, geçirimsiz yüzeyler) sınıflandırılması üzerine yaptıkları çalışmada denetimli öğrenme algoritmalarından DVM, yapay sinir ağları(YSA) ve rastgele ormanları

kullanmışlardır. Çay ağaçları için doğruluk oranları DVM %87, YSA %89, RO için %86 gibi oranlar elde edilmiştir.

Chen ve arkadaşları (2018) karışık piksel problemine(görüntülerde alanların farklılaştığı yerlerin kenar pikselleri) nesne tabanlı superresolution mapping (OSRM) yöntemi ile arazi örtüsü sınıflandırılması yapmıştır. Yaptıkları deney sonucunda OSRM'nin karışık nesnelere için daha fazla arazi örtüsü detayı ürettiği açıklanmıştır.

Pipaud ve arkadaşları (2017) nesne tabanlı sınıflandırmada segmentasyon için mean-shift yöntemi ve sınıflandırıcı için DVM kullanarak alüvyon fanlarının sınıflandırılması konusunu ele almıştır. Çalışma sonucunda mean-shift ve DVM temelli sınıflandırmanın belirli bir yer şeklinin tasviri ve sınıflandırılması için etkili bir yöntem olduğu kanısına varmışlardır.

Zhu ve arkadaşları (2018) yaptıkları çalışmada temel olarak iki adet sinir ağından oluşan General Adversarial Network(GAN) yöntemini kullanarak hyperspektral görüntüyü sınıflandırmışlardır. Sonuç olarak GAN'ların geleneksel sinir ağlarından daha iyi sonuç verdiği bulunmuştur.

Junior ve arkadaşları (2019) eCognition ve WEKA yazılımlarından yararlanarak coğrafik nesne tabanlı görüntü analizi(GEOBIA) ve veri madenciliği ile soya fasulyesi ekim alanlarını sınıflandırmış ve %76 doğruluk oranı elde edilmiştir.

Ruiz ve arkadaşları (2018) insansız hava araçları(İHA) tarafından elde edilen görüntüleri sınıflandırmak için İteratif K-En Yakın komşular (IKNN) tekniğini geliştirmiş. Bu teknik DVM ve geleneksel KNN'e göre %90 oranında doğruluk vermiştir.

Shi ve arkadaşı (2015) DVM ile uzak sensör görüntülerinin haritalanması üzerine bir çalışma yapmışlardır. DVM nin etkinliğini daha iyi incelemek için, farklı arazi örtülerinden oluşan ve karmaşık bir arazi kullanımı olan Gwinnett County bölgesi çalışma alanı olarak kullanılmıştır. Çalışmada arazi örtüsü sınıflandırması için DVM ile geleneksel sınıflandırıcılardan biri olan MO karşılaştırılmıştır. Belirli arazi örtüsü kategorilerinde sınıflandırma işlemi için iki yöntemin de doğru sınıflandırma yaptığı gözlemlenmiştir. Ancak karmaşık piksellerin bulunduğu sınıflarda ve benzer spektral özelliğe sahip sınıflarda DVM yönteminin sınıflandırma doğruluğunun MO'yu aştığı

görülmüştür. Sonuç olarak DVM'nin, uzaktan algılama topluluğunda yaygın olarak kullanılan sınıflandırıcılardan biri olan MO sınıflandırıcısına göre daha iyi bir performans gösterdiğini doğrulamışlardır.

Rudrapal ve arkadaşı (2015) Samson hiperspektral veri seti üzerinden bir sınıflandırma işlemi gerçekleştirmişlerdir. Veriyi daha iyi anlamak için önce denetimsiz öğrenme tekniklerinden biri olan K-Means ile kümeleme işlemi yapılmıştır. Daha sonra DVM ile sınıflandırma işlemi yapılmıştır. Toprak, su, bitki ve insan yapıları olmak üzere toplamda 4 sınıf üzerinde yapılan sınıflandırma da genel doğruluk oranı %90 dan fazla bulunmuştur. Ayrıca DVM'nin az eğitilmiş bir hiperspektral veris üzerinde de iyi sonuçlar verdiği görülmüştür.

Kalkan ve arkadaşı (2010) IKONOS görüntüsü kullanarak piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerini karşılaştırmış. Piksel tabanlı sınıflandırma için ERDAS görüntü yazılımı, nesne tabanlı sınıflandırma için e-Cognition yazılımı kullanılmış. Piksel tabanlı sınıflandırıcı için genel doğruluk oranı %92.91, nesne tabanlı sınıflandırma için %98.39 elde etmişlerdir.

Gürcan ve arkadaşları (2016) Göktürk-2 uydusu görüntülerini kullanarak arazi sınıflandırması yapmış. Geliştirdikleri En Küçük Kareler yöntemi ile Maksimum olasılık algoritmasını karşılaştırarak yaptıkları bu çalışmada sırasıyla ortalama %96.51 ve %83.13 gibi doğruluk oranları elde etmişlerdir.

Üstüner ve arkadaşı (2017) LANDSAT-8 uydu görüntüsünün arazi örtüsü/kullanımı sınıflandırılması üzerine bir çalışma yapmış. Çalışma kapsamında sınıflandırma işlemi için DVM, rastgele ormanlar, KNN makine öğrenmesi algoritmalarını kullanmış. Sınıflandırma sonucunda en yüksek doğruluk oranını %96.2 ile DVM algoritması vermiştir.

Ming ve arkadaşları (2016) arazi örtüsü kategorilerinin doğru haritalanması için Rastgele Ormanlar sınıflandırıcısını kullanmıştır. RO'da sınıflandırma doğruluğunu etkileyen optimum parametre seçimi problemi için, yapay zekada uygulanan sezgisel bir arama yöntemi olan Genetik algoritmayı (GA) kullanılmışlardır. Deneysel sonuçlar, GA'nın RO'nun parametre seçiminde iyi bir yöntem olduğunu göstermektedir. Deneyler ayrıca GA-RO yöntemini, geleneksel RO ve DVM

yöntemini kullanarak arazi örtüsü sınıflandırma sonuçlarını karşılaştırır. GA-RO yöntemi kullanıldığında, sınıflandırma doğrulukları sırasıyla% 1,02 ve% 6,64 oranında arttırdığını tespit etmişlerdir. Karşılaştırma sonuçlarında, GA-RO'nun aşırı zamana neden olmadan arazi örtüsü sınıflandırması için uygun bir çözüm olduğu kanısına varmışlardır.

Sarath ve arkadaşları (2014) HSG verisini sınıflandırmak için MO Sınıflandırıcısı, Minimum Mesafe Sınıflandırıcısı ve Paralel Yüzlü Sınıflandırıcı gibi çeşitli denetimli ve denetimsiz sınıflandırma tekniklerini kullanmıştır. Yaptıkları çalışma sonucunda MO Sınıflandırıcısının, Paralel Yüzlü Sınıflandırmaya göre daha iyi doğruluk gösterebileceğini açıklamışlardır. Ancak daha hızlı uygulamalar için MO ve Minimum Mesafe Sınıflandırıcısına göre Paralel Yüzlü Sınıflandırıcısının tercih edilebileceğini belirtmişlerdir.

Bakr ve arkadaşları (2010) çeşitli zamanlarda alınmış Landsat uydu görüntü verilerini kullanarak Mısır'daki arazi örtüsü ve kullanımının değişimlerinin tespiti üzerine çalışmalar yapmışlardır. Yaptıkları tespit için insan faaliyetleri ile doğa olayları arasındaki etkileşimi tahmin etmek için etkili yöntemler ve doğru sonuçlar sağladığını beyan etmiştir. Bu çalışmada kullanılan ana yöntemler hibrit sınıflandırma (denetimli sınıflandırma ve denetimsiz sınıflandırma) ve NDVI'dır. Çalışmalar kentsel veya yerleşik arazi, tarım arazisi, su ve çorak arazi olmak üzere dört arazi kullanımı kategorisi üzerinde yapılmıştır.

Zhang ve arkadaşları (2013), HSG'lerden arazi örtüsü özelliklerini sınıflandırmak için Meanshift segmentasyon tekniği ve sparse representation sınıflandırıcısını(SRC) kullanmışlardır. Ayrıca sınıflandırma sonrasında yanlış sınıflandırılan piksellere çoğunluk analizi uygulanarak yeni harita çıkarmışlardır. İki HSG üzerinde yaptıkları çalışmada önerilen yöntemin etkili ve iyi bir performans gösterdiğini belirtmişlerdir.

Gislason ve arkadaşları (2006) çok kaynaklı(birden çok kaynaktan gelen veriler, uydulardan alınan MSG verileri, havadan alınan HSG verileri gibi) UA ve coğrafi veri setinin sınıflandırılması için yaptıkları arazi örtüsü sınıflandırmasında RO sınıflandırıcısını kullanmıştır. Algoritma için her düğümde 500 ağaç ve 3 değişken kullanılmıştır. Arazi örtüsü on sınıf üzerinden sınıflandırılmıştır. RO su için %100 doğrulukla sınıflandırırken orman türlerinin sınıflandırmasında bu sınıfların karışık

doğasından ötürü zorlandığı görülmektedir. Sonuç olarak çalışmalarında RO'nun iyi bir performans gösterdiğini beyan etmişlerdir.

Havryliuk ve arkadaşları (2018) Landsat uydusundan alınmış multispektral görüntüler üzerinde RO sınıflandırıcısını kullanarak Ukrayna'nın Prykarpattya bölgesinde arazi örtüsü yorumlamışlardır. Çalışmaları sonucunda RO'nun çok hızlı olduğunu ve sınırlı veri kümesi üzerinde tatmin edici sonuçlar ürettiğini belirtmişlerdir. Ayrıca bu yaklaşımın çok zamanlı görüntülerle arazi örtüsündeki değişikliklerin izlenmesinde kullanılmasının iyi olduğunu beyan etmişlerdir.

Zhu ve Blumberg (2002) İsrail Birşeva bölgesinin bir ASTER görüntüsünü kullanarak DVM ile sınıflandırma yapmışlardır. Farklı derecelerde polinom çekirdekleri ve radyal temel fonksiyonu (RBF) çekirdeği kullanarak DVM sınıflandırma deneyleri yaptılar. Deney sonucunda RBF'nin sınıflandırma sonuçları, Polinom çekirdekten daha iyi sonuç verdiği görülmüştür. Genel doğrulukları % 87 ile % 91 aralığında elde ettiler.

Melgani ve Bruzzone (2004) hiyperspektral veriyi sınıflandırmak için DVM'yi kullanmıştır. Ayrıca geleneksel sınıflandırıcılara göre DVM'nin etkinliğini görmek için K-NN ve RBF sinir ağı (RBF-NN) sınıflandırıcıları ile karşılaştırıldı ve SVM, K-NN ve RBF sınıflandırıcılarından sırasıyla % 93.42, % 83.94 ve % 86.99 doğruluk elde edildi. Geleneksel öğrenme tekniklerinin aksine, girdi alanlarının boyutuna açık bir şekilde bağlı olmayan DVM'lerin, hiperspektral verilerin sınıflandırılmasında başarılı olduğunu belirtmişlerdir.

UA görüntülerinin sınıflandırılması üzerine literatürde pek çok çalışma mevcuttur. Yapılan çalışmalar incelendiğinde denetimli öğrenme, denetimsiz öğrenme, hibrit denilen denetimli ve denetimsiz öğrenme yaklaşımlarının birlikte kullanılması, çeşitli yaklaşımların birleştirilerek yeni bir yöntem oluşturularak sınıflandırma işleminin yapılması vb. birçok yöntem önerilmiştir. Tablo 2.1 ve Tablo 2.2'de literatürde UA verisinin sınıflandırılması üzerine yapılan çalışmaların özetini göstermektedir.

Tablo 2.1: Literatür İncelemesinin Özeti 1

Çalışma	Yöntem	Veri Seti	Doğruluk (%)
(Dhriti Rudrapal & Mansi Subhedar, 2015)	DVM	Samson Hiperpektral veri	90
(Kalkan & Maktav, 2010)	Piksel ve Nesne Tabanlı Karşılaştırma	IKONOS Görüntü Verisi	92.91, 98.39
(Gürcan et al., 2016)	EKY, MO	Göktürk-2 Görüntü Verisi	96.51, 83.13
(Paper et al., 2017)	DVM, KNN	Landsat-8 Görüntü Verisi	96.2
(Ming et al., 2016)	GA-RO, RO, DVM	Multispektral Veri	
(Sarath et al., 2014)	MO, MMS, PYS	Hiperspektral Veri	
(Bakr et al., 2010)	NDVI, Hibrit Sınıflandırma	LANDSAT Uydu Verisi	
(Zhang et al., 2013)	Mean-Shift, SRC	Hiperspektral Veri	
(Gislason et al., 2006)	RO	Multispektral ve Hiperspektral veri	
(Tokar et al., 2018)	RO	LANDSAT Multispektral Veri	
(G. Zhu & Blumberg, 2002).	PF-DVM, RBF-DVM	Aster Görüntü Verisi	87, 91
(Melgani & Bruzzone, 2004).	DVM, KNN, RBF-NN	Hiperspektral Veri	93.42, 83.94, 86.99

Tablo 2.2: Literatür İncelemesinin Özeti 2

Çalışma	Yöntem	Veri Seti	Doğruluk (%)
(Ghamisi et al., 2017)	DVM, RO, LR...	Hiperspektral Veri	80.18, 72.99, 80.60
(Jamil et al., n.d.)	DVM, MO	Multispektral Veri	85.99, 75.83
(Jamil & Bayram, 2018)	DVM, YSA, RO	Yüksek çözünürlüklü Ortofoto Haritaları	87, 89, 86
(Silva Junior et al., 2019)	GEOBIA	Modis Sensör Verisi	76
(Chen et al., 2018)	OSRM	Multispektral Veri	
(Pipaud & Lehmkuhl, 2017)	Mean-Shift Segmentation, DVM	SRTM Sayısal Yükseklik Verisi	
(Ruiz et al., 2018)	IKNN (DVM, KNN)	Yüksek Çözünürlüklü İHA Verisi	90
(L. Zhu et al., 2018)	GAN	Hiperspektral Veri	
(Shi & Yang, 2015)	DVM, MO	Landsat-5 Tematik Harita Verisi	

BÖLÜM 3


UZAKTAN ALGILAMA VE SINIFLANDIRMA YÖNTEMLERİ

Bu bölümde teorik olarak uzaktan algılama, uzaktan algılama verisi ve sınıflandırılması açıklanmıştır. Ayrıca çalışmada kullanılan Maksimum Olasılık, Destek Vektör Makinesi ve Yapay Sinir Ağları sınıflandırıcılarının kapsamlı bir şekilde açıklaması yapılmıştır.

3.1. Uzaktan Algılama

Dünya'nın atmosferi, okyanusları ve kara yüzeyleri hakkında bilgi toplamak için çeşitli sistemler geliştirilmiştir. Uzaktan algılama teknolojileri bu sistemlere en iyi örnektir. Uzaktan algılama kabaca belirli bir mesafeden yeryüzünden yayılan ve yansıyan elektromanyetik enerjinin temassız olarak ölçülmesi olarak ifade edilebilir. Enerjinin ölçülmesi uçaklardaki kameralardan, Dünya'nın yörüngesindeki uydulardan, okyanustaki gemilerin sonar sistemleri gibi teknolojik aletler tarafından yapılmaktadır. UA sistemleri sayesinde insanlar ulaşımı tehlikeli ve ulaşımı imkânsız gözle göremediğimiz yerler hakkında bile bilgi sahibi olabilmektedir. Örneğin insanlar ulaşılması zor olan okyanus tabanına inmeden gemideki sonar sistemi ile okyanus tabanından görüntü alabilmektedir. Yine ulaşımı zor ve tehlikeli kutup bölgelerinden, yüksek dağlık alanlardan, derin vadilerden mağaralara kadar birçok yer hakkında UA sistemleri sayesinde bilgi sahibi olmaktadır insanlar. Bununla birlikte UA insanlara küresel değişimi haritalamak ve izlemek için büyük fırsatlar verir.

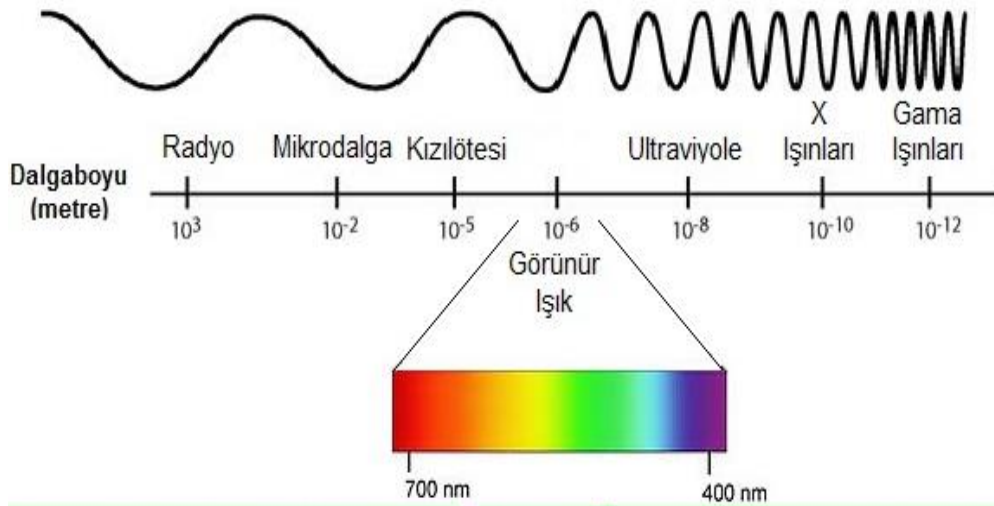
Uzaktan algılama cihazları aktif ve pasif olmak üzere iki kategoride incelenmektedir. Aktif cihazlar algılama yapmak için nesnelere ve yerlere kendi enerjisini gönderir ve yansıyan enerjiyi yine kendisi toplar. Gece gündüz fark etmeksizin aktif cihazlar veri toplayabilir. Radar ve Lidar aktif uzaktan algılama cihazlarına örnek verilebilir. Bununla birlikte pasif cihazlar enerji kaynağı olarak güneşi kullanırlar. Pasif cihazlar, güneşten gelen enerjin nesnelere veya yerlerdeki yansımasını toplayarak veri elde eder. Pasif algılama enerji kaynağı olarak güneşi kullandığı için algılama sadece gündüz yapılır. Multispektral sensörler ve hiperspektral sensörleri barındıran Landsat uyduları, Spot Uyduları insansız hava araçları pasif algılama yapan cihazlara örnek verilebilir.



Şekil 3.1.1: Pasif ve aktif sensör diyagramı.

Kaynak: NASA Applied Remote Sensing Training Program


Uzaktan algılama uydularının sahip olduğu sensörler farklı konumsal ve spektral çözünürlüklerde yeryüzündeki objeler hakkında bilgi toplayabilme kabiliyetine sahiptirler(Yüksek et al., n.d.). Uydulardan elde edilen görüntüler elektromanyetik spektrumlardaki bant sayısına ve bu bantların dar olma özelliklerine göre farklılık gösterir. İnsanlar nesnelere yansıyan enerjiyi kırmızı, yeşil ve mavi olmak üzere sadece üç kanalda görür. Gözümüzün görmediği enerji çeşitli sensörler sayesinde algılanabilir. Elektromanyetik spektrum gözle göremediğimiz ışık türleri de olmak üzere her türlü ışığı tanımlar.(Şekil 3.1.2 EMS'yi göstermektedir.) Elektromanyetik spektrumda bant adı verilen bölümler algılama cihazları tarafından ölçülen enerjinin elde edildiği yerdir. Cisimlerin yüzeylerinden yansıyan enerjinin elektromanyetik spektrumdaki bantlardaki ölçümü farklıdır.



Şekil 3.1.2: Elektromanyetik Spektrum

Kaynak: <https://gunesisigi.weebly.com/spektrum.html>

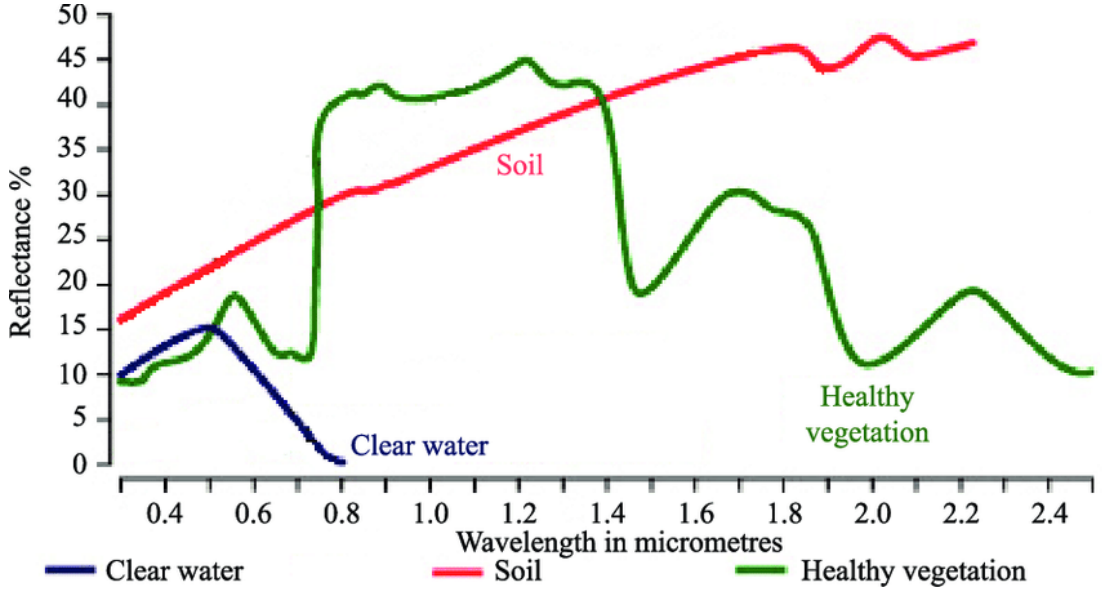
UA cihazları tarafından ölçülen dalga boyu aralıklarının sayısının miktarı yani bantların sayısı ve darlığı bize görüntülerin spektral özellikleri hakkında bilgi verir. Örneğin multispektral görüntüler EMS de birden fazla bantta ölçülen sensörlerden elde edilirler. Buna karşılık Hiperspektral görüntülerde ise cisimlerden yansıyan enerji EMS’de birçok dar ve bitişik dalga boyu bandında ölçümü olarak ifade edilebilir. Hiperspektral görüntülerin multispektral görüntülerden en belirgin farkı bant sayısı ve darlığıdır. HSG’ler daha yüksek düzeyde spektral ayrıntıya sahiptir. HSG’ler, bir piksel için elektromanyetik spektrumun görünür ve yakın kızılötesi kısmını kapsayan yüzlerce çok dar bitişik bantlı hiperspektral sensörler tarafından elde edilir, arazi örtüsü sınıflandırma görevi için hem yüksek bir spektral çözünürlük hem de bol miktarda ayırt edici bilgi sağlamaktadır(Zhang et al., 2013). Ancak HSG’nin maliyeti yüksek olduğu için ve birçok dar banta sahip olduğu için bu görüntülerle çalışmak bazen zor olabilir. Şekil 3.1.3’e bakılarak MSG ve HSG arasındaki farklılıklar görülebilir. Biz çalışmamızda daha az karmaşık olan MSG ile çalıştık.



Şekil 3.1.3: Multispektral ve Hiperspektral Görüntülerin EMS deki gösterimi

Kaynak: Altigator.com

Sensörler tarafından algılanan her nesne farklı bir spektral değere sahiptir. Bu farklı değerler sayesinde nesnelerin haritası çıkarılmaktadır. Örneğin bir araziden alınan görüntüdeki her nesne(su, ağaç, çıplak arazi, yol, yapı vb.) yaydıkları farklı enerji sayesinde birbirinden ayrılmaktadır. Şekil 3.1.4 su, toprak ve bitkilerin spektral yansımalarını göstermektedir. Fakat birbirine benzer enerji yayan nesnelere (örneğin çay bitkisi ve diğer ağaçlar gibi) birbirine benzer enerji yansıtabilir. Bu da arazi örtüsünü sınıflandırırken sınıflar arasında bir karmaşıklığa sebep olabilmektedir. Arazi örtüsü sınıflandırılmasında temel problemlerden biri olan karmaşıklık problemini en aza indirmek için çeşitli yöntemler(çoğunluk analizi vb.) geliştirilmiştir.



Şekil 3.1.4: Farklı arazi örtüleri için spektral yansımaya varyasyonu (Kırmızı çizgi toprak, Yeşil çizgi bitki ve mavi çizgi suyun spektral yansımalarını göstermektedir.

Kaynak: Kumar & Reshmidevi, 2013

Uzaktan algılanmış görüntülerden arazi örtüsünü çıkarmak için çeşitli yöntemler kullanılmaktadır. NDVI(Normalleştirilmiş Bitki Örtüsü Farkı) ve sınıflandırma işlemi bu yöntemlere örnek verilebilir. NDVI bitkinin canlılık özelliğini kullanan bir ölçümdür. Bu ölçüm bitki örtüsünün yansıttığı yakın kızıl ötesi(NIR) ve bitki örtüsünün soğurduğu kırmızı ışığın arasındaki fark ile yapılır. NDVI her zaman -1 ile +1 arasındadır. NDVI -1'e yaklaştıkça bitki örtüsünün cansızlık (su, yol, çıplak toprak) özelliği artar. NDVI +1'e yaklaştıkça bitki örtüsün yoğun, yeşil ve sağlıklı olma özellikleri artar. Arazi örtüsünü çıkarmak için kullanılan bir diğer yöntem olan sınıflandırma yönteminde görüntü analizi için farklı sınıflandırma metotları kullanılmaktadır. Sınıflandırmanın amacı, her pikseli uydu görüntülerinin spektral özelliklerine göre farklı gruplara atamaktır.

Uzaktan algılama birçok farklı alanda, geniş bir uygulama alanına sahiptir. Bu alanların bazıları şöyle ifade edilebilir;

1. Kıyı uygulamaları: Kıyı şeridi değişikliklerini izleme, kıyı şeridindeki tortuların taşınmasını izleme, kıyı özelliklerinin haritasını çıkarımı vb. uygulamalar UA verilerini kullanmaktadır. Ayrıca bu alandaki veriler, kıyı haritalama ve erozyonun önlenmesi için kullanılabilir.

2. Okyanus uygulamaları: UA verileri sayesinde Okyanus hareketleri, okyanus sıcaklığı, dalga yüksekliklerinin ölçümü ve denizlerde oluşan buz izlenebilir. Bu alandaki veriler, okyanusları ve okyanus kaynaklarının en iyi şekilde nasıl yönetileceğini ve nasıl kullanılacağını daha iyi anlamak için kullanılabilir.
3. Tehlike değerlendirmesi: Kasırgaları, depremleri, erozyonu selleri vb. tehlikeleri izlemek için UA verileri kullanılabilir. Veriler, bir doğal afetin etkilerini değerlendirmek ve tehlikeli bir olaydan önce ve sonra kullanılacak hazırlık stratejileri oluşturmak için yararlıdır.
4. Doğal kaynak yönetimi: Arazi kullanımını izleme, sulak alanların haritasını çıkarma ve vahşi yaşam habitatlarının haritasını çıkarma, bitki örtüsü haritasını çıkarma vb. birçok alanda UA verileri kullanılmaktadır. Bu alanda elde edilen veriler, kentsel büyümenin çevreye verdiği zararı en aza indirmek ve doğal kaynakların en iyi nasıl korunacağına karar vermek için kullanılabilir.

3.2. Sınıflandırma Yöntemleri

Sınıflandırma görüntü işleme alanında çokça kullanılan bir karar verme işlemidir. Uzaktan algılama görüntülerine dayalı arazi örtüsü sınıflandırması, arazi kaynaklarını izlemek, değerlendirmek ve yönetmek için önemli bir araçtır. Bununla birlikte, karmaşık arazi örtüsü kategorilerinin doğru bir şekilde haritalandırmak için sağlam sınıflandırma yöntemleri gerekmektedir. Sınıflandırmanın amacı, uydu görüntülerindeki benzer spektral özelliklere sahip pikselleri gruplandırmak ve pikselin yansıtma değerine göre yeryüzünde karşılığı olan sınıfa atamaktır.

Anderson, ABD için yaptığı bir çalışmada UA verilerini etkin bir şekilde kullanabilen bir arazi örtüsü ve arazi kullanımını sınıflandırma sistemi için bazı kriterler önermiştir. Bu tür kriterlerin kullanımı, uzak sensör görüntüleriyle kullanılmak üzere etkili sınıflandırma şemaları geliştirmeye ilgili mevcut sorunların daha iyi anlaşılmasına yönelik bir yaklaşım olarak önerilmektedir (Anderson, 1971). Anderson'ın önerdiği kriterler şöyledir:

1. Uzak sensör verilerinden arazi kullanımını ve arazi örtüsü kategorilerinin belirlenmesinde minimum yorumlama doğruluğu seviyesi en az yüzde 85 olmalıdır.
2. Çeşitli kategoriler için yorumlamanın doğruluğu yaklaşık olarak eşit olmalıdır.

3. Tekrarlanabilir veya tekrar eden sonuçlar, bir tercümandan diğerine ve bir algılama zamanından diğerine elde edilebilmelidir.
4. Sınıflandırma sistemi geniş alanlara uygulanabilir olmalıdır.
5. Sınıflandırma, bitki örtüsünün ve diğer arazi örtüsü türlerinin faaliyet için vekil olarak kullanılmasına izin vermelidir.
6. Sınıflandırma sistemi, yılın farklı zamanlarında elde edilen UA verileriyle kullanıma uygun olmalıdır.
7. Yer araştırmalarından veya daha büyük ölçekli veya gelişmiş UA verilerinin kullanımından elde edilebilecek alt kategorilerin etkin kullanımı mümkün olmalıdır.
8. Kategorilerin toplanması mümkün olmalıdır.
9. Gelecekteki arazi kullanımı verileriyle karşılaştırma mümkün olmalıdır.
10. Mümkün olduğunda arazinin birden fazla kullanımı tanınmalıdır.

Sınıflandırma işlemi için kullanılan algoritmalarda işlem birimi dikkate alınmaktadır. Arazi örtüsü sınıflandırma işlemi genel olarak piksel tabanlı ve nesne tabanlı olarak karşımıza çıkmaktadır.

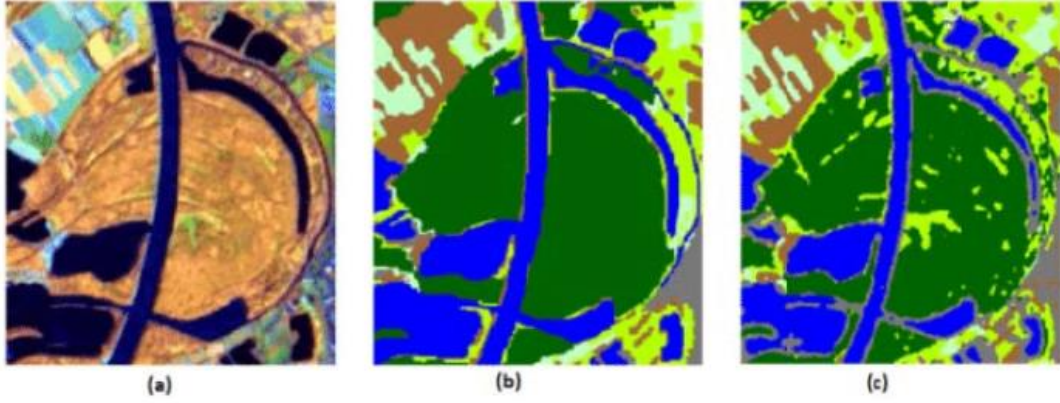
3.2.1. Piksel Tabanlı Sınıflandırma

Piksel tabanlı sınıflandırma, görüntüdeki her pikselin tek tek analizine dayanmaktadır. Tüm pikseller aynı boyutta, aynı şekildedir ve komşularıyla ilgili herhangi bir bilgi yoktur. Geçmiş çalışmalarda piksel tabanlı yaklaşımlar çokça kullanılmıştır. Ancak teknolojinin gelişmesiyle UA görüntülerindeki mekânsal çözünürlük ve boyutsal özellikler arttığı için nesne tabanlı sınıflandırma gibi yeni yöntemler geliştirilmiştir. Klasik piksel-tabanlı metotlar, yüksek çözünürlüklü görüntülerdeki nesnelerin genellikle farklı spektral özniteliklere sahip heterojen piksellerden oluşması sebebiyle nesne çıkarımı aşamasında yetersiz kalmaktadırlar(Tonbul & Kavzoğlu, 2017). Sınıflar arası spektral varyasyonlar ve sınıf içi spektral benzerlik, piksel tabanlı yaklaşımlar için daha fazla zorluk teşkil eder(Jamil et al., n.d.). Nesne tabanlı görüntü analizi yüksek çözünürlüklü görüntülerin artmasına paralel olarak uzaktan algılama alanında daha önemli bir seviyeye ulaşmış ve piksel tabanlı sınıflandırmanın önüne geçmiştir(Tonbul & Kavzoğlu, 2017).

3.2.2. Nesne Tabanlı Sınıflandırma

Uzaktan görüntü algılama sistemlerinin geliştirilmesiyle görüntü çözünürlüğü artmıştır. Buna bağlı olarak nesne tabanlı sınıflandırma yöntemi geliştirilmiştir. Nesne tabanlı sınıflandırma yöntemleri, geleneksel piksel tabanlı sınıflandırma tekniklerine kıyasla yakın zamanda geliştirilmiştir. Nesne tabanlı yöntemler, görüntü segmentasyonu yoluyla görüntü nesnelere üretir ve daha sonra pikseller yerine nesnelere üzerinde görüntü sınıflandırması yapar(Pal & Bhandari, 1992). Ayrıca nesne tabanlı yöntemlerde aynı nesneye ait piksellerin benzer spektral özelliklere sahip olduğu varsayılır. Denetimli nesne tabanlı sınıflandırma işlemleri için görüntü tipi, segmentasyon yöntemi, doğruluk değerlendirmesi, sınıflandırma algoritması, eğitim örnek kümeleri, girdi özellikleri ve hedef sınıflar gibi birçok seçenek seçilmelidir (Ma et al., 2017). Segmentasyon nesne tabanlı görüntü analizinde ilk ve önemli aşamalardan biridir. Nesne tabanlı görüntü analizi, görüntü segmentasyonu adı verilen ve homojen nesnelere elde etmek için benzer pikselleri bir araya toplama işlemiyle başlar(Tonbul & Kavzoğlu, 2017). Görüntüler segmentasyon teknikleri ile görüntü nesnelere, spektral, mekânsal bilgiler kullanılarak oluşturulur. Bu aşamada piksellerin renk, frekans, parlaklık, komşuluk vb. gibi özellikleri dikkate alınarak benzer özelliklerdeki pikseller bir nesneye gruplandırılır. Segmentasyonun amacı görüntüyü daha iyi analiz etmek için anlamlı görüntü nesnelere oluşturmaktır. Böylelikle ayrı ayrı devasa miktarda piksellerle uğraşmak yerine bu nesnelere dikkate alınarak işlemler yapılır. Nesne tabanlı yaklaşımlar, coğrafi nesnelere birden çok nesneye oluştuğunu varsaydığından, çok yüksek çözünürlüklü uzaktan algılama görüntüleri için daha uygun kabul edilir (Rajyalakshmi, Raju, & Varma, 2016). Şekil 3.2.1 Rajyalakshmi tarafından yapılmış çalışma da Nesne ve Piksel sınıflandırma sonucunu tematik harita şeklinde göstermektedir.

Günümüzde nesne tabanlı yöntemler, uygulanabilir, düzgün ve gürültüsüz bir sınıflandırma haritası sağlaması açısından piksel tabanlı yöntemlere göre daha çok tercih edilmektedir. Ancak bu tercih her zaman nesne tabanlı yöntemlerin yüksek doğruluk verdiği anlamına gelmez. Nesne tabanlı sınıflandırıcıların en büyük dezavantajı, nesnelere yanlış çıkarıldığında yanlış sınıflandırma haritasına neden olmalarıdır. Hem görüntü segmentasyon hatası hem de sınıflandırma işlemi hatası toplanır. Bir nesne yanlış sınıflandırılırsa, o nesnenin tüm pikselleri yanlış sınıflandırılır ve bu da büyük bir hataya neden olur.



Şekil 3.2.1: (a) Saf uydu görüntüsünü gösterir. (b) Uydu görüntüsünün Nesne Tabanlı olarak sınıflandırılmasını gösterir. (c) Uydu görüntüsünün Piksel Tabanlı olarak sınıflandırılmasını gösterir.

Kaynak: Rajyalakshmi et al., 2016

Hem piksel tabanlı hem de nesne tabanlı sınıflandırma işlemleri için günümüze kadar pek çok yöntem önerilmiştir. Bu yöntemlerin başında makine öğrenmesi yöntemleri gelmektedir. İlgili çalışmalar incelendiğinde makine öğrenmesi yöntemlerinin, test örnekleri ile karşılaştırıldığında eğitim verileri çok az bile olsa, uzaktan algılama verilerini sınıflandırmak için kullanılacak en etkili araç olduğu söylenebilir. Makine öğrenmesi bilinen özelliklere dayanarak öğrenilen verilerden yapılan tahminler üzerine odaklanan bir alandır. Temel olarak sayısal öğrenme ve model tanıma gibi özellikleri kullanarak veriler hakkında bilgi sağlar. Makine öğrenmesi denetimli, denetimsiz, yarı denetimli ve takviyeli öğrenme olarak ayrı ayrı kategorilerde incelenmektedir. Çalışmamızda sadece UA verilerinde çokça kullanılan denetimli öğrenme ve denetimsiz öğrenme kategorilerinden bahsedilmiştir.

I. Denetimli Öğrenme

Makine öğrenmesi yöntemlerinden en çok kullanılan yaklaşımlar denetimli öğrenme yaklaşımlarıdır. Bu yöntemde sınıflandırma işlemi kimliği belirsiz pikselleri sınıflandırmak için kimliği belli olan pikselleri örnek almaya dayanır. Kullanıcılar tarafından veri etiketlenir. Etiketlenmiş bu veriye eğitim kümesi adı verilir. Tüm makine öğrenimi teknikleri her zaman yüksek hassasiyetli bir arazi kullanımı/arazi örtüsü haritası oluşturamaz çünkü iyi sonuçlar makine öğrenimi modeli kurulumuna, eğitim örneklerine ve girdi parametrelerine bağlıdır(Talukdar et al., 2020). Başarılı bir sınıflandırma sonucu için eğitim kümesi her bir sınıfı tanımlayan homojen hücre

gruplarını içermelidir. Sınıflandırıcı algoritma eğitim kümesindeki verilerin(nesneyi, hücreyi) özelliklerini temel alarak, görüntülerdeki tüm veriyi karşılaştırarak sınıflandırma işlemini yapar.

Genel olarak Denetimli öğrenmede sınıflandırma işlemi üç adımdan oluşur bunlar:

1. Eğitim aşaması, temsili eğitim alanlarının belirlenmesi ve sayısal bir eğitim seti veya eğitim alanları olarak bilinen olay yerindeki her bir arazi örtüsü türünün spektral özelliklerinin açıklaması;
2. Sınıflandırma aşaması, görüntü veri setindeki her piksel arazi örtüsü sınıfına ayrılması.
3. Çıktı aşaması: Tematik haritalar vb.

Denetimli öğrenmede, kullanıcı sınıfları doğru bir şekilde tanımlarsa, denetimli sınıflandırmaların sonuçları denetimsiz öğrenmeden daha doğru ve kesin olur. Dolayısıyla denetimli öğrenmede kullanıcıya büyük iş düştüğünü ve sürecin kullanıcı kontrollü olduğunu söyleyebiliriz.

Denetimli öğrenme geniş bir algoritma yelpazesine sahiptir. K-En Yakın Komşu (KNN) Naive Bayes, Karar Ağaçları (KA), Maksimum Olasılık (MO), Rastgele Ormanlar(RO), Karar Ağaçları, Destek Vektör Makinesi(DVM), Yapay Sinir Ağları(YSA) sınıflandırma için kullanılan başlıca denetimli öğrenme algoritmalarındandır. Aşağıda bu algoritmaların bazılarının kısaca açıklaması verilmiştir. Ayrıca Tablo 3.1'de MO, DVM ve YSA gibi bazı yöntemler formülize edilirken kullanılan bazı notasyonalar (gösterimler) ve açıklamalarının listesi verilmiştir.

Tablo 3.1: MO, DVM ve YSA formülize edilirken kullanılan bazı notasyonlar ve açıklamalarının listesi

Gösterim	Açıklama
n	Bant sayısı
b	Bias(sapma)
m	Eğitim seti
x	Piksel vektör
d	boyut
$H1, H2$	Hiper Düzlem(DVM), Gizli katman(YSA)
α	Lagrange Çarpanı
C	Düzenleme parametresi
γ	Gama parametresi
K	Kernel(çekirdek)
φ	Transformasyon(Dönüşüm)
z	Çekirdek derecesi
y	Sınıf etiketi
$\ \cdot \ $	Öklid mesafesi
Σ	Varyans-kovaryans matrisi
$ \Sigma $	Determinant
μ	Ortalama vektör
w	Ağırlık vektörü
$P(y_i/x_i)$	i pikselinin olasılığı(olasılık yoğunluk fonksiyonu)

1. K-En yakın komşu

Tüm mevcut durumlardan benzerlik ölçüsüne göre sınıflandırma işlemini yapan bir algoritmadır. Verilerin arasındaki uzaklık ölçüsü Öklid, Manhattan, Minkowski, Gauss vb. mesafe fonksiyonları ile hesaplanmaktadır. Uzaklık hesaplanmasından sonra sınıflandırmak istenilen yeni özellik daha önceki özelliklerden k tanesine olan yakınlığa bakılarak sınıflandırma işlemi yapılır. KNN, sınıflandırma problemlerinde basit, anlaşılır ve kullanışlı olduğu için çokça kullanılmaktadır. Ancak maliyet bakımından büyük veriler üzerinde işlemleri uzun sürede gerçekleştirdiği için tercih edilmemektedir.

2. Naive Bayes Sınıflandırıcısı

Thomas Bayes'in şartlı olasılık kuralına dayanan bir denetimli öğrenme algoritmasıdır. Bu algoritma ilk olarak veri içindeki her sınıfın olasılığını bağımsız olarak hesaplar daha sonra gösterilen her örnek için olasılığı en yüksek sınıfı bulmaya çalışır. Genellikle büyük veriler üzerinde kullanılmaktadır. Çok başarılı ve popüler bir algoritmadır. Popüler olmasının sebebi sadece iyi performansı değil basit yapısı yüksek hesaplama hızı ve eksik verilere olan duyarsızlığıdır(Liu & Lei, 2006).

3. Karar Ağaçları

Belirli koşullar altında bir verinin tüm olası durumlarını ağaç-dallanma grafik yöntemiyle örnekleyen bir denetimli öğrenme algoritmasıdır(Kaur & Jindal, 2016). Bu ağaçtaki iç düğüm verinin nitelikleri üzerinde bir testi, yaprak düğümler sınıf etiketlerini temsil etmektedir. Sınıflandırma kuralı kökten yapraklara doğrudur. Karar ağaçları özyinemeli olarak verileri sınıflandırmaktadır. Her ne kadar bu işlem eğitim verilerinin maksimum doğruluğunu sağlasa da verilerin sadece belirli davranış özelliklerini tanımlayan aşırı kurallar oluşturabilir(Sehgal, Mohan, & Sandhu, 2012).


4. Rastgele Ormanlar

RO'lar, UA verilerinin sınıflandırılmasında kullanılan güçlü bir denetimli öğrenme sınıflandırma tekniklerinden biridir. Toplu öğrenme yöntemlerinden biri olan RO algoritması, sınıflandırma işlemi esnasında birden fazla karar ağacı üreterek sınıflandırma tahmini yapmaktadır. Bireysel olarak oluşturulan karar ağaçları bir araya gelerek karar ormanı oluşturur. Buradaki karar ağaçları bağlı olduğu veri setinden rastgele seçilir. Bu işlemler rastgele yapıldığı için RO'lar aşırı uyum(overfit) problemlerini gidermektedirler. RO'lar toplu öğrenme başarısı, hızlı oluşları ve aşırı uyum göstermemesindeki başarılarından dolayı arazi örtüsü sınıflandırılmasında yaygın bir şekilde kullanılmaktadır.

5. Maksimum Olasılık

MO arazi örtüsü sınıflandırılmasında kullanılan başlıca geleneksel sınıflandırıcılardan biridir. MO sınıflandırma yönteminde her bir sınıf için olasılık yoğunluk fonksiyonunun Gauss dağılımı tarafından yönetildiği varsayımına dayanmaktadır(K.

Fukunaga 1990). Bu yöntemde ana mantık eğitim kümesindeki tüm sınıflardaki verilerin ortalamasını ve varyansını bulmak ve Gauss dağılımı ile her pikselin belirlenen sınıflara ait olma olasılığını hesaplamaktır. Hesaplanan olasılıklar en yüksek hangi sınıfa yakınsa o sınıfa atanır. Bu algoritma Gauss dağılımını kullandığı için normal dağılım göstermeyen(örneğin geçiş pikselleri) sınıflarda doğruluk oranı düşebilir. Şekil 3.2.2 multispektral bir görüntünün iki boyutlu bir düzlemde Gauss dağılımı ile temsil edilen su, bitki ve topraktan oluşan spektral sınıfları göstermektedir.



Şekil 3.2.2: İki boyutlu (multispektral görüntü) düzlemde Gauss olasılık dağılımları ile temsil edilen spektral sınıflar(Su, Bitki ve toprak sınıfları)

Kaynak: Resler, 2002

MO sınıflandırıcısı, her bir banttaki her bir sınıf için istatistiklerin normal olarak dağıtıldığını(Gauss Dağılımı) varsayar ve belirli bir pikselin belirli bir sınıfa ait olma olasılığını hesaplar. Her piksel, en yüksek olasılığa (yani, maksimum olasılığa) sahip sınıfa atanır.

Olasılık şu şekilde formülize edilebilir:

$$L_k = P(k/X) = P(k) * P(X/k) / \sum P(i) * P(X/i)$$

Burada :

- L_k sınıfı k 'ya ait bir pikselin arka olasılığı olarak tanımlanır.
- $P(k)$: k sınıfının önceki olasılığı olarak tanımlanır.

- $P (X / k)$: k sınıfından X 'i gözlemlemek için koşullu olasılık veya olasılık yoğunluk işlevi
- Genellikle $P (k)$ 'nin birbirine eşit olduğu varsayılır ve $P (i) * P (X / i)$ de tüm sınıflar için ortaktır. Bu nedenle $L_k, P (X / k)$ veya olasılık yoğunluk fonksiyonuna bağlıdır.

MO'da olasılık yoğunluk fonksiyonu olarak çok değişkenli bir normal dağılım uygulanır. Normal dağılım durumunda, olasılık aşağıdaki gibi ifade edilebilir.

$$L_k(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_k|^{\frac{1}{2}}} \exp[-1/2(x-\mu_k) \Sigma_k^{-1}(x-\mu_k)^t]$$

Burad: n: bantların sayısı

x : n bantlı görüntü verisini ifade eder.

$L_k (x)$: k sınıfına ait x 'in olasılığı

μ_k : k sınıfının ortalama vektörü

Σ_k : k sınıfının varyans- kovaryans matrisi

$|\Sigma_k|$: determinant

MO yöntemi, olasılık teorisi açısından avantaja sahiptir, ancak bu avantajlardan yararlanmak için bazı noktalara dikkat edilmesi gerekir. Bu noktalar şöyle ifade edilebilir:

1. Ortalama vektörün ve verinin varyans-kovaryans matrisinin doğru bir şekilde tahmin edilmesi için her sınıf için yeterli sayıda ve doğru temsili eğitim örneği seçilmelidir.
2. Varyans-kovaryans matrisinin ters matrisi, iki bant arasında çok yüksek korelasyon olması veya kesin referans verilerinin çok homojen olması durumunda kararsız hale gelebilir. Böyle durumlarda, bant azaltılmalıdır.
3. Verinin dağılımı normal dağılıma uymaması durumunda maksimum olasılık yöntemi uygulanması zordur. Çünkü MO Gauss dağılımı tarafından yönetildiği varsayımına dayanmaktadır

6. Destek Vektör Makineleri (DVM)

İlk olarak 1960'larda Vapnik tarafından teorik temelleri atılmıştır. İstatistiksel öğrenme teorisine dayanan bir makine öğrenmesi algoritmasıdır. İstatistiksel öğrenme teorisine göre bir sınıflandırıcı kimliği bilinen eğitilmiş girdi örneklerini kullanarak kimliği belli olmayan veriyi tahmin eder(Watanachaturaporn, Arora 2004). 1995 yılında ise ilk defa bir sınıflandırma probleminin çözümünde kullanılmıştır. Destek Vektör Makineleri teori olarak iki sınıfa ait örnekleri doğrusal olarak en iyi ayıran destek vektörlerine dayanmaktadır. DVM'ler genel olarak iki grup örneklem arasındaki mesafeyi maksimize eden optimum ayıraç hiper düzlem (hyperplane) ile ikili (binary) sınıflandırma yaparlar. Hiper düzlemin sınırlarına en yakın grup elemanlarına destek vektörleri (support vectors) denir(Chaudhuri & De, 2011). Geleneksel öğrenme tekniklerinin aksine, DVM'ler, girdi alanlarının boyutluluğuna açık bir şekilde bağlı değildir(Melgani & Bruzzone, 2004). Yüksek boyutlu uzayda sınıflandırma, regresyon gibi çeşitli istatistiksel problemleri çözerler. Yüksek performanslı ve başarılı bir sınıflandırıcıdır. Parametre almazlar. Doğrusal ve doğrusal olmayan verilere uygulanabilmektedir. Destek Vektör Makineleri birçok sahada kullanılmaktadırlar. Uzaktan algılanmış görüntülerin (Multispektral, Hiperspektral) sınıflandırılmasında popüler olarak kullanılan algoritmalarından biridir. Literatürde, Rastgele ormanlar DVM UA verilerinde kullanılan en yaygın sınıflandırıcılardır(Vali et al., 2020). DVM az ve sınırlı sayıda eğitilmiş veri ile yüksek boyutlu verileri işleyebilme yetenekleri sayesinde hiperspektral verilerin sınıflandırılmasında yaygın olarak kullanılmaktadır(Dhriti Rudrapal & Mansi Subhedar, 2015; Ghamisi et al., 2017).

DVM sınıflandırıcısını daha iyi anlamak için destek vektörleri, marjın, hiper düzlem, soft marjın, hard marjın gibi bazı kavramların anlaşılması gerekmektedir. Bu kavramlar kısaca şöyle açıklanabilir:

Hiper düzlem: Bir hiper düzlem, farklı sınıf üyeliklerine sahip bir dizi nesneyi birbirinden ayıran bir karar düzlemidir.

Destek Vektörleri: Hiper düzleme en yakın olan veri noktalarıdır. Bu noktalar, kenar boşluklarını hesaplayarak ayırma çizgisini daha iyi tanımlamaya yardımcı olur.

Marjın: En yakın sınıf noktalarındaki iki çizgi arasındaki boşluktur. Bu, destek vektörleri arasındaki mesafenin hesaplanmasıdır. İyi bir sonuç için bu mesafenin

maksimum olması istenir. Veri noktalarının marjin bölgesinde bulunması soft marjin olarak ifade edilir. Bu marjin bölgesinde bulunmayan veriler doğrusaldır ve bu hard marjin olarak ifade edilir.

DVM sınıflandırıcıları şu şekilde tanımlanabilir: m bir eğitim seti olsun, (x_i, y_i) , $x=1,2,\dots, m$:

$$(x_i)^T = (x_i1, \dots, x_id) \in R^d$$

Burada d i 'nin boyutsal özelliğini gösterir. $y \in \{-1, +1\}$ kodlanmış sınıf etiketidir. Örnek x_i pozitif sınıfa atanmışsa $y_i +1$, negatif sınıfa atanmışsa $y_i -1$ olur.

Bu eğitim seti hiper düzlem $w^T x_i + b = 0$ ile ayrılabilir, burada w ağırlık vektörü ve b sapmadır. Hiper düzlemlerin (H_1 ve H_2) denklemleri aşağıdadır.

$$H_1: (w^T x_i + b) = 1$$


$$H_2: (w^T x_i + b) = -1$$

Doğru bir şekilde sınıflandırılmış noktalar aşağıda belirtilen eşitsizliği sağlamış olur.

$$y_i (w^T x + b) \geq 1 \quad (1)$$

Burada x_i için, $i=1,2,3,\dots,m$.

Hiper düzlemlerin (H_1, H_2) arasındaki mesafe $2/\|w\|$ ye eşittir.



Şekil 3.2.3: DVM ile verilerin sınıflandırılması

Kaynak: García-Gonzalo, Fernández-Muñiz, Nieto, Sánchez, & Fernández, 2016

Burada problem 1. Denkleme tabi olan $\|w\|$ 'yi en aza indirerek marjinin maksimize edilmesidir. Yani iki sınıfı birbirinden ayıran çizgilerin arasındaki mesafeyi artırmak. Bu problemi çözmek için Lagrange çarpanları kullanılır.

$$\text{Minimize } J_p = \frac{\|w\|^2}{2} + \sum_{i=1}^m \alpha_i \left[(w^T x_i + b) y_i - 1 \right] \quad (2)$$

2. Denklemede hem w hem de b 'ye göre türev alınarak ikili problem tanımlanabilir:

$$\text{Maksimize } J_d(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3)$$

$$\text{Subject to } \sum_{i=1}^m \alpha_i \cdot y_i = 0, \quad \alpha \geq 0$$

J_p yi minimize ettikten sonraki optimum ağırlıklar w (4)'deki denklem gibi göstermektedir:

$$w^* = \sum_{i=1}^m \alpha_i^* y_i x_i \quad (4)$$

(4)'deki denklemde görülen α^* i optimum Lagrange çarpanlarıdır. Lagrange çarpanları yalnızca $y_i (w^{*T} x_i + b) = 1$ olduğu zaman sıfır olmayan katsayılarıdır. Bu gözlenen x_i 'ler destek vektörleridir. Herhangi bir x_i destek vektörü için optimum sapma,

$b^* = (y_i - w^{*T} x_i)$ denklemi ile ifade edilebilir. Dolayısıyla karar fonksiyonu (5)'teki denklemi gibi ifade edilebilir.

$$f(x) = \text{sign}\left(\sum_{i=1}^m \alpha_i^* y_i x_i^T x + b^*\right) \quad (5)$$

Gerçek dünya problemlerinde giriş verisi gürültülüdür ve düzlemdeki noktasal veriler her zaman doğrusal olarak ayrılmayabilir. Noktasal verilerin marjin bölgesinde bulunması durumu soft marjin olarak ifade edilir. Soft marjin (6)'daki denklem gibi ifade edilebilir:

$$y_i (w^T x_i + b) \geq 1 - \xi_i \quad (6)$$

Burada $\zeta_i \geq 0 (i=1,2,\dots,m)$ kısıtlardaki ihmalî ölçen bir değişkendir. Optimum ayırma düzlemini elde etmek için optimizasyon kriteri aşağıdaki gibi gösterilebilir:

$$\begin{aligned} \text{Minimize } \psi &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \zeta_i \\ \text{subject to } y_i (\mathbf{w}^T \mathbf{x}_i + b) &\geq 1 - \zeta_i, \quad \zeta_i \geq 0 \quad (i = 1, \dots, m) \end{aligned} \quad (7)$$

(7)'deki denklemde ifade edilen C düzenleme parametresidir (Penalty Parameter). Bu parametrenin görevi eğitim hatasını en aza indirmek ve sınıfları ayıran çizgilerin arasını yani marjini maksimum yapmaktır.

DVM doğrusal ve doğrusal olmayan verilere uygulanabilir. Ancak doğrusal olarak ayrılmayan verilerde DVM bir φ fonksiyon kullanarak veriyi yüksek boyutlu alanda doğrusal olarak ayrılabilir hale getirir. $K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırılmasına imkân sağlamaktadır (Kavzoğlu & Çölkesen, 2010). Şekil 3.2.4'de doğrusal olarak ayrılmayan bir verinin kernel fonksiyonları kullanılarak boyut artırmasıyla nasıl ayrılabilir hale getirdiği gösterilmektedir. Bir φ fonksiyonu seçildikten sonra denklem 8 deki gibi olur:

$$\begin{aligned} \text{Maximize } J_d(\alpha) &= \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{subject to } 0 &\leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0, \quad i = 1, \dots, m \end{aligned} \quad (8)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = [\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)]$$

Burada K kernel (çekirdek) fonksiyonu ifade eder. (8) deki denklem Kernel fonksiyona göre tekrar düzenlenirse 9 daki denklem elde edilir.

$$f(\mathbf{x}) = \text{sign} \left[\sum_{i=1}^m a_i^* y_i K(\mathbf{x}_i, \mathbf{x}) + b^* \right] \quad (9)$$


Polinomal kernel ve Radial Basis fonksiyon (RBF) kernel fonksiyonlara örnek verilebilir. Kernel fonksiyonlar sayesinde veri yüksek bir boyuta getirilerek sınıflandırma işleminin yapılması sağlanır.

Polinomal Kernel: Genel olarak bu çekirdek şu şekilde tanımlanır; K çekirdek, z çekirdek derecesi, a sabit terimi olmak üzere denklem (10)'daki gibi ifade edilir.

$$K (X_1, X_2) = (a + X_1^T X_2)^c \quad (10)$$

Radial Basis fonksiyon(RBF) kernel: DVM modellerinde yaygın bir şekilde kullanılan çekirdek fonksiyonlarından biridir. RBF çekirdeği, destek vektörlerini bulur ve her bir noktanın belirli bir noktaya ne kadar benzediğini bulmaya çalışır. (11)' deki denklemde γ çekirdeğin yayılmasını ayarlayan bir parametredir. Ayrıca denklemdeki $\| x_i - x_j \|$ ifadesi x_i ve x_j arasındaki Öklid mesafesidir.

$$K_{\text{RBF}}(x_i, x_j) = \exp [-1/\gamma \cdot \| x_i - x_j \|^2] , \gamma > 0 \quad (11)$$



Şekil 3.2.4: Doğrusal olmayan verinin kernel fonsiyonla boyutunun artırılması

Kaynak: Kavzoğlu & Çölkesen, 2010

DVM sınıflandırıcısı önemli denetimli öğrenme algoritmalarındandır. Yapısı, bulundurduğu kernel fonksiyonları sayesinde doğrusal ve doğrusal olmayan verilere uygulanabilme yeteneklerine sahiptir. Ayrıca son yıllarda UA verilerinin analizi için yaygın bir şekilde kullanılan sınıflandırıcılardan biridir.

SVM'ler, birçok nedenden ötürü uzaktan algılamalı görüntü sınıflandırması için iyi yöntemlerdir(Gualtieri & Chettri, 2000). Bunlardan bir kaçışöyle açıklanabilir:

UA görüntüsü yüzbinlerce piksellerden oluşur bunların içinden yeterli sayıda eğitme piksellerinin seçimi her zaman bir problem olmuştur. Bunun yanında diğer sorunlardan biri çözünürlüğü artan UA görüntülerindeki karışık piksel sorunudur. Birden fazla sınıftan oluşan yüksek çözünürlüklü UA görüntülerindeki karışık pikseller içinde

eđitim piksellerinin seęimi ciddi bir iřtir. Bunun üstesinden gelmek için küçük bir eđitim veri kümesiyle iyi ęalışan DVM iyi bir seęim olabilir ęalışabilir.

Çok yüksek boyutlu verilerin sınıflandırılmasında iyi sonuçlar elde etmek için çok parametre gerektiren yaklaşımlara karşı DVM'ler herhangi bir parametre almadan yüksek sınıflandırma doğruluęu ile ęalışabilir. Kişisel gelirin veri setinde 123 parametre kullanılarak sınıflandırılması gibi uygulamalarda yüzlerce boyutu olan veriler için SVM'lerin yüksek sınıflandırma doğruluęu ile ęalıştığı bulunmuştur(Keerthi, 2002).

Son zamanlarda UAT gelişmesiyle multispektral ve hiperspektral verilerdeki bant sayısı artmıştır. Kaliteli bilgi elde etmek için bu tür yüksek boyutlu verilerin işlenmesi her zaman bir zorluk olarak kalacaktır. Geleneksel istatistiksel sınıflandırıcılar, çok sayıda eğitim örneğinin gereklilięi nedeniyle yüksek boyutlu verileri işleyemez. SVM'ler, sınırlı sayıda eğitim örneęi ile yüksek boyutlu verilerden doğru sınıflandırmalar üretme potansiyeline sahiptir.

SVM'ler, doğrudan eğitim örneklerinden bir karar sınırı bulmaktan ziyade marjinin maksimizasyonuna dayandıkları için aşırı uyum sorununa karşı dayanıklıdır.

SVM'nin yapısı yüksek boyutlu verilerle bile daha az karmaşıktır.

Son olarak, yeni bir parametrik olmayan sınıflandırıcı, yani karar ağacı sınıflandırıcı ile karşılaştırıldığında, bir SVM, uzmanların bilgisine büyük ölçüde baęlı olan kuralların oluşturulmasını gerektirmez. Bu, yüksek sınıflandırma doğruluęu elde etmek için çok önemlidir.

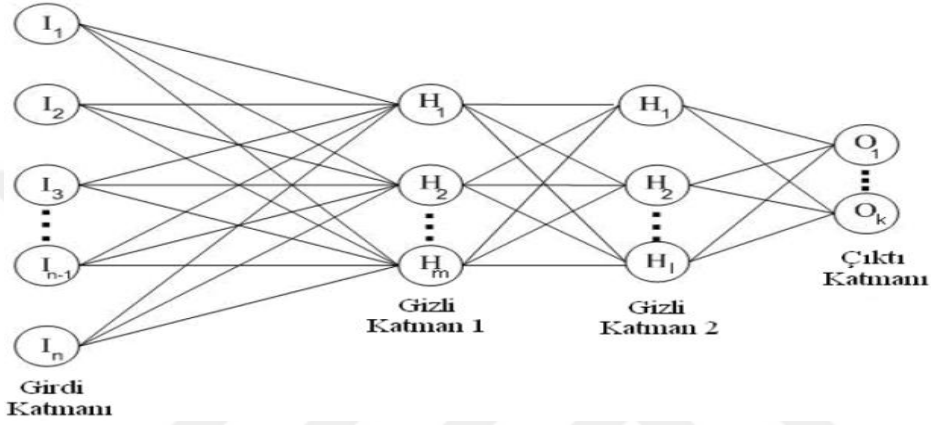
7. Yapay Sinir Ağları (YSA)

YSA, Yapay Zeka biliminin bir alt dalı olarak karşımıza çıkmaktadır. İnsan beyni ve sinir sisteminden esinlenerek oluşturulan bir modeldir. YSA, insan beyninin öğrenme yolunu taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile topladığı verilerden yeni veri üretebilme gibi temel işlevlerin gerçekleştirildięi bilgisayar yazılımlarıdır(Öztürk & Şahin, 2018). İlk yapay sinir aęı modeli 1943 yılında bir sinir hekimi olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap (A Logical Calculus of Ideas Immanent in Nervous Activity) başlıklı makale ile ortaya çıkarılmıştır(Mcculloch & Pitts, 1990). Yapıları sayesinde karmaşık problemlere karşı çözüm üretebilmektedir.

Tahmin, sınıflandırma, veri yorumlama, veriler arası ilişkileri bulma vb. pek çok problemin çözümü için sıklıkla kullanılan yapılardır. Sadece sayısal bilgilerle çalışan, bilgiyi saklama, örnekleri kullanarak öğrenme ve görülmemiş örnekler hakkında bilgi üretebilme, sınıflandırma ve şekil tamamlama gibi özelliklere sahip olan YSA, günlük hayatımızda finansal konulardan mühendislik ve tıp bilimine, üretim uygulamalarından arıza tespit ve analizine kadar birçok alanda uygulanabilmektedir(Ağyar, n.d.).

Bir sinir ağı, nöron adı verilen birimlerden oluşan bir mimaridir. İlk geliştiği zamanlar tek katmanlı yapılardan oluşan bu mimariler, doğrusal olmayan verilere uygulama zorluğundan ve verinin aşırı büyüklüğü gibi bazı nedenlerden dolayı çok katmanlı mimariler geliştirilmiştir. Bu mimariler genel olarak giriş, ara ve çıkış katmanı olmak üzere üç ana katmanda incelenir. İlk bölüm giriş katmanı olarak bilinmektedir. Dış dünyadan gelen veri, girdi olarak ilk bu katmana gelir. Giriş katmanına gelen her girdi bir nörondur ve bu girdiler herhangi bir işleme tabi tutulmadan bir sonraki katmana iletilir. Bir veya birden fazla katmandan oluşan ara katman giriş katmanından gelen bilgileri işler ve kendisine bağlı olan çıkış katmanına iletir. Ara katmanda bulunan her bir nöron giriş katmanında ve çıkış katmanında bulunan her bir nörona bağlantılıdır. Çıkış katmanı, ara katmandan gelen bilgilerin işlendiği ve giriş katmanından gelen verilere karşılık olarak çıktıların üretildiği katmandır. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir. Şekil 3.2.5'te çok katmanlı temel bir YSA yapısı gösterilmektedir. Bir YSA'nın kısaca çalışma mantığı şöyle açıklanabilir: Bir katmandaki her nöron bir üst katmanda ki nörona çeşitli ağırlıklar ile bağlıdır. Girdi katmanındaki her bir veri ağırlık değeriyle çarpılarak gizli katmana iletilir. Burada toplama fonksiyonu ile yapay sinir hücresine ağırlıklarla çarpılarak gelen girdiler, toplanıp hesaplanır. Aktivasyon fonksiyonlarıyla, önceki katmandaki tüm girdilerin ağırlıklı toplamı alınarak genel olarak doğrusal olmayan bir çıkış değeri üretilir ve bu değer bir sonraki çıkış katmanına iletilir. Dolayısıyla bir sinir ağının performansı, ağırlıkların değerine bağlıdır. Ağırlıklar eğitim sırasında ayarlanır, böylece belirli bir çıktı elde edilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir. Mimarinin girdiler için doğru çıktıları üretebilmesi için ağırlıkların doğru değerlerinin olması gerekmektedir. Buda ağın iyi bir şekilde eğitilmesi anlamına gelir. Ağırlıklar ilk olarak rastgele atanır. Eğitim

sırasında her örnek ağı gösterildiğinde ağı öğrenme kuralına göre ağırlıklar değiştirilir. Daha sonra başka bir örnek ağı sunularak ağırlıklar yine değiştirilir ve en doğru değerleri bulunmaya çalışılır. Bu işlemler ağı eğitim setindeki örneklerin tamamı için doğru çıktılar üretinceye kadar tekrarlanır. Bu sağlandıktan sonra test setindeki örnekler ağı gösterilir. Eğer ağı test setindeki örneklere doğru cevaplar verirse ağı eğitilmiş kabul edilmektedir.



Şekil 3.2.5: Bir YSA Yapısı


Kaynak: Birgül Kutlu Yrd Doç Bertan Badur Boğaziçi Üniversitesi Yönetim Bilişim Sistemleri Bölümü, 2009

İnsan beyni ve sinir sistemini taklit eden YSA yapıları sayesinde, karmaşık sınıflandırma problemleri gibi pek çok probleme çözümler üretebilmektedir. Bunun için çeşitli aktivasyon fonksiyonları kullanılır. Aktivasyon fonksiyonlarının amacı verileri anlaşılır hale getirmektir. Doğrusal fonksiyon, sigmoid fonksiyon, hiperbolik tanjant fonksiyonu aktivasyon fonksiyonlarına örnek olarak verilebilir.

1. Doğrusal fonksiyon:

Fonksiyon doğrusal olduğu için herhangi bir aralık değeri yoktur. Karmaşık verilerde yetersiz kalır.

Denklem: $f(x) = ax$ şeklindedir.




Şekil 3.2.6: Doğrusal fonksiyonun grafiksel gösterimi

2. Sigmoid fonksiyon:

YSA'larda en çok kullanılan aktivasyon fonksiyonlarından birisidir. Sigmoid fonksiyonu her zaman (0-1) aralığında değerler üretir. Sigmoid fonksiyonu türevlenebilir bir fonksiyon olduğundan öğrenme işlemi gerçekleşir. Sigmoid fonksiyon grafik olarak şekil 3.2.7'de gösterilmiştir. Sigmoid fonksiyon denklem olarak aşağıdaki gibi ifade edilir.


$$\text{Sigmoid Fonksiyon: } F(x) = \frac{1}{1 + e^{-x}}$$



Şekil 3.2.7: Sigmoid fonksiyonun grafiksel gösterimi

3. Hiperbolik Tanjant Fonksiyonu:

Yapısı sigmoid fonksiyona benzemekle birlikte değer aralığı $(-1,+1)$ 'dir. Türevinin fazla değer alması onu sigmoid fonksiyonuna göre daha avantajlı kılar. Bu da modelin daha hızlı öğrenmesini sağlar.




Şekil 3.2.8: Hiperbolik Tanjant fonksiyonunun grafiksel gösterimi

4. ReLU (Rectified Linear Unit) Fonksiyonu

Yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir. Genellikle sinir ağının gizli katmanlarında uygulanır. ReLu pozitif değerlerin geçmesine izin veren bunun yanında negatif değerleri sıfırlayan bir yapıya sahiptir. Sigmoid ve Tanjant aktivasyon fonksiyonlarının aksine çalışırken tüm nöronları çalıştırmaz bundan dolayı hesaplamalar hızlı, kolay ve daha verimlidir.

Denklem: $F(x) = \max(0, x)$ şeklinde ifade edilir.



Şekil 3.2.9: ReLu Aktivasyon fonksiyonunun grafiksel gösterimi

YSA birçok avantaja sahiptir. Bunlardan en önemlisi hem denetimli öğrenme hem de denetimsiz öğrenme yöntemlerinde kullanılan bir yaklaşım olmasıdır. Yapıları sayesinde öğrenme kabiliyeti vardır ve farklı öğrenme algoritmalarıyla öğrenebilirler. Örüntü tanıma ve sınıflandırma gibi pek çok probleme çözüm üretebilirler. Ağların özellikleri ile problemlerin özellikleri karşılaştırılarak hangi problem için hangi ağın daha uygun olduğu belirlenebilmektedir. Bunun yanında öğrenme yetenekleri sayesinde eksik veya belirsiz bilgiyle çalışabilirler. YSA genel olarak teşhis, sınıflandırma, tahmin, kontrol, veri ilişkilendirme, veri filtreleme, yorumlama gibi alanlarda kullanılmaktadır.

II. Denetimsiz Öğrenme

Denetimsiz öğrenmede girdi verileri etiketsizdir ve bu verilerin sonucu hakkında herhangi bir bilgi verilmez. Denetimsiz öğrenmenin amacı bu veriler hakkında daha fazla bilgi edinmek için verilerdeki temel yapıyı modellemektir. Sistem otomatik olarak verilerin arasındaki ilişkiyi bulmaya çalışır. Denetimsiz öğrenmede sınıflandırma için gerekli olan bölge bilgisine gerek yoktur, burada kullanıcı sadece istenen kategori sayısını belirleyebilir ve insan hatası olasılığı en aza indirilir. Sınıflandırılmış haritalar daha sonra her bir sınıfın gerçek dünyada neyi temsil ettiğini belirlemek için çalışma alanı hakkında bilgi gerektirir. Verilerden çıkarılan sonuçların doğruluğu kesin değildir. Bundan dolayı denetimli öğrenmeye göre zordur. K-Means ve ISODATA başlıca denetimsiz öğrenme algoritmalarındandır.

1. K-Means Algoritması

Kümeleme problemini çözen en basit denetimsiz öğrenme algoritmalarından biridir. Algoritmanın genel mantığı n adet veri nesnesinden oluşan bir veri kümesini (X), giriş parametresi olarak verilen küme sayısı k ($k \leq n$) adet kümeye bölmektir. K küme sayısı kullanıcı tarafından verilir. Buradaki temel amaç kümelerin, küme içi benzerliklerinin maksimum ve kümeler arası benzerliklerinin minimum olmasını sağlamaktır.

Makine Öğrenmesi algoritmaları pek çok alanda insanların problemlerine çözümler getirmiştir. Bu alanlardan biri şüphesiz UA görüntülerin sınıflandırma problemidir. Denetimli öğrenme en çok kullanılan makine öğrenmesi yaklaşımıdır. Çünkü kullanılan eğitim verisi sayesinde çıktılar kesin ve daha güvenlidir. Bizim

çalışmamızda sınıflandırma problemi için denetimli öğrenme algoritmaları kullanılmıştır.

2. ISODATA (Iterative Self Organizing Data Analyses)

Denetimsiz öğrenme yöntemlerinden yaygın bir şekilde kullanılan bir diğer yöntem ISODATA'dır. Bu yöntem minimum mesafe tekniklerini kullanarak sınıflandırma işlemlerini yapar. Bu yöntem, tekrarlı olarak veri uzayında sınıf özelliklerini hesaplama ve minimum mesafe yöntemleri ile bu özellikleri sınıflara atama ve yapılan her iterasyon sonrasında yeniden istatistik hesaplamaya dayanır. K-Means yönteminin gelişmiş hali olan ISODATA sınıflandırması, diğer sınıflandırma yöntemine göre daha esneklerdir.



BÖLÜM 4

METODOLOJİ

Bu bölümde, yüksek çözünürlüklü multispektral görüntülerden arazi örtüsü (çay alanları, diğer ağaçlar çıplak alanlar ve yol-bina) çıkarılması için önerilen yöntemlerin açıklaması yapılmıştır. Çalışma alanı ve kullanılan verilerin özellikleri detaylı olarak açıklanmıştır. Ayrıca nesne tabanlı sınıflandırma yapmanın ilk adımı olarak görülen segmentasyon ve verinin sınıflandırılması için kullanılan Maksimum Olasılık, Destek Vektör Makinaları, Yapay Sinir Ağları yöntemlerinin uygulama işlemleri açıklanmıştır.

4.1. Çalışma Alanı ve Veri Seti

Çalışma alanı olarak Türkiye'nin Karadeniz Bölgesinin doğusunda bulunan, 40.9165°K 40.8545°D koordinatlarına sahip, çay bitkisinin yoğun olarak yetiştirildiği Rize ili seçilmiştir. Yılın her zaman diliminde yağış alan bu bölge tarım ve ormancılık için oldukça verimli topraklara sahiptir. Ayrıca bulundurduğu vadiler ve dağlık bölgeleriyle çay üretimine oldukça elverişlidir. Türkiye Dünya üzerinde en çok çay tüketen ülkelerden biri olmakla birlikte dünyada çay üretiminde de altıncı sırada yer almaktadır. Türkiye'deki en büyük çay üretim merkezi Rize'dir. Bununla birlikte bu bölge, ülke ekonomisinde önemli bir role sahiptir.

Rize'den Uzaktan görüntü algılama sistemleriyle elde edilmiş, yaklaşık 7164x9360 boyutlarında 5 adet multispektral görüntü üzerinde çalışmalar yapılmıştır. Görüntüler incelediğinde, yoğun olarak çay alanlarını, çay alanları dışındaki diğer ağaçlar, ekilmemiş çıplak alanlar, yol ve yapılar görülmektedir. Şekil 4.1.1 Rize ilinin Türkiye Haritası üzerindeki yerini, ilçelerini ve oradan alınmış UA görüntülerinden bir kesit gösterilmektedir.

Çalışmamızda kullandığımız Multispektral görüntüler, 13 Mart 2013 tarihlerinde Rize'den 30 cm yer örnek mesafeli havadan UltraCam-X dijital hava kamerası ile çekilmiştir. Bu insansız hava kamerası, pankromatik, kırmızı, yeşil, mavi ve yakın kızılötesi bantlarda algılama yapabilen metrik, CCD algılayıcıya sahip bir UA kameradır. Kamera 8 bitlik radyometrik çözünürlüğe sahiptir. Uçuş yüksekliği


yaklaşık 4200 m iken, görüntüler arasında ileri ve yanal örtüşmeler sırasıyla % 70 ve % 30'dur. Görüntüler, kırmızı (R), yeşil (G), mavi (B) ve yakın kızılötesi (NIR) olmak üzere dört spektral banttandır. Bu çalışmada, kullanılan görüntüler EMI Group Inc. tarafından sağlanmıştır. Kamera ve uçuş bilgilerinin detaylı gösterimi Tablo 4.1'de verilmiştir.

Tablo 4.1: Kamera ve Uçuş Bilgileri Detayları

Parametre Adı	Detay
Yer	Rize
Yer Koordinat Bilgileri	40.9165°K 40.8545°D
Görüntü Sayısı	5
Kamera Modeli	UltraCam-X
Çözünürlük	7164x9360
Uçuş Yüksekliği	4200m
Tipi	İHA
Uçuş tarihi	13.03.2013
Radio Metrik Çözünürlük	8 bit
Örnekleme aralığı	30 cm
Spektral Bant	Kırmızı, Yeşil, Mavi, Kızıl Ötesi
Görüntü Formatı	TIFF
İleri Örtüşme	%70
Yanal Örtüşme	%30
Mercek Sistemi	Linos Vexcel Apo-Sironar digital HR



(a)



(b)



(c)



(d)


Şekil 4.1.1: (a): Rize ilinin Türkiye haritası üzerindeki yeri. (b): Rize ilinin ilçeleri ile gösterimi. (c): Rize'nin UA sistemleri tarafından alınan görüntüsü. (d): (c)'de gösterilen görüntünün sarı renkle kare içine alınan bölgenin yakınlaştırılmış görüntüsü

4.2. Görüntü Segmentasyonu (Bölütleme)

Bir görüntüyü analiz edebilmek için segmentasyon işlemi, nesne tabanlı görüntü sınıflandırmada önemli bir aşamadır. Segmentasyon, bir görüntüdeki pikselleri aynı spektral, piksel ve dokusal değerlere sahip nesnelere ayırma işlemidir. İyi bir sınıflandırma sonucu için segmentasyonun eksik veya fazla olmaması istenir. Çalışmamızda segmentasyon işlemi için grafik tabanlı minimum yayılan ağaç segmentasyonu kullanıldı. Bu algoritmada görüntüde tek piksel düzeyinde başlar ve aşağıdan yukarıya dayalı olarak çalışır. İşlem sırasında, giderek daha fazla piksel daha büyük segmentlerde bir arada gruplanır. Piksellerin benzerliği belirlenen minimum eşik değere değerlendirilir. Burada bu benzerlik değeri eşik değeri aşırsa bu pikseller birlikte gruplandırılır. Şekil 4.2.1 henüz segmentasyon işlemi uygulanmamış görüntü kesitini Şekil 4.2.2 ise bu görüntü bir kesitinin segmentasyon işlemi ile elde edilen haritasını göstermektedir.



Şekil 4.2.1: Normal görüntü kesiti



Şekil 4.2.2: Görüntü Segmentasyon haritası

4.3. Özellik Çıkarımı ve Eğitim Verisi

Uzaktan algılama görüntüleri, spektral, mekânsal, zamansal bilgi gibi özelliklerle karakterize edilir. UA verisini sınıflandırmak için spektral ve mekânsal özellikler yaygın bir şekilde kullanılmaktadır. Sınıflandırma doğruluğunu artırmak için arazi örtüsü türlerini karakterize eden özelliklerin seçimi ve çıkarımı önemli bir işlemdir. Özellik çıkarımının temel amacı veriyi makine öğrenmesi yöntemlerinin anlayabileceği hale dönüştürmektir. Bundan dolayı özellik seçimi, denetimli sınıflandırmada çok önemli bir rol oynar. Her piksel için çıkarılan özellikler Tablo 4.2’de verilmiştir.

Tablo 4.2: Her piksel için çıkarılan özellikler

Özellik Tipi	Özellikler
Spektral Özellik	Kırmızı, Yeşil, Mavi ve NIR bantlarının ortalaması, Standart Sapması, Ortalama parlaklığı
Mekansal Özellik	Mahalledeki minimum gri değer, Maksimum gri değer, Gri değerlerin modu

Nesne tabanlı görüntüleri analiz etmek için nesnelerin spektral, mekânsal özellik bilgileri kullanılır. Spektral özellikler, hedeflerin yansıyan parlaklığını tanımlar ve doğrudan sensöre yani kameraya bağlıdır. Mekansal özellik UA görüntüsünde algılanan en küçük bilgi boyutu olarak ifade edilebilir. Mekânsal özellikler multispektral ve hiperspektral gibi yüksek çözünürlüklü görüntülerin analizinde oldukça faydalıdır. Bitkilerin arasındaki spektral benzerlik(Çay bitkisi ve diğer ağaçlar gibi) yüzünden sınıflandırma işlemlerinde problemler oluşabilir. Bu tür sınıflandırma problemlerini en aza indirmek için eğitim verileri dikkatli bir şekilde seçilmelidir. Bunun yanında, kullanılan denetimli sınıflandırıcıların karmaşıklığı verinin yüksek boyutuna ve hesaplama maliyetine atfedilebilir. Bu sınıflandırıcı karmaşıklıkları iyi seçilmiş parametrelerle hafifletilebilir.


Tablo 4.3: Her sınıf için seçilen eğitim örnekleri


Sınıf Numarası	Sınıflar	Eğitim Örnekleri	Piksel Sayısı
1	Çay Alanları	14	4985
2	Diğer Ağaçlar	15	11052
3	Yol-Bina	14	3714
4	Çıplak Arazi	14	2549

Çalışmamızda ilk olarak, her sınıf için eğitim örnekleri beş adet multispektral görüntü üzerinden seçildi. Şekil 4.3.1’de üzerinde eğitim örnekleri seçilen multispektral görüntü girdisinin örnek bir kesiti gösterilmektedir. Amacımız, seçtiğimiz eğitim örneklerinden iyi bir sınıflandırma doğruluğunu elde etmektir. Daha önce de belirttiğimiz gibi herhangi bir sınıflandırıcının doğruluğu eğitim verilerinden etkilenmektedir. Bundan dolayı, her bir sınıfı en iyi şekilde temsil etmek için spektral olarak homojen örnekleri seçtik. Her sınıf için seçilen örnekler arasında ortalama ve standart sapmanın istatistiksel ölçümlerini kullanarak homojenliği daha da sağladık. Tablo 4.3, seçilen örneklerin sayısını ve seçilen bu örneklerin piksel sayısını göstermektedir. Tabloda da görüldüğü üzere eğitim örnekleri sayısını az seçtik. Bunun nedeni az seçilmiş eğitim verisine karşılık sınıflandırıcıların durumlarını gözlemlemektir. Şekil 4.3.2’de örnek girdi görüntüsü üzerinde seçilmiş örnek çay alanlarını, diğer ağaçları, ekilmemiş çıplak arazilerin ve insan yapımı yol ve binaların seçim örnekleri gösterilmiştir. Yeşil dikdörtgen içine alınmış bölgeler çay alanları, lacivert içine alınmış bölgeler diğer ağaçları, sarı çıplak arazi ve kırmızı dikdörtgen içine alınmış bölgeler yol ve bina örneklerini gösterir.




Şekil 4.3.1: Girdi Görüntüsü



 Çay alanları

 Diğer Ağaçlar

(a)



Çıplak Arazi Yol ve Bina

(b)

Şekil 4.3.2: Eğitim verisi seçim örnekleri (a):Girdi görüntüsü üzerinde işaretlenmiş örnek çay ve diğer ağaçlar. (b): İşaretlenmiş örnek insan yapımı yol-bina alanları

4.4. Sınıflandırma Yöntemleri

Uzaktan algılanan verileri analiz etmek, yorumlamak ve buna bağlı olarak yararlı bilgiler elde etmek için başvurulan yöntemlerin başında sınıflandırma işlemleri gelir. Bu çalışmada UA verilerinden arazi örtüsü çıkarımı için nesne tabanlı sınıflandırma yöntemleri kullanıldı. Sınıflandırma işlemi için uzaktan algılanmış görüntülerin sınıflandırılmasında çokça kullanılan geleneksel sınıflandırıcılardan biri olan MO ve son zamanların popüler sınıflandırıcılarından olan DVM ve YSA tercih edilmiştir.

4.4.1. Maksimum Olasılık

MO, kullanıcının eğitim alanlarını belirleyerek sınıflandırmayı denetlediği parametrik bir istatistiksel yöntemdir. MO sınıflandırıcısı, her bir banttaki her bir sınıf için istatistiklerin normal olarak dağıtıldığını(Gauss Dağılımı) varsayar ve belirli bir pikselin belirli bir sınıfa ait olma olasılığını hesaplar. Her piksel, en yüksek olasılığa

(yani, maksimum olasılığa) sahip sınıfa atanır. Çalışmamızda MO, (1) denklemini kullanarak sınıflandırma işlemini yapar.

$$g_i(x) = \ln p(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (1)$$

Bu denklemde:

i : sınıfı ifade eder

x : n boyutlu bir veriyi ifade eder. (Burada n bant sayısını ifade etmektedir.)

$P(w_i)$: görüntüde w_i sınıfının oluşma olasılığını ve tüm sınıflar için varsayımla olasılığını gösterir.

Σ_i : w_i sınıfındaki verilerin kovaryans matrisi belirleyicisi

Σ_i^{-1} : Ters matris

m_i : Ortalama vektörü ifade eder.

MO denetimli öğrenme yöntemlerinden biri olduğu için, sınıflandırma algoritmasının ihtiyaç duyduğu ortalama vektörü ve kovaryans matrisini doğru bir şekilde tahmin etmek için her sınıf için yeterli sayıda temsili eğitim örneğine ihtiyaç duyar. Denklemde gördüğümüz ortalama vektör (m_i) ve kovaryans matris her sınıf için eğitim kümesinden tahmin edilir. Genel olarak MO sınıflandırıcısı, uzaktan algılanan çok bantlı bir görüntüdeki bir pikseli, x vektörünü kullanarak w_i ürününün maksimum olduğu bir sınıfa atar. Böylece MO üzerinde sınıflandırma yaptığımız tüm arazi örtüsü piksellerini en çok benzeyen spektral sınıfa göre sınıflandırır. MO sınıflandırıcısı, farklı arazi örtüsü sınıflarından gelen ancak çok benzer spektral özelliklere sahip pikselleri ayırt etmekte güçlük çekebilir ve sonuç olarak, karmaşık peyzaj ortamı, görüntüde karışık piksel bulunma olasılığını artıracaktır. Şekil 5.1.5 MO sınıflandırma sonucu oluşan tematik haritayı gösterir.

4.4.2. Destek Vektör Makineleri

DVM az ve sınırlı sayıda eğitilmiş veri ile yüksek boyutlu verileri işleyebilme yetenekleri sayesinde UA verilerinin sınıflandırılmasında yaygın olarak kullanılmaktadır. DVM ler aynı düzlem üzerinde bulunan iki grubun üyeleri arasında maksimum uzaklıkta bir hiper düzlem oluşturarak ikili sınıflandırma yapma mantığına dayanır. Sınıflandırma işleminde ilk olarak aynı sınıfa ait tüm veri vektörleri hiper düzlemin aynı tarafına yerleştirilir. Daha sonra her iki sınıf arasındaki birbirine yakın

olan veri vektörleri arasındaki mesafe arttırılarak sınıflar birbirinden ayrılır. Doğrusal olarak ayrılabilen veride uygulanabilen bu yöntem doğrusal olmayan veride, veriyi doğrusal olarak ayrılabilir hale getirmek için kernel fonksiyonlar kullanılır. Bu kernel fonksiyonlar sayesinde düşük boyutta birbirinden ayrılmayan veri yüksek boyuta getirilerek ayrılabilir hale getirilir. Çekirdek fonksiyonlarının kullanılması, hesaplama çabasını önemli ölçüde azaltmaktadır. Uygun bir kernel fonksiyon seçimi, DVM tabanlı sınıflandırmada da önemli bir rol oynar. Doğrusal çekirdek, polinom çekirdeği, RBF çekirdeği ve sigmoid çekirdek olmak üzere dört tür çekirdek incelenmiştir.

Çalışmamızda kullandığımız veri doğrusal olarak ayrılmadığı için kernel fonksiyon kullanmamız gerekti. Bunun için verimliliği ve sağlamlığı sayesinde yaygın bir şekilde kullanılan RBF çekirdek fonksiyonunu tercih ettik. DVM aşağıdaki denklemi kullanarak marjini en üst düzeye çıkarmaya yani maksimize etmeye çalışır:

$$\begin{aligned} \text{Maximize } J_d(\alpha) &= \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{subject to } 0 &\leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0, \quad i = 1, \dots, m \end{aligned} \quad (2)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = [\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)]$$

(2) denklemdeki alfalar Lagrange Çarpanlarıdır. $K(x, y)$ kernel fonksiyon ve C düzenleme parametresidir (Penalty Parameter). Eğitim verileri yalnızca saf piksellerden oluşmaz. Bazı pikseller, seçilen eğitim verilerindeki mevcut gürültü ve sınıfların karşımı gibi nedenlerden dolayı yanlış etiketleme yüzünden karışık olabilir. Dolayısıyla bu karışık pikseller yüzünden sınıflandırma hataları ortaya çıkar. Bu hataları işlemek için C (düzenleme parametresi) kullanılır. Bu parametrenin görevi eğitim hatasını en aza indirmek ve sınıfları ayıran çizgilerin arasını yani marjini maksimum yapmaktır. C değeri eğitim verilerine ve çekirdeğin türüne bağlıdır. DVM ile sınıflandırma işlemi yapmak için düzenleme parametresi (C) ve RBF çekirdeği gamma (γ) parametrelerinin ayarlanması gerekir. Parametreler on kat çapraz doğrulama(10-fold cross validation) yöntemi ile belirlenmiştir. Eğitim verisinde en

yüksek sınıflandırma doğruluğunu veren parametreler, test için seçilmiştir. Tablo 4.4 DVM ve RBF için seçilen parametrelerin detayını göstermektedir.

Tablo 4.4: SVM ve RBF çekirdek parametreleri ve detayları

Parametre	Minimum	Maksimum	Optimal Değerler
Gamma (γ)	0.01	20	0.3
Maliyet(C)	0.01	2e+03	2.5

4.4.3. Yapay Sinir Ağları

MSG ve HSG gibi yüksek boyutlu veri setlerinin karmaşık sınıflandırma görevleri için YSA'lerin kullanımı son yıllarda geniş çapta yayılmıştır. UA verilerinin örüntü tanıma /sınıflandırma problemlerini ele alan birçok çalışma yapılmıştır. YSA uzaktan algılamış görüntülerin sınıflandırılmasında kullanılan bir diğer önemli sınıflandırıcıdır. İnsan beyni ve sinir sisteminden esinlenerek oluşturulan bu model yapay zeka tekniklerinden biridir. YSA'lar karmaşık sınıflandırma problemlerine çözüm üretebilirler. Bunun için çeşitli aktivasyon fonksiyonlarını kullanır. Aktivasyon fonksiyonlarının amacı verileri anlaşılır hale getirmektir. Doğrusal fonksiyon, sigmoid fonksiyon, hiperbolik tanjant fonksiyonu aktivasyon fonksiyonlarına örnek olarak verilebilir. YSA ile sınıflandırma yapmak için bazı parametrelerin ayarlanması gerekir. Bu parametrelerden öğrenme oranı ve momentum ayarlanması gereken temel parametrelerdendir. Yaptığımız çalışmada optimum öğrenme oranı parametresi için 0.001 ile 0.5 aralığı, momentum ise 0 ile 1 aralığı belirlenmiştir. Öğrenme oranı için optimal oran 0.2, momentum için optimal oran ise 0,9 olarak elde edilmiştir. İterasyon sayısı 1000 olarak belirlendi. Çalışmamızda ağdaki nöronlar için sigmoid fonksiyonu kullanılmıştır. Sigmoid fonksiyonu her zaman (0-1) aralığında değerler üretir. Bu sayede büyük değerlerle uğraşılmasına gerek kalmaz. Bu çalışmada, giriş, gizli, çıkış nöronları ile üç katmanlı ileri beslemeli bir sinir ağı modeli kullanılmıştır. Giriş nöronu, giriş vektörüyle eşleşen sabit sayıda nörona sahipken, çıkış katmanında her sınıfı temsil eden yalnızca 4 nöron vardır. Nöron sayısı değişebilir ve bizim durumumuzda tek katmanlı 200 nöron optimum sonuçlar üretti. Tablo 4.5 YSA için ayarlanan parametreleri ve bu parametrelerin detaylarını göstermektedir.

Tablo 4.5: YSA sınıflandırıcısı için kullanılan parametrelerin detayları

Parametre	Minimum	Maksimum	Optimal Değer
Öğrenme Oranı	0.001	0.5	0.2
Momentum	0.1	0.9	0,9
Gizli Katmanlar	-	-	1
Gizli Nöronlar	-	-	200
Çıkış Nöronları	-	-	4
Aktivasyon Fonksiyonu	-	-	Sigmoid
İterasyon Sayısı	-	-	1000

4.5. Değerlendirme Ölçütleri

Kullanılan bir sınıflandırma modelinin performansı seçilen eğitim verilerine, test verilerine sınıf dağılımına bağlı olabilir. Veri setindeki örneklemin nasıl yapılacağını gösteren çeşitli değerlendirme yöntemleri vardır. Rastgele Öğrenme Yöntemi, Hold Out(Dışarıda Tutma), K-Fold Cross Validetion(K katmanlı Çapraz Doğrulama) bu değerlendirme yöntemlerine örnek olarak verilebilir. Bizim çalışmamızda K-Fold Çapraz doğrulama yöntemi kullanılmıştır.

K-Fold Çapraz Doğrulama, kullandığımız sınıflandırıcı modelin başarısının rastgele olup olmadığı hakkında bilgi verir. Kısaca modeli açıklayacak olursak; bu model veriyi belirlenen bir k sayısına göre eşit parçalara bölerek, her bir parçanın hem eğitim hem de test için kullanılmasını sağlar. Böylece modelimiz verimizi dağılım ve parçalanmadan kaynaklanan sapma ve hataları minimum seviyeye indirir.

Çalışmamızda kullandığımız MO, DVM ve YSA sınıflandırıcılarının performanslarını görmek için şu kriterleri kullandık:

Recall(Duyarlılık): Geliştirdiğimiz modelin pozitif durumları ne kadar başarılı tahmin ettiğini gösterir.

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Psitives} + \text{False Negatives}}$$

Precision(Hassasiyet): Model burada pozitif olarak tahminde bulunduğumuz verilerin kaçının gerçekten pozitif olduğunu gösterir.

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

F1 Score(F1 Skoru): Bu hesaplama Recall ve Precision değerlerinin harmonik ortalaması alınarak yapılır.

$$\text{F1 Score} = 2 * \frac{\text{Recall} * \text{Precision}}{\text{Recall} + \text{Precision}}$$

Accuracy(Doğruluk): Bir modelin başarısı ölçülürken kullanılan en yaygın yöntemlerden biri doğruluk oranıdır. Doğruluk ölçütü bize modelin doğru bir şekilde eğitilip eğitilmediği ve genel performansı hakkında bilgi sahibi olmamızı sağlar. Bu ölçüt, doğru sınıflandırılmış örnek sayısının toplam örnek sayısına oranı olarak hesaplanır.

$$\text{Accuracy} = \frac{\text{True Positives} + \text{True Negative}}{\text{TruePositives} + \text{TrueNegatives} + \text{FalsePositives} + \text{FalseNegatives}}$$

Kullandığımız DVM ve YSA modelleri için bahsettiğimiz ölçütler kullanılarak performans analizi yapılmıştır. Buna bağlı olarak her sınıf(Çay alanları, Diğer Alanlar, Çıplak arazi ve Yol-Yapı) için en uygun model aranmıştır.

BÖLÜM 5


DENEYSEL SONUÇLAR

Multispektral görüntülerden arazi örtüsü sınıflandırması yapmak için öncelikle her sınıf için eğitim örnekleri hazırladık. Sınıflandırma doğruluğu eğitim örneklerine dayandığından, seçimlerimizi karmaşık olmayan net spektral bölgelerde yaptık. Çay alanları spektral olarak homojen bir dağılım gösterirken, diğer ağaçlar farklı ağaç türleri barındırdığı için değişen spektral ve dokusal özelliklere sahip olduğu belirlenmiştir. Aynı şekilde çıplak arazi ve yol-bina alanlarının değişen spektral ve dokusal özelliklere sahip olduğu belirlenmiştir. Her bir sınıf için seçtiğimiz örnek sayısı Tablo 4.3'de özetlenmiştir. Örnek sayısının az olmasının nedeni, az eğitim verisi ile nasıl bir sınıflandırma doğruluğu elde edilebileceği sorusuna cevap bulmaktır.

Modelin doğrulanması için K-fold cross validation(çapraz doğrulama) uygulandı(K=10 olarak seçildi). Veri kümesi, on alt veri kümelerine bölünmüştür. Eğitim sürecinde, verilerin geri kalanı eğitim için kullanılırken, doğrulama için tek bir alt veri kullanıldı. Bu işlem on kez tekrarlandı ve her bir yinleme için hatalar hesaplandı. Son olarak, toplam hatalar, tüm tekrardaki tüm hataların ortalaması alınarak doğrulama için tahmin edildi. Bu şekilde model, tüm eğitim örnekleri kullanılarak eğitildi.

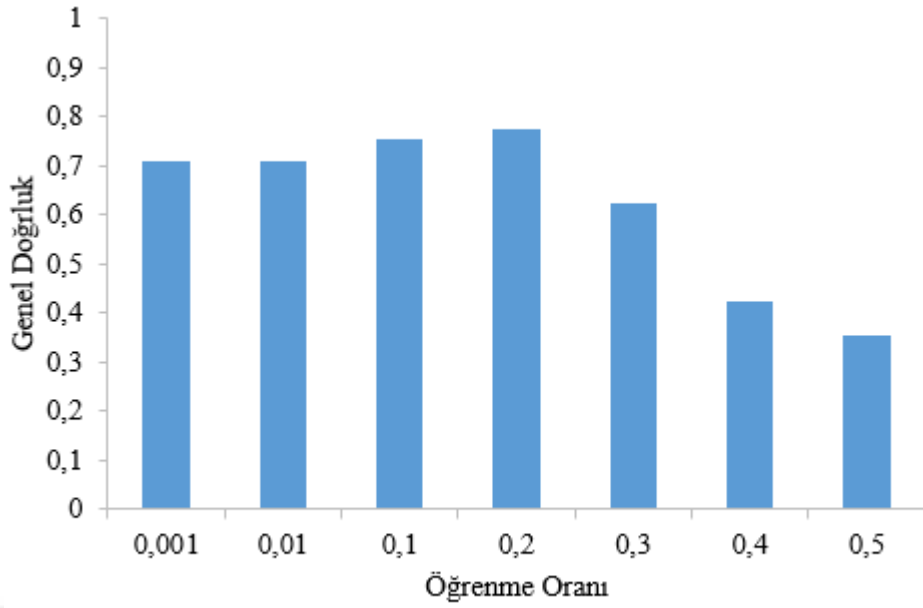
Denetimli sınıflandırıcılar genellikle bazı parametre değerlerinin ayarlanmasını gerektirir. DVM için ampirik yöntemle (önceden yapılmış deneyler göz önünde bulundurularak) iki parametre elde edildi: maliyet (cost) ve gama. Gama çekirdeği işlevi değeri 0.333, maliyet ise 250 olarak ayarlandı. DVM ve RBF çekirdeği için ayarlanan parametreler ve detayları Tablo 4.4'de gösterilmiştir. Ayrıca Şekil 5.1.1 DVM ve RBF için her bir C ve γ çifti için elde edilen parametre aralığı aramasının

görsel bir temsili ve karşılık gelen doğruluklar gösterilmektedir.

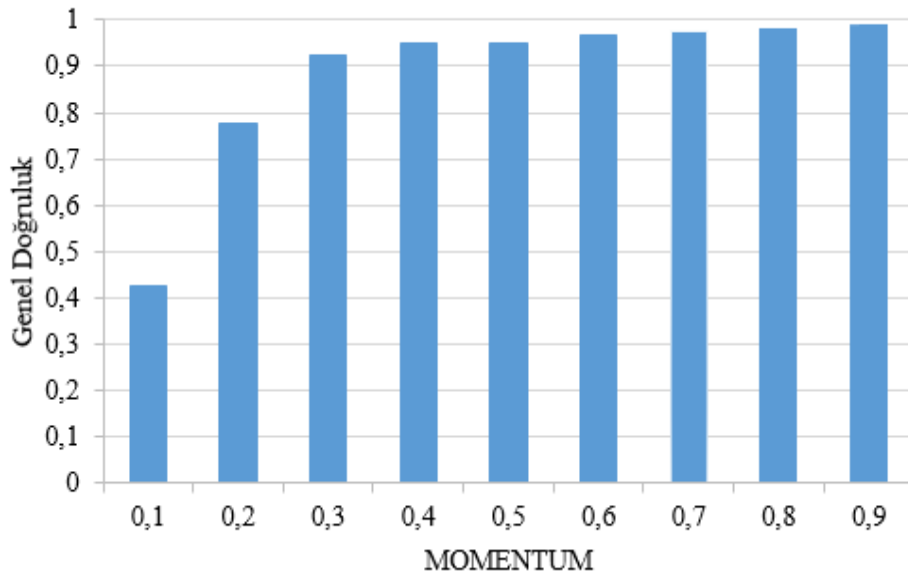


Şekil 5.1.1: DVM ve RBF için elde edilen maliyet(C) ve gama parametrelerinin görsel hali

YSA ile sınıflandırma yapmak için de ayrıca öğrenme oranı, momentum iterasyon gibi bazı parametrelerin ayarlanması gerekir. YSA için öğrenme oranı 0.2, momentum 0.9 ve gizli katmandaki nöron sayısı olarak 200 belirlendi. YSA için diğer parametreler sabit tutuldu. YSA için ayarlanan parametrelerin detayları Tablo 4.5’de gösterilmiştir. Şekil 5.1.2 ve Şekil 5.1.3, YSA sınıflandırıcısı için öğrenme oranı ve momentum için elde edilen genel doğruluğun grafikte gösterimi verilmiştir. Şekil 5.1.2’de öğrenme oranı parametresinin 0.2’ye kadar olan değerlerin sınıflandırma doğruluğunun birbirine yakın olduğu ve diğer değerlere göre yüksek olduğu görülmektedir. Bu değer arttıkça, sınıflandırıcının doğruluğu yavaş yavaş azalmaya başlamıştır. Aynı şekilde, Şekil 5.1.3’te görüldüğü gibi 0.3 den 0.9 kadar olan momentum değerlerinin genel doğruluk oranlarının birbirine yakın olduğu ancak en yüksek doğruluk oranını 0.9 değerinin verdiği görülmektedir. Bu yüzden çalışmamızda kullanılan veri setinde maksimum doğruluk sağlandığı için 0.9 değeri seçilmiştir.



Şekil 5.1.2: YSA için öğrenme oranı ve genel doğruluk grafiği



Şekil 5.1.3: YSA için momentum ve genel doğruluk grafiği

Modeller eğitildikten sonra, arazi örtüsü haritalarının oluşturulması için son test görüntüleri sunulmuştur. Her sınıflandırıcı için elde edilen sonuçlar, sınıflandırmanın doğruluğunu artırmak için sonradan işlenmiştir(Post-Processed). Bu teknikler, nesnelerdeki küçük delikleri kaldırmak ve farklı sınıflar arasında pürüzsüz bir sınır

oluşturmak için morfolojik açılma ve kapanmayı içerir. Ayrıca, elde edilen haritalar, sınıflandırma doğruluğunu daha da iyileştirmek için bir çoğunluk analiz adımından geçirildi. Çoğunluk analizinin temel amacı, mahalledeki hakim sınıfa bir piksel atamaktır. Çoğunluk analizinden sonra elde edilen sınıflandırma haritası Şekil 5.1.8'de gösterilmektedir. Şekilden de anlaşılacağı üzere sınıflandırma sonucu oluşan haritada bir alanda hangi sınıf çoğunluktaysa aykırı pikseller o sınıfa atanmıştır. Aykırı pikselleri diğer ağaç sınıfı için oldukça fazladır. Bu durum sınıf içindeki farklı ağaç türlerinden kaynaklandığı ve bu türlerden bazılarının çay bitkisiyle benzer spektral özellik gösterdiği düşünülmektedir. Hali hazırda görüntüler incelendiğinde diğer ağaç türlerinin renk, parlaklık doku olarak değişen özellikler bulundurduğu görülebilir. Tablo 5.1, MO, DVM ve YSA sınıflandırıcıları için elde edilen sonuçları ve Çoğunluk Analizi sonucunda elde edilen sonuçları özetlemektedir.

Tablo 5.1: Kullanılan sınıflandırıcıların ve uygulanan Çoğunluk Analizinin doğruluk analizleri(%)

Sınıflar	Kullanılan Sınıflandırıcılar			
	MO	DVM	YSA	Çoğunluk Analizi
Çay Alanları	72.68	68.43	82.08	88.63
Diğer Ağaçlar	78.03	89.67	80.04	83.46
Yol-Bina	64.98	71.06	79.25	82.38
Çıplak Araziler	79.93	85.51	89.01	90.25
Ortalama	73.90	78.67	82.60	86.18

MO, DVM ve YSA için ortalama doğruluk sırasıyla % 73.90 % 78.67 ve % 85.10 olarak elde edildi. Genel sonuçlar, YSA'nin arazi örtüsü sınıflandırması için DVM ve MO sınıflandırıcısına kıyasla daha etkili olduğunu göstermektedir. Benzer şekilde, her sınıf için YSA için elde edilen doğruluk daha iyiydi. Çay alanları ve diğer ağaçlar için elde edilen sonuçlar, YSA'ye göre DVM ve ML sınıflandırıcıları için düşük kalmıştır. Bu durum, bu iki sınıf arasındaki spektral benzerliğe atfedilebilir, çünkü her ikisi de benzer bitki örtüsüne sahiptir, ancak dokuları farklıdır ve bazı durumlarda DVM ve MO sınıflandırıcıları tarafından yakalanmadığı muhtemeldir. Bunun yanında yol ve çıplak arazi sınıflarında da bazı karışıklıklar oluştu. Bu da bu iki sınıf arasındaki


spektral benzerliğe bağlanabilir. Çünkü görüntülerde de görüldüğü gibi yolların çoğu topraktır ve muhtemelen sınıflandırıcılar bunu ayırt etmekte zorlanmıştır. Yol-bina ve çıplak arazi sınıflarının sınıflandırma doğruluğu için en yüksek doğruluk YSA'da görülmektedir. Çoğunluk analizinin uygulanması, tüm sınıflar için % 86.18 ortalama doğruluk sağlayan oldukça tatmin edici sonuçlar üretti. Dahası, çoğunluk analizi sayesinde hem MO, hem DVM hem de YSA sınıflandırıcıları için her bir sınıfın doğruluğu daha da arttı. Bu sonuçlar, arazi örtüsü sınıflandırmasında daha yüksek sınıflandırma doğruluğu elde etmek için bir son işlem adımı olarak çoğunluk analizinin yararlı olduğunu göstermektedir.




Şekil 5.1.4: Herhangi bir işlem uygulanmamış orijinal görüntü kesiti




Şekil 5.1.5: MO sınıflandırma sonucu oluşan harita



Şekil 5.1.6: DVM sınıflandırma sonucu oluşan harita



Şekil 5.1.7: YSA sınıflandırma sonucu oluşan harita



Şekil 5.1.8: Post-Procession Çoğunluk analizi sonucu oluşan harita

Şekil 5.1.5, 5.1.6, 5.1.7 ve 5.1.8 de gösterilen haritalarda, yeşil renkli alanlar çay alanlarını, lacivert renkli alanlar çay dışındaki diğer ağaçları, sarı renkli alanlar ekilmemiş çıplak arazileri ve kırmızı renkli alanlar yol ve yapıları(ev-bina vb.) göstermektedir.

BÖLÜM 6

SONUÇ VE GELECEK ÇALIŞMALAR

Gelişen teknolojiyle paralel bir gelişim gösteren UAT, yüksek çözünürlüklü ve büyük boyutta veriler (Multispektral, Hiperspektral veriler gibi) sağlamaktadır. Bu verilerin işlenmesi ve analiz edilmesi için geçmişten günümüze kadar pek çok çalışma yürütülmüştür. UA verileri için arazi örtüsü sınıflandırma bu çalışmalardan biridir. Sunulan tez çalışması, uçak üzerindeki Ultracam-X kamerası tarafından sağlanan yüksek çözünürlüklü multispektral görüntülerden makine öğrenmesi yöntemlerini kullanarak arazi örtüsü sınıflandırması üzerine odaklanır. MO, DVM ve YSA sınıflandırma için kullanılan makine öğrenmesi yöntemleridir. Bu yöntemlerin seçilmesindeki amaç MO gibi geleneksel bir yöntemi YSA ve DVM gibi günümüzde sıkça kullanılan popüler yöntemlerle kıyaslamak, yapılan çalışmalarda az sayıdaki eğitim verisi üzerindeki başarısı kanıtlanan DVM'nin yeteneğini görmek, UA görüntülerindeki çay alanlarının sınıflandırması için en iyi yöntemi bulmaktır.

Çalışmamızda Rize ilinden alınmış UA görüntülerinden makine öğrenmesi yöntemleri kullanılarak yapılan arazi örtüsü sınıflandırılması işlemlerinden bir takım sonuçlar elde edilmiştir. Bu bölümde, ilk olarak yukarıdaki sonuçlardan ve tartışmalardan, Rize şehrinde arazi örtüsünün dağılımları tematik haritalar ve istatistiksel tablolara bakılarak nihai sonuç çıkarılmıştır. Daha sonra sonuçların doğruluğunu artırmak için gelecekte yapılması planlanan çalışmalardan bahsedilmiştir.

Günümüzde UA verilerinin anlaşılabilir hale getirilmesi için en yaygın kullanılan yöntemlerin başında sınıflandırma yaklaşımları gelmektedir. Havadan ve uydulardan alınan UA görüntülerin kalitesinin, çözünürlüğünün (Multispektral ve Hiperspektral görüntüler gibi) ve sayısının artması gibi nedenlerden dolayı verilerin işlenmesi, anlaşılabilir hale getirilmesi giderek önem kazanmaktadır. Dolayısıyla UA verilerinden sınıflandırma yöntemi ile arazi örtüsü tespiti önemli bir araştırma konusu olmuştur. Bu nedenle, bu çalışmada etiketlenmiş(eğitilmiş) veri gerektiren denetimli sınıflandırma yöntemlerinin(MO, DVM ve YSA) arazi örtüsü sınıflandırılması için uygulanması ve performanslarının karşılaştırılması üzerine çalışılmıştır. Arazi örtüsü genel olarak çay alanları, diğer ağaçlar, çıplak araziler ve yol-bina olmak üzere dört

sınıf üzerinden işlemlere tabii tutulmuştur. Bizim çalışmamızdan elde ettiğimiz sonuçlar, arazi örtüsünü sınıflandırmak için MO, DVM ve YSA yöntemlerinin kullanılmasının etkili ve uygulanabilir olduğunu göstermektedir. Verilerin ve işlemlerin doğruluğu ile ilgili sorunlar olsa da, UA görüntülerinden arazi örtüsü tespiti yapmak için kullanılan yöntemler oldukça tatmin edici sonuçlar üretmiştir. Bununla birlikte DVM ve YSA yöntemlerinin az eğitilmiş veride bile iyi sonuçlar ürettiği görülmüştür. Bu çalışmada genel olarak, güvenilir ve doğru sınıflandırılmış arazi örtüsü haritaları oluşturmak için, üç tür sınıflandırma yaklaşımı (MO, DVM ve YSA) ve çoğunluk analizi (Post-Processed, Majority Analyses) kullanılmıştır. MO, DVM ve YSA için ortalama doğruluk oranları sırasıyla % 73.90 % 78.67 ve <a% 85.10 idi. Elde edilen doğruluk oranlarına bakılırsa, kullanılan makine öğrenmesi yöntemlerinin UA verilerinin sınıflandırılmasında yararlı olduğu söylenebilir. Sınıflandırmanın doğruluğu önemlidir, çünkü bu doğruluk oranlarına bakılarak yöntemin başarısı hakkında konuşulabilir. Sınıflandırma doğruluğunu artırmak için daha sonra Çoğunluk Analizi uygulandı. Uygulanan Çoğunluk analizi, tüm sınıflar için yaklaşık % 88.18 ortalama doğruluk oranıyla oldukça tatmin edici sonuçlar üretti.

Özetle, Bu çalışmada, uzaktan algılanan multispektral görüntülerden arazi örtüsü sınıflandırması problemi araştırılmıştır. Görüntülerdeki spektral ve mekansal özellikler birleştirildi ve sınıflandırma için yaygın olarak üç denetimli sınıflandırıcı (MO, DVM ve YSA) kullanıldı. Görüntülerdeki genel dağılım baz alınarak dört sınıf (çay alanları, diğer ağaçlar, yol ve inşaat alanları ve çıplak arazi) tanımlandı. Ayrıca, sınıflandırıcıların etkinliklerini görmek için test örneklerine kıyasla daha az sayıda eğitim örneği seçtik. Deneysel sonuçlar, YSA'nın doğruluk açısından her bir sınıf için MO sınıflandırıcısı ve DVM'den daha etkili olduğunu göstermiştir. Bunun yanında, son işlem olarak kullanılan çoğunluk analizini sınıflandırmanın genel doğruluğunu arttırdı.

Açıkçası, önerilen yöntemin, spektral benzerlik nedeniyle çay bitkisi ve diğer ağaç türleri arasında, çıplak alanların yol-bina sınıfları arasında yanlış sınıflandırmalar olması gibi bazı problemleri vardır. Sınıflandırma doğruluklarını artırmak için gelecekte bazı çalışmaların yapılması planlanmaktadır. Planladığımız bu çalışmalarda odaklanacağımız nokta otomatik olarak özellik çıkarımları yapmak olacaktır. Bunun için Evrişimli sinir ağları (CNN- Convolutional Neural Networks) gibi derin

öğrenmeye dayalı yaklaşımların kullanılması planlanmaktadır. Bu yaklaşım, sonuç olarak sınıflandırma doğruluğunu artırmaya ve oldukça ayırt edici özelliklerin elde edilmesine yardımcı olacaktır. Dahası, derin öğrenme daha büyük eğitim verisi gerektirdiğinden, her sınıf için etiketlerle daha fazla eğitim örneği hazırlayacağız. Böylece arazi örtüsü sınıflandırılması konusu üzerine bu alana katkılar sağlanacaktır.



KAYNAKÇA

- Ağyar, Z. (n.d.). *1E0E9686a06655F_Ek. 662*.
- Anderson, J. R. (1971). Land-Use Classification Schemes-used in selected recent geographic applications of remote sensing. *Photogrammetric Engineering*, 37(4), 379–387. Retrieved from https://www.asprs.org/wp-content/uploads/pers/1971journal/apr/1971_apr_379-387.pdf
- Bakr, N., Weindorf, D. C., Bahnassy, M. H., Marei, S. M., & El-Badawi, M. M. (2010). Monitoring land cover changes in a newly reclaimed area of Egypt using multi-temporal Landsat data. *Applied Geography*, 30(4), 592–605. <https://doi.org/10.1016/j.apgeog.2009.10.008>
- Belward, A. S., & Skøien, J. O. (2015). Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 115–128. <https://doi.org/10.1016/j.isprsjprs.2014.03.009>
- Birgöl Kutlu Yrd Doç Bertan Badur Boğaziçi Üniversitesi Yönetim Bilişim Sistemleri Bölümü, D. (2009). *YapaSinir Ağları ile Borsa Endeksi Tahmini*.
- Chaudhuri, A., & De, K. (2011). Fuzzy Support Vector Machine for bankruptcy prediction. *Applied Soft Computing Journal*, 11(2), 2472–2486. <https://doi.org/10.1016/j.asoc.2010.10.003>
- Chen, Y., Ge, Y., Heuvelink, G. B. M., An, R., & Chan, Y. (2018). Object-based superresolution land-cover mapping from remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 56(1), 328–340. <https://doi.org/10.1109/TGRS.2017.2747624>
- Dhriti Rudrapal, & Mansi Subhedar. (2015). Land Cover Classification using Support Vector Machine. *International Journal of Engineering Research And*, V4(09), 584–588. <https://doi.org/10.17577/ijertv4is090611>
- García-Gonzalo, E., Fernández-Muñiz, Z., Nieto, P. J. G., Sánchez, A. B., & Fernández, M. M. (2016). Hard-rock stability analysis for span design in entry-type excavations with learning classifiers. *Materials*, 9(7), 1–19.

<https://doi.org/10.3390/ma9070531>

Ghamisi, P., Plaza, J., Chen, Y., Li, J., & Plaza, A. J. (2017, March 1). Advanced Spectral Classifiers for Hyperspectral Images: A review. *IEEE Geoscience and Remote Sensing Magazine*, Vol. 5, pp. 8–32. <https://doi.org/10.1109/MGRS.2016.2616418>

Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294–300. <https://doi.org/10.1016/j.patrec.2005.08.011>

Gualtieri, J. A., & Chettri, S. (2000). Support Vector Machines for classification of hyperspectral data. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2, 813–815. <https://doi.org/10.1109/igarss.2000.861712>

Gürçan, İ., Teke, M., & Leloğlu, U. M. (2016). *Göktürk - 2 Uydu için Arazi Sınıflandırması Land use / Land cover Classification for G öktürk-2 Satellite*. (May), 1–4. <https://doi.org/10.1109/SIU.2016.7496185>

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), 89–94. <https://doi.org/10.1109/JSTARS.2017.2756864>

Jamil, A., Bayram, B., & Seker, D. Z. (n.d.). *Mapping Hazelnut Trees from high resolution digital orthophoto maps: A Comparative analysis of an object and pixel-based approach Disaster Management View project AUTOMATIC 3D SHORELINE EXTRACTION AND ANALYSIS FROM UAV AND UAV-LIDAR DATA FOR SUSTANIABLE S*. Retrieved from <https://www.researchgate.net/publication/331466399>

Kalkan, K., & Maktav, D. (2010). *Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği) NESNE TABANLI VE PİKSEL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI (IKONOS ÖRNEĞİ)*. (January).

Kaur, S., & Jindal, S. (2016). *02.Nvae10084*. 3(11), 6–14.

Kavzoğlu, T., & Çölkesen, İ. (2010). *Destek Vektör Makineleri ile Uydu*

Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi (Investigation of the Effects of Kernel Functions in Satellite Image Classification Using Support Vector Machines). (October 2016), 73–82.

Keerthi, S. S. (2002). Efficient tuning of SVM hyperparameters using radius/margin bound and iterative algorithms. *IEEE Transactions on Neural Networks*, 13(5), 1225–1229. <https://doi.org/10.1109/TNN.2002.1031955>

Kumar, D. N., & Reshmidevi, T. V. (2013). Remote sensing applications in water resources. *Journal of the Indian Institute of Science*, 93(2), 163–188.

Liu, P., & Lei, L. (2006). Missing data treatment methods and NBI model. *Proceedings - ISDA 2006: Sixth International Conference on Intelligent Systems Design and Applications*, 1, 633–638. <https://doi.org/10.1109/ISDA.2006.194>

Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>

Mcculloch, W. S., & Pitts, W. (1990). A logical calculus nervous activity. *Bulletin of Mathematical Biology*, 52(1), 99–115.

McHaffie, P., Hwang, S., & Follett, C. (2018). Introduction to Remote Sensing and GIS. *GIS: An Introduction to Mapping Technologies*, 239–270. <https://doi.org/10.1201/9780429441028-9>

Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778–1790. <https://doi.org/10.1109/TGRS.2004.831865>

Ming, D., Zhou, T., Wang, M., & Tan, T. (2016). Land cover classification using random forest with genetic algorithm-based parameter optimization. *Journal of Applied Remote Sensing*, 10(3), 035021. <https://doi.org/10.1117/1.jrs.10.035021>

Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekaya Genel Bir Bakış. *Takvimi Vekayi*, 6(2), 25–36. Retrieved from <http://www.sloi.org/sloi-name-of-this-article>

Pal, N. R., & Bhandari, D. (1992). On object background classification. *International*

Journal of Systems Science, 23(11), 1903–1920.
<https://doi.org/10.1080/00207729208949429>

- Paper, C., Changes, T., Using, R., & Satellite, M. (2017). *LANDSAT-8 Uydu Görüntüsü ile Arazi Örtüsü Sınıflandırması İçin Makine Öğrenme Algoritmalarının Kullanılması (The use of machine learning algorithms in Landsat-8 satellite image classification)*. (July).
- Pipaud, I., & Lehmkuhl, F. (2017). Object-based delineation and classification of alluvial fans by application of mean-shift segmentation and support vector machines. *Geomorphology*, 293, 178–200.
<https://doi.org/10.1016/j.geomorph.2017.05.013>
- Rajyalakshmi, D., Raju, K. K., & Varma, G. P. S. (2016). Taxonomy of Satellite Image and Validation Using Statistical Inference. *Proceedings - 6th International Advanced Computing Conference, IACC 2016*, (February 2016), 352–361.
<https://doi.org/10.1109/IACC.2016.72>
- Resler, L. M. (2002). Remote Sensing and Image Analysis. In *Geomorphology* (Vol. 46). [https://doi.org/10.1016/s0169-555x\(01\)00164-7](https://doi.org/10.1016/s0169-555x(01)00164-7)
- Richards, J. A. (2013). Remote sensing digital image analysis: An introduction. *Remote Sensing Digital Image Analysis: An Introduction*, 9783642300, 1–494.
<https://doi.org/10.1007/978-3-642-30062-2>
- Ruiz, L. F. C., Guasselli, L. A., Caten, A. ten, & Zanotta, D. C. (2018). Iterative K-Nearest Neighbors Algorithm (IKNN) for submeter spatial resolution image classification obtained by Unmanned Aerial Vehicle (UAV). *International Journal of Remote Sensing*, 39(15–16), 5043–5058.
<https://doi.org/10.1080/01431161.2018.1444296>
- Sarath, T., Nagalakshmi, G., & Jyothi, S. (2014). A Study on Hyperspectral Remote Sensing Classifications. *International Journal of Computer Applications. International Conference on Information and Communication Technologies*, 0975–8887.
- Sehgal, L., Mohan, N., & Sandhu, P. S. (2012). Quality Prediction of Function Based Software Using Decision Tree Approach. *International Conference on Computer Engineering and Multimedia Technologies (ICCEMT'2012)*, 43–47.

- Shi, D., & Yang, X. (2015). *Support Vector Machines for Land Cover Mapping from Remote Sensor Imagery*. 265–279. https://doi.org/10.1007/978-94-017-9813-6_13
- Silva Junior, C. A. da, Nanni, M. R., Oliveira-Júnior, J. F. de, Cezar, E., Teodoro, P. E., Delgado, R. C., ... Chicati, M. L. (2019). Object-based image analysis supported by data mining to discriminate large areas of soybean. *International Journal of Digital Earth*, 12(3), 270–292. <https://doi.org/10.1080/17538947.2017.1421722>
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y. A., & Rahman, A. (2020). Land-use land-cover classification by machine learning classifiers for satellite observations-A review. *Remote Sensing*, 12(7). <https://doi.org/10.3390/rs12071135>
- Tokar, O., Vovk, O., Kolyasa, L., Havryliuk, S., & Korol, M. (2018). Using the random forest classification for land cover interpretation of landsat images in the prykarpattya region of Ukraine. *2018 IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies, CSIT 2018 - Proceedings, 1*(September), 241–244. <https://doi.org/10.1109/STC-CSIT.2018.8526646>
- Tonbul, H., & Kavzoğlu, T. (2017). *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi Nesne- Tabanlı Sınıflandırmada Segmentasyon (Bölütleme) Kalitesinin Sınıflandırma Doğruluğu Üzerine Etkisinin İncelenmesi Investigation of The Effect of Segmentation Quality on Object-Base*. 17, 118–125.
- Vali, A., Comai, S., & Matteucci, M. (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15). <https://doi.org/10.3390/RS12152495>
- Yüksek, G., Enstitüsü, T., Mühendisliği, F., & Kocaeli, G. (n.d.). *Uzaktan algılama teknolojileri ve uygulama alanları*.
- Zhang, X., Li, Y., Zheng, Y., Hou, B., & Hou, X. (2013). Joint segmentation and classification of hyperspectral image using meanshift and sparse representation classifier. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1971–1974. <https://doi.org/10.1109/IGARSS.2013.6723194>

Zhu, G., & Blumberg, D. G. (2002). Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote Sensing of Environment*, 80(2), 233–240. [https://doi.org/10.1016/S0034-4257\(01\)00305-4](https://doi.org/10.1016/S0034-4257(01)00305-4)

Zhu, L., Chen, Y., Ghamisi, P., & Benediktsson, J. A. (2018). Generative Adversarial Networks for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5046–5063. <https://doi.org/10.1109/TGRS.2018.2805286>

<http://ziraat.erdogan.edu.tr/tr/page/rize-hakkinda/1147>



ÖZGEÇMİŞ

Fatma KİRAÇ

A. EĞİTİM

Yüksek Lisans: İstanbul Sabahattin Zaim Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce), 2018-

Lisans: Sakarya Üniversitesi, Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilgisayar Mühendisliği, 2017

B. MESLEKİ DENEYİM

2018-2020 Özel bir şirkette İnsan Kaynakları ve Muhasebe Yöneticisi