

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

PİKSEL TABANLI VE NESNE TABANLI GÖRÜNTÜ SINIFLANDIRMA
YÖNTEMLERİNİN PERFORMANSLARININ İNCELENMESİ

YÜKSEK LİSANS TEZİ

Ahmed İSAM HUSSEİN

ARALIK 2024
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

PİKSEL TABANLI VE NESNE TABANLI GÖRÜNTÜ SINIFLANDIRMA
YÖNTEMLERİNİN PERFORMANSLARININ İNCELENMESİ İ

Ahmed İSAM HUSSEİN

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
“HARİTA YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 30 / 10/ 2024

Tezin Savunma Tarihi : 02 / 12/ 2024

Tez Danışmanı : Doç. Dr. Esra TUNÇ GÖRMÜŞ

Trabzon 2024

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Harita Mühendisliği Anabilim Dalında
Ahmed İSAM HUSSEİN Tarafından Hazırlanan

PİKSEL TABANLI VE NESNE TABANLI GÖRÜNTÜ SINIFLANDIRMA
YÖNTEMLERİNİN PERFORMANSLARININ İNCELENMESİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 07 / 11/ 2024 gün ve 2076. sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Doç. Dr. Özlem AKAR

Üye : Doc. Dr. Esra TUNÇ GÖRMÜŞ

Üye : Doç. Dr. Volkan YILMAZ

Prof. Dr. Asim KADIOĞLU
Enstitü Müdürü

ÖNSÖZ

“Piksel Tabanlı ve Nesne Tabanlı Görüntü Sınıflandırma Yöntemlerinin Performanslarının İncelenmesi” başlıklı bu çalışma, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı Yüksek Lisans Programında bir yüksek lisans tezi olarak hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Doç. Dr. Esra TUNÇ GÖRMÜŞ’e teşekkürlerimi sunarım.

Yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocalarım Sayın Doç. Dr. Volkan YILMAZ’a, Sayın Prof. Faruk YILDIRIM’a ve Sayın Prof. Fevzi KARSLI’ya, eğitim öğretim hayatımda katkısı olan tüm hocalarıma ve ortak olarak çalışmalar yürüttüğümüz ve tez çalışması süresinde de hiçbir yardımdan kaçınmayan arkadaşım İrem Özge YAMAN ve Şule YAMAN’a teşekkür ederim.

Tez çalışması sürecinde bana desteklerini esirgemeyen Harita Mühendisliği Bölümündeki tüm değerli hocalarıma ve asistan arkadaşlarıma teşekkürlerimi sunarım. Son olarak doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Aygün ŞENGÜL ve babam İsam ŞENGÜL’a, teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Ahmed ISAM HUSSEIN

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Piksel Tabanlı ve Nesne Tabanlı Görüntü Sınıflandırma Yöntemlerinin Performanslarının İncelenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Doc. Dr. Esra TUNÇ GÖRMÜŞ’n sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 02/12/2024

Ahmed İsam HUSSEİN

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XII
1. GENEL BİLGİLER.....	1
1.1. Konu ve Kapsam.....	1
1.2. Uzaktan Algılama	2
1.2.1. Sayısal Görüntü ve Özellikleri	3
1.2.2. Görüntü Yorumlama Elemanları.....	6
1.2.3. Sınıflandırma.....	9
2. YAPILAN ÇALIŞMALAR.....	18
3. BULGULAR	21
3.1. Veri seti Ve Yöntemler	21
3.1.1. Çalışma Alanı ve Uzaktan Algılanan Veriler.....	21
3.1.2. Veri İşleme ve Görüntü Segmentasyonu.....	24
3.1.3. Eğitim Veri Seti.....	27
3.1.4. Doğrulama Örnek Toplama.....	30
3.1.5. Denetimli Sınıflandırma Yöntemleri.....	30
3.1.6. Çapraz Doğrulama Parametre Ayarı	33
3.1.7. Sınıflandırma ve Replikasyonlar	34
3.1.8 Hata Değerlendirmesi.....	35
3.2. Araştırma Bulguları	35
3.2.1. Doğruluk Değerlendirmesi	35
3.2.2. Piksel Tabanlı Sınıflandırma.....	37
3.2.3. Nesne Tabanlı Sınıflandırma.....	40

3.2.4. Piksel Tabanlı Sınıflandırma İle Nesne Tabanlı Sınıflandırma Karşılaştırması.....	41
3.2.5. Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Google Earth ile Karşılaştırması.....	51
3.2.6. Görsel Analiz.....	58
4. TARTIŞMA.....	60
5. SONUÇLAR.....	64
6. ÖNERİLER	66
7. KAYNAKLAR.....	67
ÖZGEÇMİŞ	



Yüksek Lisans Tezi

ÖZET

PİKSEL TABANLI VE NESNE TABANLI GÖRÜNTÜ SINIFLANDIRMA
YÖNTEMLERİNİN PERFORMANSLARININ İNCELENMESİ

Ahmed İSAM HUSSEİN

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Esra TUNÇ GÖRMÜŞ
2024, 71 Sayfa

Bu araştırmada, SENTINEL-2 ve LANDSAT-9 kullanılarak büyük ölçekli uzaktan algılanan veri kümeleri beş denetimli algoritma, Support Vector Machine (SVM), Maximum Likelihood Classification (MLC), Minimum Distance Classification (MDC), Artificial Neural Net Classification (ANN) ve eCognition - Support Vector Machine (ECO-SVM) ile sınıflandırılmış ve performansları incelenmiştir. Genel doğruluk oranları, örnek boyutları 200 ile 403 arasında değişmiştir. Çalışmada, büyük eğitim setlerinin küçük eğitim setlerine kıyasla daha yüksek doğruluk oranı verdiği görülmüştür. Hem SENTINEL-2 hem de LANDSAT-9 verilerinde, büyük eğitim setleri kullanıldığında daha yüksek doğruluk oranları elde edilmiştir. Doğruluk oranı, aynı sınıflandırıcı ve eğitim örneği miktarı kullanılsa bile farklı eğitim örnekleri ile yapılan sınıflandırmalar arasında değişiklik göstermiştir. Bu nedenle, eğitim setinin boyutuna bağlı olarak bazı algoritmalar diğerlerinden daha fazla doğruluk sunabilir. Çalışmanın sonuçlarına göre, nesne tabanlı sınıflandırmaların sonuçları, piksel tabanlı sınıflandırmadan daha yüksek doğruluk oranları sunmuştur. SVM, hem SENTINEL-2 hem de LANDSAT-9 verilerinde en yüksek doğruluk oranını sağlamıştır.

Anahtar Kelimeler: Piksel Tabanlı, Nesne Tabanlı, Görüntü

Master Thesis

SUMMARY

INVESTIGATING THE PERFORMANCE OF PIXEL-BASED AND OBJECT-BASED IMAGE CLASSIFICATION METHODS

Ahmed İSAM HUSSEİN

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Map Engineering Program
Supervisor: Doc. Dr. Esra TUNÇ GÖRMÜŞ
2024, 71 Pages

In this research, large-scale remotely sensed datasets namely SENTINEL-2 and LANDSAT- 9 were classified by five supervised algorithms, Support Vector Machine (SVM), Maximum Likelihood Classification (MLC), Minimum Distance Classification (MDC), Artificial Neural Net Classification (ANN) and eCognition - Support Vector Machine (ECO-SVM) depending on the amount of training samples. The overall accuracy ranged from 200 to 403 sample sizes. In the study, it was observed that large training sets gave higher accuracy rates compared to small training sets. For both SENTINEL-2 and LANDSAT-9 data, higher accuracy rates were obtained when using large training sets. Accuracy varied between classifications with different training samples, even when using the same classifier and training sample size. Therefore, depending on the size of the training set, some algorithms may be more accurate than others. According to the results of the study, Results of object-based classifications have provided higher accuracy rates than pixel-based classification. SVM provided the highest accuracy in both SENTINEL-2 and LANDSAT-9 data. In SENTINEL-2, the pixel-based classification algorithm ANN gave the second highest result, while in LANDSAT-9, the pixel-based SVM gave the second highest result. In general, higher accuracy rates were obtained when using larger sample sizes.

Key Words: Pixel-based, Object-based, Image.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Elektromanyetik spektrum.....	4
Şekil 2.	Görüntü yorumlama elemanları.....	6
Şekil 3.	Doku ve desen özellikleri	8
Şekil 4.	eCognition görüntü segmentasyonu	14
Şekil 5.	Satranç tahtası bölümlendirme görüntü segmentasyonu	14
Şekil 6.	Quadtree tabanlı görüntü segmentasyonu	15
Şekil 7.	Spektral fark algoritmaları görüntü segmentasyonu.....	15
Şekil 8.	Multiresolution segmentation	16
Şekil 9.	(a) Çalışma alanı.....	212
Şekil 10.	landsat-9 (b) B2_B3_B4_B5_B8 (c) NDVI	22
Şekil 11.	Sentinel-2 (d) B2_B3_B4_B8 (e) NDVI.....	22
Şekil 12.	Eğitim için örnek görüntü nesnelerinin konumu	30
Şekil 13.	Arcmap Şekil 9.ten google earth'e atılan nokta görüntüsü	34
Şekil 14.	Denetlenen sınıflandırmaların ve eğitim seti boyutunun ortalama genel doğruluğu.....	36
Şekil 15.	Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için piksel tabanlı genel doğruluk grafiği	42
Şekil 16.	Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için nesne tabanlı genel doğruluk grafiği.....	42
Şekil 17.	Landsat-9 Sentinel-2'nin Piksel tabanlı ve Nesne tabanlının en yüksek sınıflandırıcının sonuçları	43
Şekil 18.	Landsat-9 piksel tabanlı ve nesne tabanlı arazi örtüsü sınıflandırması	44
Şekil 19.	Sentinel-2 piksel tabanlı ve nesne tabanlı arazi örtüsü sınıflandırması.....	48
Şekil 20.	Sentinel-2 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği.....	52
Şekil 21.	Landsat-9 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği	53
Şekil 22.	Sentinel-2 ve Landsat-9 için nesne tabanlı sınıflandırma zemin gerçeği	57
Şekil 23.	ENVI ve eCognition yazılım türlerinin karşılaştırma sonuçları	58
Şekil 24.	Araştırma alanının genel arazi örtüsü sınıflandırmasına bir örnek.....	59

TABLolar DİZİNİ

Sayfa No

Tablo 1.	Segmentasyon kalite metrikleri. $Ar(i)$ toplam referans alanını göstermekte, $As(j)$ ele alınan segmentlerin toplam alanını göstermektedir.....	19
Tablo 2.	Piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma arasındaki farklar.....	20
Tablo 3.	Arazi örtüsü sınıfları.....	24
Tablo 4.	Cochran formülünde kullanılan Z değeri.....	29
Tablo 5.	Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için piksel tabanlı genel doğruluk	42
Tablo 6.	Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için nesne tabanlı genel doğruluk	43
Tablo 7.	Landsat-9 Sentinel-2'nin piksel tabanlı ve nesne tabanlının en yüksek sınıflandırıcının sonuçları	43
Tablo 8.	Landsat-9 piksel tabanlı 200 örnek boyutundan yapılan maximum likelihood sınıflandırma doğruluk oranı	45
Tablo 9.	Landsat-9 piksel tabanlı 200 örnek boyutundan yapılan minimum distance sınıflandırma doğruluk oranı	45
Tablo 10.	Landsat-9 Piksel Tabanlı 200 örnek boyutundan yapılan neural net sınıflandırma doğruluk oranı	45
Tablo 11.	Landsat-9 piksel tabanlı 200 örnek boyutundan yapılan support vector machine sınıflandırma doğruluk oranı.....	46
Tablo 12.	Landsat-9 Nesne Tabanlı 200 örnek boyutundan yapılan Sınıflandırma doğruluk oranı	46
Tablo 13.	Landsat-9 piksel tabanlı 403 örnek boyutundan yapılan maximum likelihood sınıflandırma doğruluk oranı	46
Tablo 14.	Landsat-9 piksel tabanlı 403 örnek boyutundan yapılan minimum distance sınıflandırma doğruluk oranı.	46
Tablo 15.	Landsat-9 piksel tabanlı 403 örnek boyutundan yapılan neural net sınıflandırma doğruluk oranı	47
Tablo 16.	Landsat-9 piksel tabanlı 403 örnek boyutundan yapılan support vector machine sınıflandırma doğruluk oranı.....	47
Tablo 17.	Landsat-9 nesne tabanlı 403 örnek boyutundan yapılan sınıflandırma doğruluk oranı	47
Tablo 18.	Sentinel-2 piksel tabanlı 200 örnek boyutundan yapılan maximum likelihood sınıflandırma doğruluk oranı	49

Tablo 19. Sentinel-2 piksel tabanlı 200 örnek boyutundan yapılan minimum distance sınıflandırma doğruluk oranı	49
Tablo 20. Sentinel-2 piksel tabanlı 200 örnek boyutundan yapılan neural net sınıflandırma doğruluk oranı	49
Tablo 21. Sentinel-2 piksel tabanlı 200 örnek boyutundan yapılan support vector machine sınıflandırma doğruluk oranı.....	49
Tablo 22. Sentinel-2 nesne tabanlı 200 örnek boyutundan yapılan sınıflandırma doğruluk oranı	50
Tablo 23. Sentinel-2 piksel tabanlı 403 örnek boyutundan yapılan maximum likelihood sınıflandırma doğruluk oranı	50
Tablo 24. Sentinel-2 piksel tabanlı 403 örnek boyutundan yapılan minimum distance sınıflandırma doğruluk oranı	50
Tablo 25. Sentinel-2 piksel tabanlı 403 örnek boyutundan yapılan neural net sınıflandırma doğruluk oranı	50
Tablo 26. Sentinel-2 piksel tabanlı 403 örnek boyutundan yapılan support vector machine sınıflandırma doğruluk oranı.....	51
Tablo 27. Sentinel-2 nesne tabanlı 403 örnek boyutundan yapılan sınıflandırma doğruluk oranı	51
Tablo 28. Sentinel-2 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği.....	53
Tablo 29. Landsat-9 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği.....	53
Tablo 30. Sentinel-2’de 200 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı.....	54
Tablo 31. Sentinel-2’de 200 örnek boyutu için piksel tabanlı (ANN) sınıflandırmanın gerçek zemin doğruluk oranı	54
Tablo 32. Sentinel-2’de 403 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı.....	55
Tablo 33. Sentinel-2’de 403 örnek boyutu için piksel tabanlı (ANN) sınıflandırmanın gerçek zemin doğruluk oranı	55
Tablo 34. Landsat-9’da 200 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı.....	55
Tablo 35. Landsat-9’da 200 örnek boyutu için piksel tabanlı (svm) sınıflandırmanın gerçek zemin doğruluk oranı	56
Tablo 36. Landsat-9’da 403 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı.....	56
Tablo 37. Landsat-9’da 403 örnek boyutu için piksel tabanlı (svm) sınıflandırmanın gerçek zemin doğruluk oranı	56
Tablo 38. Sentinel-2 ve landsat-9 için nesne tabanlı sınıflandırma zemin gerçeği.	57
Tablo 39. ENVI ve eCognition yazılım türlerinin karşılaştırma sonuçları	58

SEMBOLLER VE KISALTMALAR DİZİNİ

nm	: Nanometre.
μm	: Micrometre.
n°	: Cochran'ın örneklem büyüklüğü önerisi.
N	: Popülasyon büyüklüğü.
Z	: (genellikle %95 için 1.96 alınır).
p	: Popülasyonun incelenen özelliğine sahip olan bireylerin tahmini yüzdesi.
e	: Kabul edilebilir hata miktarı.
n	: Örneklem büyüklüğü.
q	: (1-p) anlamına gelir.
ANN	: Yapay Sinir Ağları
EMS	: Elektromanyetik Spektrum
ESP2	: Çoklu Çözünürlüklü Segmentasyon Ölçek Parametresi
GEOBIA	: Coğrafi Nesne Tabanlı Görüntü Analizi
GIS	: Coğrafi Bilgi Sistemleri
IR	: Kızılötesi
ISODATA	: Tekrarlayan Kendini Organize Eden Veri
İHA	: İnsansız Hava Araçları
MDC	: Minimum Mesafe Sınıflandırması
MLC	: Maksimum Olabilirlik Sınıflandırması
MRS	: Çoklu Çözünürlüklü Segmentasyon
NDVI	: Normalized Difference Vegetation Index
NIR	: Yakın Kızılötesi
OLI-2	: Operasyonel Arazi Görüntüleyici
PAN	: Pankromatik
RGB	: Mavi, Yeşil Ve Kırmızı Bantlar
SP	: Ölçek Parametresi
SVM	: Destek Vektör Makineleri
SWIR	: Kısa Dalga Kızılötesi Spektral Aralığında
UV	: Spektrum Görüntü Bölgesi
VNIR	: Yakın Kızılötesi

1. GENEL BİLGİLER

1.1. Konu ve Kapsam

Görüntü sınıflandırma, bilgisayarla görüntü işleme alanlarında önemli bir konudur. Piksel tabanlı ve nesne tabanlı görüntü sınıflandırma yöntemleri, bu alanda yaygın olarak kullanılan iki ana yaklaşımdır. Piksel tabanlı görüntü sınıflandırma, her bir pikselin tek tek sınıflandırılması üzerine odaklanır. Bu yöntemde, her pikselin çevresindeki piksellerin özellikleri analiz edilerek sınıflandırma yapılır. Bu yaklaşım, yüksek çözünürlük ve detaylı analiz avantajı sunarken, büyük veri setlerinde yüksek hesaplama maliyeti ve gürültüye duyarlılık gibi dezavantajlara sahiptir.

Diğer yandan, nesne tabanlı görüntü sınıflandırma, görüntüyü nesne ve segmentler bazında sınıflandırmayı amaçlar. Bu yöntemde, öncelikle görüntü segmentlere ayrılır ve ardından bu segmentler sınıflandırılır. Nesne tabanlı yaklaşım, daha az gürültüye duyarlılık ve yüksek doğruluk gibi avantajlar sunarken, doğru segmentasyon yapmanın zorluğu ve bazı detayların kaybolma olasılığı gibi dezavantajlar barındırır. Performans karşılaştırmasında doğruluk, hassasiyet, geri çağırma, hesaplama zamanı ve maliyeti ile genelleme yeteneği gibi ölçütler kullanılır. Piksel tabanlı yöntemler, uydu görüntüleri gibi detaylı analiz gerektiren alanlarda daha uygun olabilirken, nesne tabanlı yöntemler tıbbi görüntülerde organ ve tümör gibi yapıların sınıflandırılmasında veya endüstriyel uygulamalarda üretim hatalarının tespitinde daha doğru sonuçlar verebilir. Sonuç olarak, piksel tabanlı ve nesne tabanlı görüntü sınıflandırma yöntemlerinin performanslarının incelenmesi, uygulama alanına bağlı olarak değişkenlik gösterir. Her iki yöntemin de kendine özgü avantajları ve dezavantajları vardır. Spesifik bir uygulama için en iyi yöntemi belirlemek, verinin özelliklerine, sınıflandırmanın gereksinimlerine ve hesaplama kaynaklarına bağlıdır. Bu nedenle, her iki yöntemin de performanslarının titizlikle değerlendirilmesi ve uygulama alanına göre en uygun yöntemin seçilmesi önemlidir.

1.2. Uzaktan Algılama

Uzaktan algılama, genel anlamda cisimlerle fiziksel bir temasta bulunmaksızın onlar hakkında bilgi edinilmesi, tanınması, çevrelerinden ayırt edilmesi ve bu bilgilerin görüntü şeklinde oluşturulması bilimi olarak tanımlanır. Teknik anlamda ise, yeryüzü hakkında onunla fiziksel temasta bulunmaksızın bilgi edinilmesi ve incelenmesidir. Uzaktan algılama, çeşitli alanlarda kullanılan çok yönlü bir teknolojidir. Arazilerin mevcut durumunun belirlenmesi, haritalanması, planlanması, takip edilmesi, tahriplerin saptanması ve doğal kaynakların yönetimi gibi birçok alanda etkili bir şekilde kullanılmaktadır. Bu teknoloji genellikle uzaktan algılama araçlarıyla yeryüzünden toplanan verilerin analizi ve yorumlanmasıyla gerçekleştirilmektedir (Bilgili vd., 2006).

Uzaktan algılama teknolojileri, yeryüzünden yansıyan veya yayılan elektromanyetik enerjinin algılanması, kaydedilmesi, elde edilen verinin işlenmesi ve analiz edilmesinde kullanıldığı görülmektedir. Bu teknolojiler, uydu görüntüleme, hava fotoğrafçılığı, lidar, termal görüntüleme ve spektral görüntüleme gibi çeşitli yöntemleri içerir. Bu yöntemler, farklı elektromanyetik spektrum bölgelerindeki yansıma, emilme veya yayılma özelliklerini kullanarak yeryüzündeki nesneleri tanımak, belirlemek ve analiz etmek için kullanılmaktadır (Kara ve Karatepe, 2012).

Doğal kaynakların verimli bir şekilde kullanılması gerçekten ülkelerin ekonomik gelişmesi için kritik öneme sahiptir. Gelişmiş ülkeler, genellikle teknolojik altyapıya ve uzaktan algılama gibi gelişmiş araçlara daha fazla erişime sahip olduklarından, doğal kaynaklarını daha etkin bir şekilde yönetme eğilimindedirler. Bu ülkeler, uydu görüntüleri ve diğer uzaktan algılama verilerini kullanarak kaynaklarını izler, planlar ve yönetmektedirler (Tunay ve Ateşoğlu, 2009).

Az gelişmiş veya gelişmekte olan ülkeler genellikle doğal kaynaklarının haritalanması ve izlenmesi konusunda yeterli bilgiye sahip değildirler. Bu ülkelerde toprak ve su kaynaklarının, madenlerin yerleri ve miktarları hakkında tam ve kesin veriler eksiktir veya güncel değildir (Öğüt, 2003). Bununla birlikte, doğal çevrenin sürekli değişkenliği ve kaynakların sık sık kontrol edilmesi gerekliliği, modern havacılık ve uzay teknolojisinin önemini artırmaktadır. Uzaktan algılama, bu noktada devreye girer. Havadan veya uzaydan elde edilen görüntüler, toprak örtüsü, su kaynakları, maden yatakları ve diğer doğal kaynakların tespiti ve izlenmesinde kullanılabilir. Uydu görüntüleme, hava fotoğrafçılığı,

lidar ve diğer uzaktan algılama teknikleri, geniş alanlardaki doğal kaynakları belirleme ve izleme konusunda önemli bir araçtır (Kazu ve Özdemir, 2009).

Uzaktan algılama yöntemi birçok alanda başarıyla uygulanmaktadır. Aşağıda belirtilen alanlarda ve benzer çalışmalarda uzaktan algılama teknikleri kullanılmaktadır (Kalem, 2014):


- Deniz ve kıyı kirliliği etütlerinde, uydu görüntülerinden işlenip uygun filtrelemeler yapılarak kirlilik haritalarının yapımı.
- Tarımsal amaçlı, arazi kullanımı ve toprak haritalarının etütlerinde.
- Orman kaynaklarının ön sayımlarının yapımı ve haritalanmasında, ayrıca orman yangınlarının yaptığı hasarların tespiti.
- Maden aramalarında, jeolojik etütlerin yapımında, yer çalışmalarını süre ve maliyet açısından en aza indirmek amacıyla tahmin yürütme.
- Otoyol, devlet yolu, demiryolu ve boru hattı koridor seçimleri, sulama, baraj, madencilik ve ormancılık ön etütlerinde.
- Üç boyutlu sayısal arazi modellerinin hazırlanmasında.

Bu alanlarda uzaktan algılama teknikleri, uydu görüntüleme, hava fotoğrafçılığı, lidar, termal görüntüleme ve spektral görüntüleme gibi çeşitli araçlarla kullanılır. Bu teknikler, doğal kaynakların etkin bir şekilde yönetilmesi, çevresel etkilerin izlenmesi, altyapı projelerinin planlanması ve uygulanması gibi birçok alanda önemli bir rol oynamaktadır.

1.2.1. Sayısal Görüntü ve Özellikleri

Günümüzde uzaktan algılama verileri, çeşitli platformlar aracılığıyla temin edilebilmektedir. Bu platformlar arasında kameralar ve sensörler bulunduran uçaklar, insansız hava araçları (İHA) ve uydular öne çıkar. Her bir platformun avantajları ve kullanım alanları farklılık gösterebilir. Uydular, yeryüzeyindeki nesneleri ve çevrelerinden gelen elektromanyetik enerjinin miktarını ölçen alıcılardan oluşur. Bu alıcılar, farklı elektromanyetik spektrum bölgelerindeki ışığı algılayabilirler. Sensörler, yeryüzünden yansıyan veya yayılan elektromanyetik enerjiyi algılamak için kullanılmaktadır. Bu sensörler genellikle elektromanyetik spektrumun belirli bölgelerinde ölçümlerini gerçekleştirirler. Elektromanyetik spektrum (EMS), ışık hızı (yaklaşık 3×10^8 m/s) ile

hareket eden ve dalga boyu nanometreden kilometreye kadar uzanan bir sürekli enerji ortamını ifade etmektedir. EMS'nin "spektrum görüntü bölgesi" olarak adlandırılan kısmı, genellikle ultraviyole (UV), görünür ve kızılötesi (IR) bölgelerini içerir. Bu bölgeler, farklı dalga boylarında ışığın yayıldığı veya yansıdığı alanlardır (Yener vd., 2006). Sensörler, bu bölgelerdeki elektromanyetik enerjiyi ölçerek çeşitli bilgiler elde etmektedirler. Görünür ışık, insan gözünün algılayabildiği dalga boylarında yer alır ve renklerin görülmesini sağlar. UV ve IR bölgeleri ise insan gözü tarafından algılanamaz, ancak sensörlerle algılanabilir. Özellikle kızılötesi bölgesi, bitki sağlığı, termal analizler, arazi kullanımı gibi birçok alanda uzaktan algılama çalışmalarında önemli bir rol oynamaktadır (Musaoğlu, 1999). Elektromanyetik spektrumun her bir aralığında (veya bölgesinde), ilgili yeryüzü özellikleri kaydedilir veya algılanmaktadır. Elektromanyetik spektrumun farklı bölümleri, farklı dalga boylarına ve frekanslara sahiptir ve bu bölümlerin her biri farklı türde bilgi sağlamaktadır.



Şekil 1. Elektromanyetik spektrum (Tavus, 2017)

İnsan gözü, elektromanyetik spektrumun sınırlı bir bölümünü algılayabilir. Bu bölüm, yaklaşık 400 nanometreden (nm) 700 nanometreye kadar olan dalga boylarını içerir ve görünür ışık olarak adlandırılır. Bu bölge insan gözünün spektral duyarlılığına karşılık gelmektedir. Görünür bölgedeki dalga boyları, renklerin algılanmasını sağlar. Yaklaşık 400 nm ile 500 nm arasındaki dalga boyları mavi, 500 nm ile 600 nm arasındaki dalga boyları yeşil ve 600 nm ile 700 nm arasındaki dalga boyları kırmızı renge karşılık gelmektedir. Ultraviyole (UV) bölgesi, görünür bölgenin mavi bandının yanında yer alır. UV bölgesi, insan gözü tarafından algılanamaz ancak bazı hayvanlar UV ışığını görebilir. UV ışığı, morötesi (morötesi) olarak adlandırılır ve genellikle 10 nm ile 400 nm arasındaki dalga

boylarını kapsamaktadır. Görünür bölgenin sonunda kızılötesi (IR) bölgesi başlar. Kızılötesi bölge, yakın kızılötesi, orta kızılötesi ve termal kızılötesi olarak üç alt bölüme ayrılabilir. Yakın kızılötesi 0,7-1,3 μm , orta kızılötesi 1,3-3 μm ve termal kızılötesi 3-14 μm dalga boyları arasındadır. Termal kızılötesi bölgesi, nesnelerin sıcaklığını algılamak için kullanılır ve genellikle termal kameralarda kullanılmaktadır (Lillesand vd., 2007).


Yakın kızılötesi (NIR) dalga boyu aralığındaki ışınlar, bitkilerde bulunan klorofil pigmentine karşı duyarlı olduğu için bitkiler ile diğer nesneler arasındaki ayrımı iyi bir şekilde yansıtmaktadır. Bu özellik, bitkilerin fotosentez sürecinde klorofil tarafından yayılan ışığın özelliklerine dayanmaktadır. Bitkiler fotosentez yaparken, güneş ışığını klorofil pigmenti tarafından emerler ve bu süreç sırasında klorofil tarafından yansıtılan ışık, yakın kızılötesi bölgede yoğunlaşır. Bu nedenle, bitkilerin yakın kızılötesi spektrumunda belirgin bir şekilde farklılaşması, uzaktan algılama çalışmalarında bitkilerin tespitinde ve analizinde önemli bir araç haline gelmektedir (Şentürk, 2020).

Uzaktan algılama ile elde edilen görüntüler, yeryüzündeki birçok bilgiyi içerir. Bu bilgiler, yer gözlem uyduları tarafından algılanan ve çeşitli bantlara kaydedilen elektromanyetik enerjinin nesnelerden yansması veya yayılması ile elde edilir. Bu süreç, spektral ölçüm olarak adlandırılmaktadır (Chanussot vd., 2006). Spektral ölçüm, farklı elektromanyetik spektrum bölgelerindeki yansıma veya emilim özelliklerini belirlemek için kullanılır. Uydudan toplanan elektromanyetik enerji, farklı dalga boylarında veya bantlarda ölçülür ve kaydedilir. Her bir spektral bant, belirli bir elektromanyetik spektrum aralığına karşılık gelmektedir (Gülersoy, 2013).

Spektral ölçüm değerleri, bilgisayarlar tarafından sayı dizilerine çevrilir ve görüntü oluşturmak için gri renk tonlarına dönüştürülür. Bu sayı dizileri, görüntünün her bir pikselini temsil eder. Pikseller, satır ve sütun elemanları olarak düzenlenir ve matris şeklinde sunulmaktadır. Bu matris, görüntünün dijital temsidir ve her bir pikselin gri tonunu içermektedir. Bu gri tonlar, algılama aralığına göre nesnelerin yansıma veya emilim özelliklerine ait değerleri temsil eder. Örneğin, bitki örtüsü belirli bir spektral bantta daha yüksek yansıma değerlerine sahip olabilirken, su veya asfalt daha düşük yansıma değerlerine sahip olabilir. Bu şekilde, spektral ölçümlerden elde edilen görüntüler, farklı nesnelerin ve özelliklerinin tespit edilmesi, analiz edilmesi ve haritalanması için kullanılır. Uzaktan algılama, bu dijital görüntülerin işlenmesi ve yorumlanması yoluyla birçok uygulama alanında önemli bilgiler sağlamaktadır (Tavus, 2017).

1.2.2. Görüntü Yorumlama Elemanları

Görüntü yorumlama elemanları, nesnelerin algılanmasına ve nesnelerle ilgili bilgilerin çıkarılmasına yardımcı olan unsurları ifade eder. Bu unsurlar, uzaktan algılama verilerinin analiz edilmesi sürecinde kullanılan ve görsel veya sayısal bilgi içeren özelliklerdir.



Şekil 2. Görüntü yorumlama elemanları (Tavus, 2017)

- Ton

Ton, görüntüdeki nesnelerin belirlenmesinde önemli bir unsurdur. Ton, nesnelerin rengini ve dolaylı olarak parlaklığını ifade eder. Bir nesnenin yansıma, yayılma, iletim veya emilim karakteristiklerine göre tonu değişebilir. Bu nedenle, aynı nesne farklı spektral bantlarda farklı tonlara sahip olabilir. Her nesnenin ton özelliği, nesnenin yüzey özelliklerine, malzemesine ve çevresine bağlı olarak değişir. Örneğin, bitkiler yeşil renkte görünür çünkü klorofil pigmenti yeşil ışığı yansıtır. Diğer yandan, beton gibi inorganik yüzeyler genellikle gri veya beyaz tonlarda görünür çünkü güneş ışığını yaymak yerine yansıtır. Ayrıca, nesnelerin geometrisi ve dokusu da tonunun değişmesine neden olabilir. Örneğin, bir dağın yüzeyi farklı açılarda güneş ışığını yansıttığı için farklı tonlarda görünebilir (Özdemir, 2013).

Tonun spektral bantlarda farklılık göstermesi, her bir bantın farklı elektromanyetik spektrum aralıklarını temsil etmesinden kaynaklanır. Bu nedenle, aynı nesne, farklı spektral bantlarda farklı şekilde görünebilir. Örneğin, bir bitki klorofil tarafından yansıtılan yeşil ışığı kızılötesi bantlarda yansıtmayabilir, bu da farklı tonlara neden olabilir. Bu

nedenle, ton özelliği, uzaktan algılama görüntülerinin analizinde önemli bir rol oynar. Nesnelerin tonları, nesnelerin sınıflandırılması, tanınması ve özelliklerinin belirlenmesinde kullanılır. Ayrıca, tonlar üzerinde yapılan ölçümler ve analizler, tarım, ormancılık, coğrafi bilgi sistemleri (GIS), çevre bilimleri ve coğrafi planlama gibi birçok alanda kullanılan değerli bilgiler sağlamaktadır (Tavus, 2017).

- Şekil

Şekil özellikleri, yeryüzündeki nesnelerin görüntü yorumlamasında önemli bir rol oynar. Nesnelerin kendine özgü yapıları veya dış hatları, yani geometrileri, belirli şekil özelliklerine sahiptir. Bu şekil özellikleri, nesnelerin tanımlanması, sınıflandırılması ve özelliklerinin belirlenmesi için kullanılmaktadır.

- Boyut

Boyut, bir görüntü üzerindeki nesnelerin fiziksel büyüklüğünü ifade eder ve ölçek ve çözünürlük gibi faktörlere bağlıdır. Görüntüde bulunan nesnelerin boyutları, bu nesnelerin belirlenmesi, sınıflandırılması ve analiz edilmesi için önemli bir özelliktir. Boyutun bazı önemli yönleri aşağıda verilmiştir (Ozulu, 2005):

- Ölçek: Görüntüdeki bir nesnenin gerçek dünyadaki fiziksel boyutuna olan oranıdır. Ölçek, görüntülenen alanın büyüklüğüne ve görüntüleme sistemlerinin özelliklerine bağlıdır. Örneğin, bir uydu görüntüsünde bir arazi parselinin boyutu, gerçek ölçekle karşılaştırılarak belirlenebilir.
- Çözünürlük: Görüntüleme sistemlerinin kabiliyetlerine bağlı olarak, bir görüntüdeki birim alan başına düşen piksel sayısıdır. Düşük çözünürlüklü görüntülerde, küçük nesneler büyük piksellerle temsil edilirken, yüksek çözünürlüklü görüntülerde daha küçük nesneler daha ayrıntılı olarak görünebilir.


Boyut, görüntü üzerindeki nesnelerin doğru bir şekilde tanımlanması ve yorumlanması için kritik bir faktördür (Lillesand vd., 2015). Özellikle, bir analistin görsel algısını ve deneyimini kullanarak, daha önce tanıdığı nesnelerin boyutlarına dayanarak, daha az bilinen nesnelerin boyutunu tahmin etmesine yardımcı olur. Bu, uzaktan algılama verilerinin yorumlanması ve analiz edilmesi sürecinde önemli bir adımdır. Boyut, nesnelerin özelliklerini anlamak için diğer gözlem özellikleriyle birlikte kullanılır. Örneğin, bir yapısal özelliği tanımlarken, ölçek ve çözünürlük, yapıyı çevresindeki diğer nesnelerle karşılaştırarak doğru bir şekilde sınıflandırmak için önemlidir. Bu nedenle, boyut, görüntü yorumlaması sürecinde dikkate alınması gereken önemli bir faktördür (Richards ve Richards, 2022).

- Desen

Desen, yeryüzündeki nesnelerin belirli bir düzen içinde bulunma şeklini ifade eder. Bu düzen, nesnelerin sistematik, doğrusal, eğrisel veya daha başka şekillerde konumlanmış olabileceği bir düzen olabilir. Desenler, nesnelerin görülen ayırt edilebilme düzenini belirler ve görüntü yorumlaması sürecinde önemli bir rol oynamaktadır (Sun vd., 2022).

- Doku

Doku, bir görüntüdeki ton ve renk özelliklerinin tekrarlanmasıyla oluşan ve görüntüdeki ton değişikliklerini ve düzeni belirleyen bir özelliktir. Bu özellik, boyut, şekil, desen ve gölge gibi diğer görsel özelliklerle yakından ilişkilidir ve nesnelerin tanımlanması ve sınıflandırılmasında önemli bir role sahiptir (Franklin vd., 1996).



Şekil 3. Doku ve desen özellikleri (Tavus, 2017)

Doku, nesnelerin yüzey özelliklerini ifade eder ve genellikle görüntüdeki yoğunluk veya piksel değerlerinin belirli bir desen içinde değişmesi olarak algılanmaktadır. Örneğin, bir ormanın dokusu genellikle ağaçların ve yaprakların tekrarlanan desenleriyle karakterizedir. Bu desenler, nesnelerin tanınmasına ve sınıflandırılmasına yardımcı olur. Doku, aynı zamanda nesnelerin malzemesini veya yüzey yapısını da yansıtabilir. Örneğin, bir çimenlik alanın dokusu, çimenlerin sık veya seyrek olarak düzenlenmesine bağlı olarak değişebilir (Anwer vd., 2018). Ayrıca, bir kum plajının dokusu, kum tanelerinin düzensiz ve rastgele dağılımını yansıtabilir. Doku, diğer görsel özelliklerle birlikte kullanılarak nesnelerin doğru bir şekilde tanımlanmasına ve yorumlanmasına yardımcı olur. Örneğin, bir arazi görüntüsündeki binaların doku özellikleri, yapı malzemesi ve yapının durumu hakkında bilgi sağlayabilir. Ayrıca, doku özellikleri, bir nesnenin çevresiyle nasıl ilişkilendiğini ve nasıl farklılaştığını anlamak için de kullanılabilir (Gaetano vd., 2009).

- Gölge

Gölge, görüntüdeki nesnelerin şekli ve boyutu hakkında bilgi vererek nesnelerin ayrılmasında ve yükseklikleri arasındaki farkların belirlenmesine yardımcı olan bir özelliktir. Gölge, bir nesnenin çevresine düşen ışığın kısıtlanması sonucu oluşur ve bu, nesnenin yerel yüksekliği ve çevresel ilişkileri hakkında önemli ipuçları sağlamaktadır. Gölge, nesnelerin belirginliğini artırabilir ve görüntüdeki nesnelerin hacmini ve yüksekliğini vurgulayabilir. Örneğin, bir bina veya ağaç gibi yükselen nesnelerin gölgeleri, nesnelerin yüksekliklerini ve konumlarını belirlemek için kullanılabilir. Ayrıca, gölgeler, nesneler arasındaki mesafeleri ve ilişkileri anlamak için de önemli bir görsel ipucu sağlamaktadır (Shahtahmassebi vd., 2013).

Gölge, nesnelerin ışık kaynağına olan uzaklığına bağlı olarak farklılık gösterebilir. Daha uzak nesnelerin gölgeleri, daha belirsiz veya az belirgin olabilirken, yakın nesnelerin gölgeleri daha belirgin olabilir. Bu, uzaktan algılama görüntülerinin analiz edilmesi sırasında gölgelerin yorumlanmasını etkileyebilir. Gölge, ayrıca coğrafi özelliklerin ve arazi şekillerinin belirlenmesinde de önemli bir rol oynar. Örneğin, bir dağın veya tepeye düşen gölgeler, arazinin eğimini ve yükseklik farklarını gösterir. Bu bilgi, topoğrafik analizlerde ve arazi haritalarının oluşturulmasında kullanılabilir (Tavus, 2017).

1.2.3. Sınıflandırma

1. Piksel tabanlı sınıflandırma

Piksel tabanlı yaklaşımlar, her bir piksel üzerinde çalışır ve yalnızca spektral bilgilere dayanarak uzaktan algılanan verilerden bilgi alır. Bu yöntem, görüntüyü piksellerin tek tek analiz edilmesiyle işler ve her pikselin spektral özelliklerine göre sınıflandırılmasını sağlar. Spektral bilgiler, genellikle farklı dalga boylarında yansıyan veya emilen elektromanyetik enerjinin ölçümüyle elde edilir. Piksel tabanlı yaklaşımlar, uzaktan algılanan verilerin detaylı bir şekilde analiz edilmesine ve farklı alanların sınıflandırılmasına olanak tanır (Gupta ve Bhadauria, 2014). Bu metoda temel amaç, arazi özelliklerine göre görüntüdeki her bir pikseli otomatik olarak bir araya getirmektir. Piksel tabanlı yaklaşımların karşılaştığı sorunlar, nesne tabanlı görüntü sınıflandırmasıyla aşılmaktadır (Yiğit ve Uysal, 2019).

Piksel tabanlı sınıflandırma, görüntüdeki piksellerin içerdikleri spektral bilgilerle ayrı ayrı analiz edilmesidir. Bu yaklaşım geleneksel olarak kullanılmaktadır çünkü pikseller, bir

görüntünün temel (mekansal) birimidir. Bu nedenle, sayısal görüntülerde piksellerin bulunması, bu yaklaşımın genellikle kolay bir şekilde uygulanmasını sağlar (Doğan, 2019). Piksel tabanlı sınıflandırmada, bir dizi farklı teknik kullanılabilir. Bunlar arasında en yaygın olanlar maximum-likelihood, minimum-distance-to-mean, minimum-mahalanobis distance, K-mean cluster gibi tekniklerdir. Bu yaklaşımda, bilinmeyen bir piksele, o pikselin en yakın benzerlik değerine sahip olduğu sınıf etiketi atanır. Ancak, bu sınıflandırma yöntemi genellikle piksel alanı içinde farklı yüzey örtü tiplerinin bulunduğu durumlarda gerçek çevresel koşullara ve uzaktan algılama verisinin dijital karakterine tam olarak uygun değildir. Başka bir deyişle, bir piksele atanan değer, yüzeyin homojen olmadığı durumlarda gerçek bir karışımı temsil eder (Sunar vd., 2011).

Bu sınıflandırma yönteminde kullanılan birçok algoritma bulunmaktadır. Bunlardan bazıları şunlardır:

Maximum Likelihood (Maksimum Olabilirlik) Yöntemi: Bu algoritma, her bir banttaki her bir sınıf için istatistiklerin normal olarak dağıldığını ve belirlenmiş bir pikselin belirli bir sınıfa ait olma olasılığını hesaplar. Bir olasılık eşiği belirlenmediği takdirde, tüm pikseller sınıflandırılır. Her piksel, en yüksek olasılıklara sahip olan (yani, maksimum olasılık) sınıfa atanır. Eğer en yüksek olasılık belirtilen eşikten küçükse, piksel sınıflandırılmamış olarak kabul edilir (Doğan, 2019).

Support Vector Machine (Destek Vektör Makinesi - SVM) Yöntemi: SVM, genellikle karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu elde etmek için kullanılan bir denetimli sınıflandırma yöntemidir. Bu yöntem, sınıfları, sınıflar arasındaki marjı maksimize eden bir karar yüzeyi ile ayırır. Bu karar yüzeyi genellikle en uygun hiper düzlem olarak adlandırılır ve bu düzleme en yakın veri noktalarına destek vektörleri denir. Destek vektörleri, eğitim setinin kritik unsurlarıdır ve sınıflandırma performansını belirlemede önemli bir rol oynarlar. SVM, doğrusal olmayan veri kümesi için doğrusal olmayan bir sınıflandırıcı olarak da uyarlanabilir. Ayrıca, birden fazla ikili SVM sınıflandırıcısını birleştirerek çok sınıflı sınıflandırma görevlerini de gerçekleştirebilir, yani her bir sınıf çifti için bir ikili sınıflandırıcı oluşturur (Sunar vd., 2011).

Minimum Distance (En Kısa Uzaklık) Yöntemi: İşlemsel olarak basit olup özellikle eğitim veri sayısının az olduğu durumlar için uygun olan bir sınıflandırma yöntemidir. Bu yöntemde ilk adım olarak, her bir sınıf için eğitim verilerinin ortalaması hesaplanır. Bilinmeyen pikseller, bu ortalamalara olan uzaklıkları dikkate alınarak en yakın oldukları

sınıflara atanır. Uzaklık ölçüsü olarak Öklit ve Blok-Yuvarlama gibi yöntemler kullanılabilir (Doğan, 2019).

Görüntü sınıflandırma Denetimsiz ve Denetimli olarak ikiye ayrılır.

- Denetimsiz Sınıflandırma

Denetimsiz sınıflandırma, görüntü işleme ve analizinde kullanılan önemli bir tekniktir. Bu yöntem, belirli bir denetim veya kontrol bölgesi olmadan gerçekleştirilen sınıflandırma işlemidir (Üstüner, 2023). Piksellerin otomatik olarak kümelendirilmesi üzerine kurulu olan denetimsiz sınıflandırma, kullanıcı müdahalesi olmadan yapılır. Bu işlemde, piksellerin benzerlik ölçütlerine göre bir araya getirilmesi esastır. Genellikle minimum uzaklık kuralı gibi karar kuralları kullanılır. Arazi örtüsü türünün önceden bilinmesine gerek olmadığı için bu yöntem, belirsiz veya karmaşık görüntülerde etkilidir. Kullanıcı, sınıf sayısını belirledikten sonra benzer pikseller, otomatik sınıflandırma programları tarafından gruplandırılır ve sınıflandırma işlemi tamamlanır (Arıkan ve Yıldız, 2023).

Temel bir denetimsiz sınıflandırma yöntemi olan K-means algoritması, görüntülerin seçilen küme merkezlerine olan uzaklıklarını dikkate alarak en yakın kümelere atanmasını sağlar. Bu yöntemde, önceden belirlenmiş tematik bilgi olmadığı için küme merkezleri genellikle rastgele veya sistemli olarak belirlenir. Daha sonra her kümeleme adımından sonra küme merkezleri güncellenir. Bu şekilde, algoritma en uygun merkez değerlerini belirleyerek, yani görüntüler için en uygun küme etiketlerini iteratif olarak günceller. Uzaktan algılamada K-means algoritmasını temel alan ISODATA (Iterative Self Organizing DATA) yöntemi daha yaygın olarak kullanılmaktadır. Bu yöntemde, oluşturulacak kümelerin piksel sayıları için alt ve üst limitler belirlenebilir, belirli bir standart sapma değerine bağlı olarak. Sonuç olarak, kümeleme sonucunda istenilen sınıf sayısından daha az veya daha fazla sınıf oluşabilir. Ayrıca, işlemin sonlandırılmasında, sadece iterasyon sayısı değil, iterasyonlar arasındaki değişim oranı da dikkate alınabilir. Bu değişim oranı, yeni bir iterasyonla küme değerlerinin değiştiği piksel sayısının toplam piksel sayısına oranıdır (Sunar ve ark., 2011).

- Denetimli Sınıflandırma

Görüntü sınıflandırmasında, belirli sınıfların elde edilmesi önceden bilinir veya belirlenir. Bu nedenle, istenen sınıfların görüntüden doğru bir şekilde elde edilmesi için denetim alanları seçilir. Denetim alanlarının seçimi, gerektiğinde arazi ölçümleri yapılabilir. Sınıflandırmanın doğruluğu, denetim alanlarının doğru bir şekilde seçilmesiyle

doğrudan ilişkilidir (Seyrek ve Uysal, 2022). Sınıflandırmada yaygın olarak kullanılan istatistiksel yöntemler arasında Ortalamalara En Kısa Mesafe Yöntemi (Minimum Distance to Means), Paralelkenar Yöntemi (Parellelepiped) ve En Yüksek Olasılık Yöntemi (Maksimum likelihood) bulunmaktadır. Bu yöntemler, piksellerin sınıflandırılması için istatistiksel ölçütlere dayanır ve farklı sınıflar arasındaki ayrımı sağlamak için kullanılır. Her bir yöntemin avantajları ve dezavantajları bulunmakla birlikte, uygun yöntemin seçimi genellikle verinin özelliklerine ve uygulamanın gereksinimlerine bağlıdır (Akosman ve Makineci, 2023).

- Melez (Hibrit) Sınıflandırma

Bu sınıflandırma, denetimli ve denetimsiz sınıflandırma yöntemlerinin doğruluğunu artırmak veya daha etkin hale getirmek amacıyla tasarlanmıştır. Örneğin, denetimsiz sınıflandırmada belirlenecek sınıfları temsil etmek için sınıfların tanımlanmasına analistin yardımcı olması amacıyla denetimsiz örneklem alanlarının sınırları görüntüde belirtilebilir. Denetimsiz eğitim alanları, bilinçli olarak seçilen oldukça farklı görüntü alanlarıdır. Bu sınıflandırmayı kullananlar, özellikle tekil örtü tipleri için spektral tepki desenlerinde karmaşık değişkenliklerin olduğu analizlerde kullanılabilir. Bu tür durumlar, bitki örtüsü haritalaması gibi uygulamalarda oldukça yaygındır. Bu bağlamda, örtü tiplerindeki spektral değişim genellikle örtü tipleri içindeki varyasyonlardan ve farklı bölge koşullarından kaynaklanmaktadır. Rehberli kümeleme, bu tür durumlarda oldukça etkili bir yöntem olarak kabul edilen karma bir yaklaşımdır. Bu yaklaşım, denetimsiz ve denetimli eğitim verilerini bir araya getirerek daha hassas ve doğru sınıflandırma sonuçlarının elde edilmesine olanak tanır (Bayburt, 2009).


Piksel tabanlı sınıflandırma yöntemleri, spektral ve dokusal bilginin yanı sıra şekil karakteristikleri ve komşuluk ilişkilerini de kullanırlar. Bu özellikler, görüntülerdeki nesnelerin belirlenmesi ve sınıflandırılması için önemli bir rol oynar. Öte yandan, obje tabanlı sınıflandırma yöntemi, piksel tabanlı sınıflandırmadan farklı olarak bulanık mantık sınıflandırması konusunda önemlidir (Yiğit ve Uysal, 2019). Bulanık mantık sınıflandırmasıyla, her bir obje birden fazla sınıf üyeliğine sahip olabilir. Bu durumda, her objenin her sınıfa ait olma derecesi 0 ile 1 arasında değişen bir rakamla ifade edilir. Bu değer ölçeğinde, 1 değeri pikselin o sınıfa tam üyeliğini temsil ederken, 0 değeri hiçbir üyeliğinin olmadığını gösterir. Aradaki değerler ise objenin ilgili sınıfa olan üyeliğinin büyüklüğünü belirtir. Bu esnek yaklaşım, karmaşık ve belirsiz sınıflandırma problemlerinde daha iyi sonuçlar elde etmeye olanak sağlar (Boyacı, 2012).

2. Nesne Tabanlı Sınıflandırma

Piksel tabanlı sınıflandırmadan farklı olarak, nesne tabanlı sınıflandırma yöntemi tekil pikseller üzerinde doğrudan işlem yapmaz. Bu yöntem, görüntüyü anlamlı bir şekilde segmentasyon işlemi ile gruplandırılmış, birçok pikselden oluşan objeler üzerinden çalışır. Daha sonra, sınıflandırma işlemi için pikseller yerine bu objeler kullanılır (Carleer ve Wolff, 2006). Bu objeler, spektral, şekil, boyut, doku gibi özellikleriyle homojen olarak oluşturulur ve birbirleri arasındaki ilişkileri kullanarak sınıflandırma işlemini gerçekleştirir. Nesne tabanlı sınıflandırma, kural-bazlı işlem kabiliyetiyle desteklenerek daha doğru sonuçlar elde edilebilir. Özellikle sınıflandırma ağaçları gibi yöntemler, objelerin özelliklerini ve ilişkilerini kullanarak karmaşık sınıflandırma problemlerini çözmeye yardımcı olabilir. Bu yöntem, piksel tabanlı sınıflandırmaya göre daha kapsamlı bir yaklaşım sunar ve genellikle karmaşık görüntü verilerinin analizi için tercih edilir (Blaschke ve ark., 2011).

Nesne tabanlı sınıflandırmada, üç temel işlem adımı bulunmaktadır: görüntü segmentasyonu, görüntü nesnelerinin özelliklerinin belirlenmesi ve görüntü nesnelerinin sınıflandırılması (Bo ve Han, 2010). Bu adımlardan ilki ve nesne tabanlı sınıflandırmanın temel işlem adımı olan, benzer spektral özelliklere sahip piksellerin bir araya getirilerek görüntü nesnelerinin oluşturulması olarak bilinen segmentasyon işlemidir. Segmentasyon ile elde edilen nesnelerin boyutunun belirlenmesinde en önemli faktör ölçek parametresidir (Li ve Shao, 2012). Bu sebeple, nesne tabanlı sınıflandırmada en uygun segmentasyon parametresinin tespiti, doğruluğu doğrudan etkileyen önemli bir husustur (Myint vd., 2011; Ma vd., 2015). Ölçek parametresinin belirlenmesi için farklı yöntemler kullanılmaktadır. Bunlardan en yaygın olanı, kullanıcı tarafından anlamlı nesneler elde edilene kadar ölçek parametresinin manuel olarak ayarlanmasıdır (deneme yanılma yöntemi). Ancak bu yaklaşım, kullanıcının tecrübesine bağlı olduğundan tercih edilmemektedir. Literatürde ölçek parametresinin otomatik veya yarı otomatik olarak belirlenmesi için çeşitli yöntemler önerilmiştir (Ma ve diğerleri, 2015). Dragut vd. (2014) tarafından en uygun ölçek parametresini belirlemek için ESP2 yöntemi geliştirilmiştir. Ölçek parametresinin belirlenmesinde kullanılan başka bir yöntem, konumsal otokorelasyon tekniği olan Moran Endeksi ve varyans değerinin birlikte kullanılmasıdır (Kavzoğlu ve Yıldız, 2015).

Nesne tabanlı görüntü analizi yaklaşımı, homojen görüntü alanlarının (yani nesnelerin) bölümlerini belirler. Bir sonraki adımda, çizilen segmentler spektral, dokusal, komşuluk ve nesneye özgü şekil parametrelerine göre gerçek dünya nesnelerine sınıflandırılır.




Şekil 4. eCognition görüntü segmentasyonu

Görüntü Bölütleme

1. Satranç Tahtası Bölümlendirme

Piksel alanı veya bir görüntü nesnesi alanı kare görüntü nesnelerine ayrılır.



Anlamlı nesneleri temsil etmekte işe yaramaz



Mevcut bir tematik katmanı dahil etmek için Kullanılır.

Şekil 5. Satranç tahtası bölümlendirme görüntü segmentasyonu

2. Quadtree Tabanlı Segmentasyon

Quadtree Tabanlı Segmentasyon algoritması piksel alanını veya bir görüntü nesnesi alanını kare nesnelerden oluşan bir quadtree ızgarasına böler.



Şekil 6. Quadtree tabanlı görüntü segmentasyonu

3. Spektral Fark Algoritmaları

Komşu görüntü nesneleri, spektral fark maksimum spektral fark tarafından verilen değerin altındaysa birleştirilir.




Şekil 7. Spektral fark algoritmaları görüntü segmentasyonu

4. Multiresolution Segmentation

- Ölçek: Birkaç nesnenin birleştirilmesiyle oluşan heterojenliğin mümkün olan en büyük değişimini belirlemek için kullanılan soyut bir değer.
- Şekil: "Kanıt" olarak kullanılabilecek iki geometrik özellik olan sıkılık ve pürüzsüzlüğü içerir.

- Kompaktlık- bir nesnede kümelenmiş piksellerin "yakınlığını" bir daireyle karşılaştırarak tanımlar.



Şekil 8. Multiresolution segmentation

Nesne Tabanlı Görüntü Analizi

- İnsan nesne tanıma sürecine dayanır.
- Uzaktan algılama (RS) görüntülerinin insan yorumunu otomatik veya yarı otomatik bir şekilde taklit eder.

2. YAPILAN ÇALIŞMALAR

Marangoz vd. (2005) çalışmasında, geleneksel piksel tabanlı sınıflandırma yönteminin yalnızca piksellerin gri değerine dayanması ve sadece spektral bilgiyi kullanması nedeniyle, nesne tabanlı sınıflandırma yöntemini tercih ettiklerini belirtmişlerdir. Nesne tabanlı sınıflandırma yöntemiyle, görüntü önce segmentlere ayrılmış ve daha sonra spektral, uzaysal ve yapısal bilgilerden yararlanılarak sınıflandırma ve obje çıkarımı gerçekleştirilmiştir. Çalışmanın sonuçlarına göre, nesne tabanlı sınıflandırma yöntemiyle otomatik olarak detay çıkarımının başarılı olduğu ve elde edilen verilerin coğrafi bilgi sistemlerine entegre edilebileceği vurgulanmıştır. Bu yaklaşım, piksel tabanlı yöntemlere göre daha kapsamlı bir analiz sağlamış ve görüntüden daha fazla bilgi çıkarılmasını mümkün kılmıştır.

Kalkan ve Maktav (2010) çalışmasında, uydu görüntülerindeki mekânsal çözünürlük artışının etkisi üzerine piksel tabanlı yöntem ile nesne tabanlı sınıflandırma yöntemlerini karşılaştırmışlardır. Piksel tabanlı sınıflandırma kapsamında hem denetimli hem de denetimsiz sınıflandırma yöntemlerini kullanmışlardır. Sınıflandırma aşamasında 8 tematik sınıf ataması yapmışlardır. Denetimli sınıflandırmada seçilen örneklemelerin sınıflandırmanın sonucunu etkilediğinden, segmentasyon aşamasının önemine değinilmiştir. Daha sonra, segmentasyon aşamasından önce girilen değerlerin deneme yanılma yoluyla projeye en uygun değerlerin bulunması gerektiği belirtilmiştir. Nesne tabanlı sınıflandırmada da 8 adet sınıf hiyerarşisi belirlenmiştir. Çalışma sonucunda her iki yöntem için de doğruluk analizi yapılmıştır. Seçilen çalışma alanının küçük olmasından dolayı her iki yöntemle de başarılı sonuçlar elde edilmiştir, ancak nesne tabanlı sınıflandırma yöntemi ile daha anlamlı sonuçların elde edildiği belirtilmiştir.

Petropoulos vd. (2012), tipik bir Akdeniz ortamında arazi kullanımı ve örtüsünün belirlenmesi için iki farklı sınıflandırma algoritmasını (piksel tabanlı destek vektör makineleri (SVM) ve nesne tabanlı sınıflandırma algoritması) ve Hyperion sensörünün performansını araştırmışlardır. Hyperion hiperspektral sensörü, 242 farklı spektral bantta 30 metrelik en yüksek spektral çözünürlükle nesneler hakkında veri sağlamaktadır. Bu çalışma, sınıflandırıcıların arazi kullanımı ve arazi örtüsü haritalama sürecinde oldukça etkili olduğunu göstermektedir. Ayrıca, nesne tabanlı yaklaşımın, SVM sınıflandırmasından daha yüksek sınıflandırma doğruluğu, Kappa istatistikleri ve üstün

performans gösterdiğini ortaya koymaktadır. Kullanılan sınıflandırma algoritmalarının avantajları ve dezavantajlarına rağmen, McNemar'ın ki-kare analiz sonuçları, nesne tabanlı yaklaşımın DVM'den daha üstün olduğunu ve hiperspektral uzaktan algılama verisinin etkinliğini istatistiksel olarak da doğrulamaktadır.

Singh vd. (2017), uydu görüntülerinin sınıflandırılmasında Genetik Algoritma (GA) ve Radyal Tabanlı Fonksiyon Ağları (RBFA) tabanlı yarı denetimli bir yöntem geliştirmişlerdir. Uydu görüntülerinin sınıflandırılmasında iki temel zorlukla karşılaşmaktadır. Bunlardan ilki, karışık piksel problemi ve diğeri ise büyük ölçekli veri işlemidir. RBFA, geniş bir parametre yelpazesi içeren, sonuçları genelleştirebilen ve gürültüye karşı dayanıklı bir ağıdır. RBFA, yeni verilere adapte olabilir ve öğrenme algoritması ile çekirdek nokta seçimi, ağı performansını önemli ölçüde etkiler. Bu nedenle, çekirdek noktalarının belirlenmesinde GA yönteminden faydalanılmıştır. Bu teknik, Güney Çin'deki Dongting Gölü'nde taşkın alanlarını belirlemede Landsat 8 OLI görüntülerinin sınıflandırılması için kullanılmıştır. Yapılan performans analizi sonuçlarına göre, diğer üç yöntemle karşılaştırıldığında ve hata matrisi değerlendirildiğinde, önerilen sınıflandırıcının oldukça etkili ve verimli olduğu tespit edilmiştir.

Sharma vd. (2017), orta çözünürlüklü uzaktan algılama görüntülerinin sınıflandırılması için yeni bir ESA (Yeryüzü Gözlem Verileri) sistemi önermiştir. Özellikle Landsat verileri için, çok boyutlu TOA (Atmosferin Üst Kısmı) yansıma verilerinden yama tabanlı örnekler hesaplanmıştır. Önerilen yaklaşım, piksel tabanlı geleneksel sinir ağı, piksel tabanlı ESA ve yama tabanlı sinir ağı yöntemleriyle karşılaştırılmıştır. Sınıflandırma sonuçları, önerilen sistemin genel olarak değil, aynı zamanda kategorik sınıflandırma doğruluğunu da belirgin bir şekilde artırdığını göstermiştir. Bu sistem, derin ESA ve yüksek çözünürlüklü uzaktan algılama verilerini birleştirerek, geniş alanlarda son derece doğru arazi örtüsü veri setleri üretme potansiyeline sahiptir.

Jain vd. (2017), piksel yoğunluklarının iç ve dış sınıflandırmasını gerçekleştirmek için Destek Vektör Makinesi'ni (DVM) optimize etme prensibine dayanan bir metodoloji kullanmıştır. Bu yöntemde, Self Organizing Maps (SOM) kullanılarak piksellerin Posterior Probability kıyaslaması yapılmıştır. Çalışmada, iki aşamalı bir yöntem izlenmiştir. İlk aşamada, Destek Vektör Makineleri ile görüntüdeki önemli özellikler öğretilmiştir. İkinci aşamada ise iç ve dış piksellerin belirlenmesi ve en uygun eşik değer ve olasılığın hesaplanması yapılmıştır. İki farklı veri kümesi üzerinde uygulanan yöntemlerin, doğruluk,

kappa ve karışıklık matrisi açısından mevcut sınıflandırma yöntemlerinden daha etkili performans gösterdiği belirlenmiştir.

Delen ve Şanlı (2017), İzmir Menemen ilçesindeki pamuk alanlarını belirlemede 5 bantlı yüksek çözünürlüklü RapidEye uydu görüntüsü üzerinde nesne tabanlı sınıflandırma tekniğini test etmişlerdir. Çalışmalarında, uydu görüntüsünün alındığı zamanda eş zamanlı olarak elde ettikleri yerel verilerle karşılaştırarak sınıflandırmanın doğruluğunu değerlendirmişler ve sonuç olarak % 98.19 gibi yüksek bir başarı elde etmişlerdir. Daha önce yapılan benzer çalışmalarda da nesne tabanlı sınıflandırma tekniğinin piksel tabanlı sınıflandırmaya göre daha başarılı sonuçlar verdiği rapor edilmiştir (Delen ve Şanlı, 2017).

Aydemir (2018) çalışmasında, nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha doğru sonuçlar ürettiğini belirtmiştir. Araştırmacılar, bu yöntemin sınıflandırma yaparken yalnızca spektral karakteristiklere değil, aynı zamanda görüntüdeki şekil ve tekstür gibi diğer parametrelere de dikkat ettiğini vurgulamışlardır. Genel olarak, nesne tabanlı sınıflandırma yönteminin piksel tabanlı yöntemlere göre daha başarılı sonuçlar vermesinin nedeni, piksellerin yalnızca spektral özelliklerine değil, aynı zamanda görüntüdeki farklı nesne tiplerine de dayalı olarak yorumlanmasıdır. Bu açıklama daha önce yapılan çalışmalarla da uyumludur (Delen ve Şanlı, 2017; Kalkan ve Maktav, 2010).

Tablo 1. Segmentasyon kalite metrikleri. $Ar(i)$ toplam referans alanını göstermekte, $As(j)$ ele alınan segmentlerin toplam alanını göstermektedir

Metrik	Formül	Kaynak
Area Fit index (AFI)	$AFI = \frac{Ar(i) - As(j)}{Ar(i)}$	Lucieer and Stein (2002)
Quality rate (Qr)	$Qr = \frac{Ar(i) \cap As(j)}{Ar(i) \cup As(j)}$	Winter (2000)

AFI, referans birimi ile en büyük üst üste gelen segment nesnesi arasındaki örtüşme derecesini ölçen bir metriktir. AFI, 0 değerini aldığı anda, referans ve segmente edilmiş nesneler arasında mükemmel bir uyum var demektir. Pozitif AFI fazla segmentasyonu, negatif AFI yetersiz segmentasyonu temsil eder. Qr metriği 0 ile 1 arasında değerler alır ve referans nesnesi ile ilgili segment arasındaki alana ait örtüşmeyi yetersiz segmentasyon ve fazla segmentasyon değerlerini ele alarak belirler. İdeal bir durumda, Qr değerinin 1'e yakın olması beklenir (Lucieer and Winter (2000)).

Tablo 2. Piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma arasındaki farklar

Piksel tabanlı sınıflandırma	Nesne tabanlı sınıflandırma
Piksel tabanlı sınıflandırma, sadece spektral değerlere dayanırken,	nesne tabanlı sınıflandırma spektral değerlerin yanı sıra şekil, doku ve bağlam bilgilerini de kullanır.
Piksel tabanlı sınıflandırmada, mekansal otokorelasyon ihmal edilirken,	nesne tabanlı sınıflandırmada mekansal otokorelasyon dikkate alınır.
	Nesne tabanlı sınıflandırma süreci, nesnelerin bireysel pikseller yerine sınıflara atanması nedeniyle genellikle daha hızlıdır.
Özetle, nesne tabanlı sınıflandırma, piksel tabanlı sınıflandırmadan daha fazla bilgi kullanarak daha kapsamlı ve doğru sonuçlar elde etmeyi amaçlar.	


3. BULGULAR

3.1. Veri seti ve Yöntemler


3.1.1. Çalışma Alanı ve Uzaktan Algılanan Veriler

Kerkük, Irak'ın kuzeyinde, Bağdat'ın 286-kilometre kuzeyinde yer almaktadır. Doğanın iklimi genellikle kuraktır. Kerkük Valiliği, Khasa Nehri boyunca, deniz seviyesinden 350 m yükseklikte coğrafi koordinatlarda (Enlem 35° 28' 5"K, Boylam 44° 23' 31"D) yer almaktadır.


Kerkük MÖ 2750 civarında keşfedilmiştir (yakl.15000 kişi ve şehir şu anda 1600000 kişilik bir nüfusa sahiptir). Kerkük şehri tarım ve sanayi üzerine kurulmuş olmakla birlikte petrol yataklarıyla da bilinmektedir.



Şekil 9. (a) Çalışma alanı




(b)




(c)

Şekil 10. landsat-9 (b) B2_B3_B4_B5_B8 (c) NDVI Çözünürlük (15M)



(d)



(e)

Şekil 11. Sentinel-2 (d) B2_B3_B4_B8 (e) NDVI Çözünürlük (10M)

Şekil 9. (a) Irak, Kerkük'te Çalışma Alanı. (b) 15M çözünürlüklü, 5 bantlı renkli kızılötesi LANDSAT-9 Ortogörüntüsünü gösteren, yakın kızılötesine (NIR), pankromatik (PAN), kırmızı, yeşil, mavi bantlarını RGB olarak gösteren küçük alt küme alanı, (c) LANDSAT-9 için kullanılan NDVI bandı görüntüsü (d) 10M çözünürlüklü, 4 bantlı renkli kızılötesi SANTINEL-2 Ortogörüntüsünü gösteren, görünür ve yakın kızılötesine(VNIR),

mavi, yeşil ve kırmızı bantları RGB olarak gösteren küçük alt küme alanı, (e) SENTINEL-2 için kullanılan NVDI bandı görüntüsü.

İki tür uzaktan algılanan veri kullanıldı: SENTINEL-2 ve LANDSAT-9 (Şekil 10-11). SENTINEL-2, dört bantlı renkli kızılötesi yaprak üstü SENTINEL-2 ortogörüntüsünden oluşur. SENTINEL-2 görüntülerinin spektral bantları arasında mavi (490 nm), yeşil (560 nm), kırmızı (665 nm) Görünür ve yakın kızılötesi (VNIR) (842 nm) bulunur. Bu projede bitki örtüsünü daha iyi sınıflandırmak için NDVI bandı kullanıldı. İyi bilinen ve yaygın olarak kullanılan NDVI, yeşil bitki örtüsünü ölçmek için basit ama etkili bir endekstir. Kırmızı dalga boylarında klorofil emilimi ile Yakın Kızılötesi dalga boylarında yeşil yaprak saçılımını normalleştirir. Görüntüler 10 m uzamsal çözünürlüğe ve 12 bit radyometrik çözünürlüğe sahiptir. SENTINEL-2 verileri, 18 Ekim 2023, tarihleri arasında bir Vega, İtalyan Uzay Ajansı (ASI) ve Avrupa Uzay Ajansı (ESA) elde edildi. Vega, İtalyan Uzay Ajansı (ASI) ve Avrupa Uzay Ajansı (ESA) tarafından ortaklaşa geliştirilen, Arianespace tarafından kullanılan harcanabilir bir fırlatma sistemidir. Geliştirme 1998 yılında başladı ve ilk fırlatma 13 Şubat 2012'de Guyana Uzay Merkezinden gerçekleşti. İlk uydu Sentinel-2'nin fırlatılışı 23 Haziran 2015 01:52 UTC'de Vega fırlatma aracıyla gerçekleşti. SENTINEL-2 her 10 günde bir aynı bakış açısıyla tekrar ziyaret ediliyor. Yüksek enlemlerde, Sentinel-2 alanı örtüşecek ve bazı bölgeler her 10 günde bir iki veya daha fazla, ancak farklı görüş açılarıyla gözlemlenecektir. 10 m, 20 m ve 60 m uzamsal çözünürlük 290 km görüş alanı Ücretsiz ve açık veri politikası. SENTINEL-2 uydularının her biri, görünür / yakın kızılötesi (VNIR) ve kısa dalga kızılötesi spektral aralığında (SWIR) 13 spektral kanala sahip tek bir çok spektral enstrüman (MSI) taşır. 13 Bant içinde, 10 metrelik uzamsal çözünürlük, SPOT-5 ve LANDSAT-8 görevleriyle sürekli işbirliğine olanak tanır ve temel odak noktası arazi sınıflandırmasıdır. SENTINEL-2 görüntüleri genellikle birçok bant içeren çok kanallı dosya formatlarında gelir. Bu genellikle en yaygın olanı JPEG2000 (.jp2) veya TIFF (.tiff) formatında olur. SENTINEL-2 görüntüleri, etiketli bir görüntü dosyası biçiminde 108 ayrı sıkıştırılmamış dijital ortofoto çeyrek dörtgen olarak sağlandı (.tiff).

LANDSAT-9, beş bantlı renkli kızılötesi yaprak üstü LANDSAT-9 ortogörüntüsünden oluşur. LANDSAT-9 görüntülerinin spektral bantları arasında mavi (0.450 - 0.51 μm), yeşil (0.53 - 0.59 μm), kırmızı (0.64 - 0.67 μm) yakın kızılötesi (NIR) (0.85 - 0.88 μm) ve Pankromatik (PAN) (0.50 - 0.68 μm) bulunur. LANDSAT-9 görüntüsünde bitki örtüsünü daha iyi sınıflandırmak için NDVI bandı kullanıldı. Tipik

olarak NDVI, yakın kızılötesi (NIR) ve kırmızı bantlar kullanılarak hesaplanır. Görüntüyü pan-sharpening yaparak 15m uzamsal çözünürlüğe ve 12 bit radyometrik çözünürlüğe sahiptir. LANDSAT-9 verileri, 10 Ekim 2023, tarihleri arasında elde edildi. Landsat 9, 27 Eylül 2021’de Atlas fırlatma aracındaki Vandenberg Uzay Kuvvetleri Üssü’ndeki Uzay Fırlatma Kompleksi-3e’den fırlatıldı. LANDSAT-9 dünya yüzeyinden yaklaşık 705 kilometre (438 mil) yukarıdadır. Eğim Yaklaşık 98.2 derece. Yörünge süresi Yaklaşık 99 dakika. Tekrar döngüsü, Landsat uyduları tipik olarak 16 günlük bir tekrar döngüsüne sahiptir, yani Dünya’daki aynı alanı yaklaşık 16 günde bir tekrar ziyaret ederler. LANDSAT-9 uydusu dünya’nın tüm kara ve kıyı bölgelerini görüntülemesi 8 gün sürecek. Landsat filosuna katılan en yeni uydu olan Landsat 9 16.384 renk tonu görüyor. Kır suları ve yoğun ormanlar gibi karanlık noktalarda daha fazla ayrıntı görebileceğimiz anlamına geliyor. Landsat 9’da iki cihaz bulunmaktadır. (OLI-2) Operational Land Imager 2, OLI-2 tamamen ışıkla ilgilidir. OLI-2 yörüngeye girdiğinde Dünya yüzeyinden yansıyan güneş ışığını topluyor. Işık görünür ve kızılötesi frekanslarda dokuz spesifik dalga boyu bandını ayırmak için bir dizi filtreden geçer. Her bant, yüzeyde ne olduğuna dair farklı bilgiler sağlar. Landsat 9’daki TIRS-2 adi verilen ikinci cihaz, termal kızılötesi dalga boylarını veya Dünyanın kendisi tarafından yayılan sıcaklık izlerini topluyor. Bu sınıflandırmada çalışma alanı, Bina, Bitki, Su, Toprak, Yol, olmaktadır.

Tablo 3. Arazi örtüsü sınıfları

İsim	Tanım
Bina	Betonlu ve demirli binalar
Bitki	Otsu bitkiler
Su	Hem yapay hem de organik su kütleleri
Toprak	Özellikle tarım alanlarında açıkta kalan toprak ve toprak benzeri spektral özelliklere sahip geçirimsiz yüzeyler
Yol	Asfaltı yollar ve topraklı yollar

3.1.2. Veri İşleme ve Görüntü Segmentasyonu

Sentinel-2 uydu görüntüsü 13 banttan oluşan bir uydu görüntüsüdür. Ve 13 banttan dört bant kullanıldı. Ve bu bantlar (mavi), (yeşil), (kırmızı), görünür ve yakın kızılötesine (VNIR). Ve bu bantları kullanarak 10m çözünürlük elde ettik. Aynı zamanda bu görüntüde bitki örtüsünü için (NDVI) bandı kullanıldı. NDVI, yeşil bitki örtüsünü ölçmek için basit

ama etkili bir endekstir. Kırmızı dalga boylarında klorofil Emilimi ile Yakın Kızılötesi dalga boylarında yeşil yaprak saçılımını normalleştirir. Bu bantlar SNAP yazılımında (Resampling) yapıp ve tiff formatına dönüştürerek (ENVI) yazılımında sınıflandırma için kullanılmıştır. SNAP (Sentinel Application Platform), Sentinel uydu verilerini işlemek için kullanılan bir yazılım paketidir. SNAP'ta "resampling" terimi, görüntü verilerini farklı bir çözünürlükte yeniden örnekleme işlemine atıfta bulunur. Bu işlem, bir Sentinel-2 görüntüsünü işlerken veya analiz ederken kullanılabilir. Bu çalışmada 11 bantlı Landsat-9'dan beş bant kullanıldı. Ve bu bantlar (mavi), (yeşil), (kırmızı), Yakın Kızılötesi (NIR), Pankromatik (PAN). ArcMap 10.5.1'de Pan-Sharpening yaparak Landsat-9 çözünürlüğü (30m) den (15m) reye düşürdük. Landsat-9 içinde (NDVI) bantı kullanıldı. Landsat-9'un NDVI (Normalized Difference Vegetation Index - Normalleştirilmiş Fark Bitki İndeksi) bantı, genellikle Kırmızı (Red) ve Yakın Kızılötesi (Near Infrared - NIR) bantlarının birbirinden çıkarılmasıyla elde edilir. Bu bantlar, bitki örtüsünün büyümesi, yoğunluğu ve sağlığı gibi çeşitli bitki fizyolojik özelliklerini belirlemek için kullanılır.

Bu çalışmalar için iki yazılım kullanıldı, (ENVI) ve (eCognition). ENVI uzaktan algılama verilerini işlemek, analiz etmek ve görselleştirmek için kullanılan güçlü bir yazılımdır. ENVI'nin temel özellikleri çeşitli uzaktan algılama ve coğrafi bilgi sistemleri (GIS) veri formatlarını destekler. ENVI, uzaktan algılama verilerini coğrafi bilgi sistemleri (GIS) verileriyle entegre edebilir ve bu iki veri türü arasında etkileşimli analizler gerçekleştirebilir. ENVI için dört algoritma kullanıldı, (Minimum Mesafe Sınıflandırması), (Maksimum Olasılık Sınıflandırması), (Destek Vektör Sınıflandırması), (Sinir Ağı Sınıflandırması).

Bu analiz için segmentasyon yöntemi olarak Trimble eCognition Developer 9.1 çoklu çözünürlüklü bölütlenme (MRS) seçildi. MRS, görüntüleri farklı görüntü nesnelere bölen, alttan yukarıya doğru bir bölge büyütme segmentasyon yaklaşımıdır. Segmentasyon için üç bantın tamamına eşit ağırlık verildi. MRS algoritmasının analist tarafından girilmesi gereken üç parametresi bulunuyor: ölçek, şekil ve kompaktlık. Ölçek parametresi (SP), görüntü nesnelerinin boyutunu belirler ve genellikle en önemli olarak kabul edilir. SP değeri genellikle deneme-yanılma yoluyla seçilir, ancak bu yaklaşım, rastgele ve tekrarlanabilir olmadığından eleştirilmiştir ve yaklaşık optimal bir değeri garanti edemez. Varsayılan şekil ve kompaktlık parametreleri sırasıyla 0.1 ve 0.5 olarak kullanıldı, çünkü bu parametreleri değiştirmenin segmentasyonun kalitesini artırmadığı gözlemlendi. Piksellerin aksine, nesne tabanlı görüntü analizlerindeki görüntü nesneleri yalnızca spektral

bilgiyi değil, aynı zamanda mekânsal bilgiyi de içerebilir. Segmentasyondan yararlı olabilecek birkaç tanımımız var her şeyden önce heterojenliği bu tüm katmanlar için ağırlıklı standart sapmaların Toplamıdır, kompaktlık kenar uzunluğunun alana bölümüdür, pürüzsüzlük ise kenar uzunluğunun sınırlayıcı kutunun top uzunluğuna bölümüdür, k parametresi bu homojen bir kriterdir ve Spektral ve şekil kriterleri ve bu Ölçek parametresi artırırsak görüntü nesnelerini daha heterojen Hale geleceği anlamına gelir, özetle söylemek gerekirse, Ölçek parametresini görüntü nesnelerinin boyutunu artarsa nesnedeki piksel değerlerinin daha yüksek değişikliğine sahip olduğumuz anlamına gelir . Daha bir iyi sınıflandırma yapmak için farkı Seçenekler test etmemiz gerekiyor bu bizim deneyimimizdir bu nedenle hangi ayarların amacımıza en uygun olduğunu bileceğiz, ben kişisel olarak tek bir projede birden fazla çoklu Çözünürlüklü segmentasyonu değiştiriyorum, örneğin binaları çıkarmak için bu segmentasyon için parametreler ayarlıyorum, ikincisi ağaçları çıkarmak için, üçüncüsü su için, böylece sınıflandırmak ve çıkarmak istediğim her sınıf için her zaman belirli Segmentasyonlar oluşturuyorum, görüntü nesnelerimizin ana hatlarını değiştirmek için bir çok aracımız var, Ölçek parametresi arttırdıkça ve bu daha büyük görüntü nesnelere yol açıyor. Şekil ayarlarına gelirse yüksek şekil değeri spektral yansıma olan düşük renk etkisine yol açar bu nedenle şekli artarsak renk fırsatı kriterinin sağ tarafta azalır, şekil etkisini 0.1 'den 0.1'e yükseltirsek renk etkileri azalır çünkü bu ikisi bir değerini oluşturur minimum değeri 0.1 maksimum değeri de 0.9 şekil değeri çoklu çözünürlüklü segmentasyon sonucunu değiştirir aynısı da kompaktlık içinde geçerlidir ancak Kompaktlık şekli etkiliyor, yani kompaktlık arttıkça pürüzsüzlük azalır ve bu ilişki şekli etkiler yani yüksek bir şekil değerimiz ve yüksek bir kompaktlık değerimiz varsa şeklin üzerinde yüksek bir etkisi olacaktır. Segmentasyon sonuçlarına göre, Şekli artarsak ancak kompaktlık değeri düşükse gerçekten kompakt görüntü nesneleri elde edersek daha pürüzsüz görüntü nesneleri elde ederiz. Sınıflandırma yapmadan önce ilk şey Algoritma modülünden multiresolution segmentation seçiyoruz sonra da parametre ayarlarından şekli 0.1 seçiyoruz ve kompaktı 0.5 seçiyoruz ve Ölçek parametresini de 10 seçiyoruz ve sonuçta oldukça homojen yansımalara sahip görüntü nesnelerimiz vardı. Nesnelerin Parlaklık değeri, nesne deki tüm pikseller üzerinden dört SENTINEL-2 VE LANDSAT-9 bandının ortalama değerleri olarak hesaplandı. NDVI, SENTINEL-2 ve LANDSAT-9 verilerinden Kırmızı ve NIR spektral bantları kullanılarak hesaplandı.

3.1.3. Eğitim Veri Seti

Tüm veri setinden, her biri 403 örnek veri setinden iki farklı, oldukça büyük örnek veri seti toplandı. İki büyük örnek veri seti kullanıldı: biri eğitim için, diğeri ise sınıflandırıcının doğruluğunu değerlendirmek için bağımsız bir doğrulama seti olarak; diğer büyük örnek seti eğitim için kullanılmadı. Bu analiz GEOBIA çerçevesinde gerçekleştirildiğinden, kullanılan örnekleme birimi görüntü nesneleriydi. Orijinal SENTINEL-2 görüntülerinin fotoğrafla yorumlanması yoluyla sınıf etiketi atandı. İşleri kolaylaştırmak için, doğrulama veri seti (aşağıdaki bölümde ele alınan) hazırlandıktan sonra eğitim örnek seti toplandı. Eğitim veri setini toplamadan önce, doğrulama veri setindeki görüntü nesneleri, veri setinin bağımsızlığını garanti altına almak için popülasyondan çıkarıldı. Araştırma alanında bitki örtüsü sınıfı baskın olduğundan görüntüdeki sınıf oranları nedeniyle eşitlenmiş tabakalı örnekleme mümkün olmamıştır. Eğitim setlerinde aşırı azınlık sınıflarının yeterince temsil edildiğini garanti etmek amacıyla, eğitim veri örneğinin toplanmasında orantısız tabakalı rastgele örnekleme kullanıldı. Örnekler, tabakanın her üyesinin eşit seçilme şansına sahip olduğu orantılı tabakalı rastgele örnekleme kullanılarak önceden tanımlanmış tabakalardan seçilir. Önceki araştırmalar, orantısız katmanlı rastgele örneklemenin, çalışma alanında aşırı azınlık sınıflarının mevcut olduğu İK uzaktan algılanan verilerin geniş alan denetimli arazi örtüsü sınıflandırmalarında veri toplama eğitimi için etkili bir yaklaşım olduğunu göstermiştir (Ramezan ve Warner, 2019). eCognition'da nesne tabanlı sınıflandırma yapmak için 3 parametre kullanılmaktadır. Bu üç parametre ölçek parametresi, şekil ve kompaktlıktır. Ölçek parametresi (SP), görüntü nesnelerinin boyutunu belirler ve genellikle en önemli olarak kabul edilir. SP değeri genellikle deneme-yanılma yoluyla seçilir. şekil ve kompaktlık parametreleri sırasıyla 0.1 ve 0.5 olarak kullanıldı, çünkü bu parametreleri değiştirmenin segmentasyonun kalitesini artırmadığı gözlemlendi. Şekil ayarlarına gelirse yüksek şekil değeri spektral yansıma olan düşük renk etkisine yol açar bu nedenle şekli artarsak renk fırsatı kriteri sağ tarafta azalır.aynısı da kompaktlık içinde geçerlidir ancak Kompaktlık şekli etkiliyor , yani kompaktlık arttıkça pürüzsüzlük azalır. Kompaktlık- bir nesnede kümelenmiş piksellerin "yakınlığını" bir daireyle karşılaştırarak tanımlar. Şekil parametresinin özelliği doğal alanlarda (örneğin ormanlar, göller vb.) ayırım yapmak için etkili bir araç olmasıdır. Bu sınıflandırmada çoklu çözünürlüklü segmentasyon kullanıldı. MRS'nin seçilmesinin sebebi karmaşık alanları iyi bir şekilde sınıflandırabilmesidir.


Bu sınıflandırmada Cochran formülü kullanılarak örnekleme büyüklüğü elde edilir. Cochran'ın 1977'de geliştirdiği örnekleme büyüklüğü formülü oldukça önemlidir, özellikle anketler veya araştırmalar için örneklem büyüklüğünü hesaplarken kullanılır. Bu formül, bir popülasyonun belirli bir özelliğine ilişkin bir örneklemin ne kadar büyük olması gerektiğini belirlemek için kullanılır. “Örnekleme Boyutu” Örnekleme büyüklüğü, bir araştırma veya deney için seçilen popülasyonun bir parçasıdır. Örneğin, bir köpek sahibi, belirli bir marka tercihiyle ilgili olarak bir anket çalışmasına katılabilir. Ülkedeki milyonlarca köpek sahibine anket yapmak istenilmez (çünkü çok pahalı ya da zaman alıcı olur), bu yüzden bir örneklem büyüklüğü alınır. Bu birkaç bin sahip olabilir. Örneklem büyüklüğü, tüm köpek sahiplerinin marka tercihlerini temsil etmektedir. Örneğin dikkatlice seçilmesi iyi bir temsil sağlamış olur. Örneklem büyüklüğünde hatanın ortaya çıkma sebebi, nüfusun yalnızca küçük bir örneğini araştırıldığında belirsizlik istatistikleri de yansır. Eğer gerçek nüfusun yalnızca belirli bir yüzdesi araştırılabilirse, istatistikleri nüfusu tam ve doğru bir şekilde temsil ettiğinden asla %100 emin olunamaz. Bu belirsizliğe örnekleme hatası denir ve genellikle bir güven aralığı ile ölçülür. Örneğin sonuçlarımızın %90 güven düzeyinde olduğu belirtilebilir. Bu, anket defalarca tekrarlanınca %90 oranında aynı sonuçların alınacağı anlamına gelir. İstatistikte Örneklem Büyüklüğü bulmak için, örnek, istatistiklerde toplam nüfusun yüzdesidir. Bir popülasyonun tamamı hakkında çıkarımlar yapmak için bir örnekten elde edilen veriler kullanılabilir. Örneğin, bir örnek veri setinin standart sapması, bir popülasyonun standart sapmasına yaklaşmak için kullanılabilir. Örneklem büyüklüğü bulmak istatistikteki en zorlu görevlerden biri olabilir ve orijinal popülasyonumuzun büyüklüğü de dahil olmak üzere birçok faktöre bağlıdır. $n = (n^2 / (1 + n^2 / N))$ Bu formül (küçük örnek büyüklüğü), popülasyon büyüklüğü, güven düzeyi, incelenen özelliğin tahmini yüzdesi ve kabul edilebilir hata miktarı gibi faktörlere dayanarak uygun bir örnekleme büyüklüğünü hesaplar. Bu sayede, belirli bir güven düzeyinde ve belirli bir hata payıyla popülasyonun temsil edilmesi için gereken minimum örnekleme büyüklüğü belirlenebilir. Bu formülde, n, Hesaplanacak örneklem büyüklüğü. N, Popülasyon büyüklüğü. Z, Güven düzeyine karşılık gelen standart normal dağılımın belirli bir yüzdesi (genellikle %95 için 1.96 alınır). P, Popülasyonun incelenen özelliğine sahip olan bireylerin tahmini yüzdesi. e, Kabul edilebilir hata miktarı. q, (1-p) anlamına gelir. Bu formül kullanılarak büyük veri seti hesaplanması yapılırken, önce alpha değeri bulunur. Alpha değerinin formülü ise $(1 - \%95)/2$ şeklindedir. Alpha değeri bulunduktan sonra Z skoru bulunur. Z skorunu bulmak

için ise (NORM.S.INV) standart normal kümülatif dağılımın tersi formülüne alpha değeri yerleştirilir. Bunun sonucunda Z skoru bulunur. Z skoru bulunduktan sonra ise Z^2 bulunur. Bulunan bu değerler $n^o = (Z^2 p(1-p))/e2$ formülünde yerine yerleştirildiğinde büyük veri seti (n^o) bulunur. Büyük veri seti bulunduktan sonra, $n = n^o / (1 + n^o/N)$ formülünde bulunan değerler yerine yerleştirilerek küçük veri seti (n) bulunur. Küçük veri seti formülü kullanılarak bulunan sonuç hata oranı ile çarpılır ve çıkan değer küçük veri seti değerine eklenerek büyük veri seti değeri bulunur.

Cochran'ın formülünün özellikle büyük popülasyonların olduğu durumlarda uygun olduğu düşünülmektedir. Herhangi bir büyüklükteki bir örnek, daha küçük bir popülasyon hakkında daha büyük bir popülasyondan daha fazla bilgi sağlar; dolayısıyla, tüm popülasyon nispeten küçükse, Cochran formülüyle verilen sayının azaltılabileceği bir 'düzeltme' vardır. Büyük eğitim örnek kümesi ($n = 403$), her bir alt küme orijinal 403'ten bağımsız olarak seçilmiş ve birbirini takip eden her küme, önceki daha büyük kümenin yaklaşık yarısı boyutunda olacak şekilde, rastgele bir dizi daha küçük eğitim kümesine bölünmüştür. Bu, 403, 200 boyutunda eğitim setleriyle sonuçlanmıştır.

Tablo 4. Cochran formülünde kullanılan Z değeri

Güven Düzeyi	Z-Score (alpha/2)
80%	1.282
90%	1.645
95%	1.960
98%	2.326
99%	2.576



Şekil 12. Eğitim için örnek görüntü nesnelerinin konumu (n = 403)

3.1.4. Doğrulama Örnek Toplama

Doğrulama verileri, daha önce bölümde belirtildiği gibi eğitim verileri toplanmadan önce oluşturulmuştur ve eğitim verilerinden tamamen farklıdır. Doğrulama veri seti örnekleri basit rastgele örnekleme yoluyla seçilmiştir (Ramezan ve Warner, 2019). Basit rastgele örneklemenin bir avantajı, örneklem istatistiklerinin doğrudan popülasyon hata matrisini tahmin etmek için kullanılabilmesidir (Stehman ve Foody, 2009). Analist, doğrulama örneğindeki her görüntü nesnesini elle etiketledi.

3.1.5. Denetimli Sınıflandırma Yöntemleri

Bu çalışmada dört sınıflandırıcı denetim altında birbiriyle karşılaştırılmıştır. Her eğitim veri kümesinde sınıflandırmalar yapıldı ve bağımsız doğrulama veri kümesine göre değerlendirildi.

1. Destek Vektör Makineleri (SVM)

Destek vektör makinesi (SVM), N boyutlu bir alanda her sınıf arasındaki mesafeyi maksimuma çıkaran optimal bir çizgi veya hiperdüzlem bularak verileri sınıflandıran denetimli bir makine öğrenme algoritmasıdır. SVM'yi diğerlerinden ayıran özelliklerden biri, hiperdüzleme en yakın olan (destek vektörleri olarak adlandırılan) eğitim örneklerinin hiperdüzlemin konumunu belirlemesi, geri kalan eğitim örneklerinin ise atılmasıdır. Optimizasyon, çeşitli sınıfların destek vektörleri arasındaki hiperdüzlemin marjini optimize ettiğinden, SVM sıklıkla maksimum marj sınıflandırıcısı olarak adlandırılır (Mountrakis ve Ogole, 2010). SVM, hiper düzlemin doğrusal bir karar sınırı olması ve birçok sınıfın doğrusal olarak ayrılabilmesi nedeniyle, özellik alanını verilerin doğrusal olarak ayrılabilmesi için daha yüksek bir boyuta dönüştürür. Bu dönüşüme çekirdek numarası denir. Pek çok farklı türde çekirdek vardır; uzaktan algılamada yaygın olarak kullanılan (Khatami ve Stehman, 2016) ve genellikle yeni SVM çekirdeklerinin ne kadar iyi performans gösterdiğini değerlendirmek için bir kıyaslama olarak kullanılan radyal tabanlı fonksiyon çekirdeğini (RBF) kullanıyoruz (Sharma ve Chutia, 2016).

RBF SVM iki parametreden oluşur: destek vektörleri olarak kullanılan eğitim örneklerinin karar sınırını ne kadar etkilediğini gösteren σ ve marj maksimizasyonu için eğitim örneği yanlış sınıflandırmasını değiştiren maliyet parametresi C (Caputo ve Smola, 2002).

2. Yapay Sinir Ağları (ANN)

Sinir ağları, insan beyinde meydana gelen öğrenme sürecinden ilham alır. Parametre adı verilen ve bilgisayarın öğrenmesine ve yeni verileri analiz ederek kendi kendine ince ayar yapmasına olanak tanıyan yapay bir işlevler ağından oluşurlar. Bazen nöronlar olarak da adlandırılan her parametre, bir veya daha fazla girdi aldıktan sonra çıktı üreten bir fonksiyondur. Bu çıktılar daha sonra onları kendi fonksiyonlarının girdileri olarak kullanan ve daha fazla çıktı üreten bir sonraki nöron katmanına aktarılır. Bu çıktılar daha sonra bir sonraki nöron katmanına aktarılır ve bu, her nöron katmanı dikkate alınana ve terminal nöronlar girdilerini alana kadar devam eder. Bu terminal nöronlar daha sonra model için nihai sonucu verir. Çıkış katmanındaki nöronlar sınıflara karşılık gelirken, giriş katmanındaki nöronlar yordayıcı değişkenlerle ilişkilidir. Eğitim verileri sinir ağının katmanları üzerinden akarken, sınıflandırmayı iyileştirmek için ağırlıklar yinelemeli olarak ayarlanır. Bu analizde tek gizli katmana sahip ileri beslemeli bir sinir ağı kullanılmıştır. Bu sinir ağının giriş ve çıkış katmanları arasında veri yalnızca tek yönde veya ileri doğru

hareket eder ve tek bir katmanı kullanır (Ripley ve Venables, 2016). Uzun yıllar boyunca ANN sınıflandırmasının uzaktan algılamada kullanımına ilişkin önemli miktarda araştırma ortaya çıkmıştır (Golhani ve Vadamalai, 2018). Bu ANN uygulamasının iki parametresi, gizli katmanda kaç birim olduğunu gösteren boyut ve aşırı uyumu önlemek için bir düzenleme parametresi görevi gören bozulmadır (Ripley ve Venables, 2016).

3. Minimum Mesafe Sınıflandırması (MDC)

Ürün türlerinin tespiti gibi uzaktan algılama konularında minimum mesafe sınıflandırma tekniklerinin uygulanması dikkate alınmaktadır. Minimum mesafe sınıflandırıcıları, sınıflandırıcıların örnek sınıflandırıcı ailesinin üyeleridir. Tek tek vektörleri sınıflandırılmış öğeler olarak sınıflandıran daha geleneksel vektör sınıflandırıcıların aksine, bu sınıflandırıcılar ölçüm vektörleri kümelerini (örneğin, bir tarım alanındaki tüm ölçüm vektörleri) sınıflandırır. Daha spesifik olarak, bir veri seti (bir vektör kümesi), tahmini dağılımı, sınıflandırılması gereken veri setinin tahmini dağılımına benzer olan minimum mesafe sınıflandırmasında bir sınıfa sınıflandırılır. Dağıtım fonksiyonlarının olduğu bir uzaydaki mesafe ölçümüne benzerlik ölçüsü denir. Minimum mesafe sınıflandırmasını içeren problemler daha sonra temel sınıf dağılımı varsayımına göre kategorize edilir.


4. Maksimum Olabilirlik Sınıflandırması (MLC)

Bir analiz yöntemi olarak maksimum olasılık, birçok moleküler biyolog arasında, özellikle de takson ilişkilerinin gerçek filogenetik modelinden çok evrim modelleriyle ilgilenenler arasında popülerdir. ML, bir durumdan diğerine olası her dönüşüm için ilişkili olasılıklarla birlikte açık bir karakter dönüşümü modeli gerektirir. Ağaçlar, cimrilikte kullanılan yöntemlere benzer bir şekilde aranır (örneğin dal değiştirme), ancak her ağaç toplam uzunluğa göre değil, bunun yerine bileşik olasılık ölçüsüne göre değerlendirilir. Karakter dağılımının bileşik olasılıkları (maksimum olasılık) en yüksek olan ağaçlar en iyi olarak seçilir. Tutumluluk, bazı teorik bağlamlarda daha az varsayım ve sonsuz parametre içeren belirli bir maksimum olasılık türü olarak anlaşılabilir. Tutumluluk ve maksimum olasılık analizleri bu durumlarda aynı sonuçları verecektir. Aynı veri setlerinin maksimum olasılık ve tutumluluk analizi genellikle oldukça karşılaştırılabilir bulgular üretmiştir. Ancak mevcut muazzam hesaplama süreleri nedeniyle, maksimum olasılık, daha büyük veri kümeleri için pratik değildir (en azından günümüzün donanım ve yazılımında). Hesaplama sorunlarının yalnızca donanım iyileştirmeleri yapılarak çözülmesi pek olası

değildir; bunun yerine, muhtemelen mevcut mühendislik yeteneklerinin ötesinde olan önemli yazılım ilerlemelerine ihtiyaç duyulacaktır.

3.1.6. Çapraz Doğrulama Parametre Ayarı

Parametreleştirmesi nedeniyle, birçok denetimli makine öğrenme algoritması belirli bir hedefe veya veri kümesine göre uyarlanabilir (Karatzoglou ve Hornik, 2006). Sınıflandırma sürecindeki önemli bir adım, sınıflandırıcı parametrelerinin seçilmesidir. Ancak ampirik çapraz doğrulama teknikleri genellikle kullanılır çünkü bu parametreler için optimal değerleri tahmin etmek genellikle mümkün değildir (Brownlee, 2020). ArcMap 10.5.1’de doğruluk değerlendirme noktasını oluşturduk. Sınıflandırılmış görüntü üzerine 300 rastgele nokta sayısı atıldı (Şekil 13) ve bu noktaları kml dosyasına çevirip Google Earth’e aktarıldı. Doğruluk analizi için seçtiğimiz sınıflandırmanın gerçek dünya durumuyla ne kadar uyumlu olduğunu değerlendirebiliriz. Google Earth’te Doğruluk analizi yapmak için uydu görüntüsüyle sınıflandırılan alanları ziyaret etmek gerekir. uydu görüntüsüyle yapılan sınıflandırmanın doğruluğunu değerlendirebilir ve gerekirse iyileştirmeler yapabiliriz. Bu çalışmada, sınıflandırma işlemi için iki büyük örnek veri seti kullanılmıştır: biri eğitim verisi olarak, diğeri ise sınıflandırıcının doğruluğunu değerlendirmek amacıyla. Her iki veri seti, piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımlarıyla işlenmiştir. Piksel tabanlı sınıflandırmada, beş denetimli algoritma (MDC, MLC, ANN, SVM) kullanılmıştır. Nesne tabanlı sınıflandırmada ise yalnızca SVM algoritması uygulanmıştır. Nesne tabanlı sınıflandırma işlemi, çoklu çözünürlüklü segmentasyon yöntemiyle gerçekleştirilmiş olup, bu segmentasyonda üç temel parametre (ölçek, şekil, kompaklık) kullanılmıştır. Ayrıca, spektral bantlar arasındaki çeşitli algoritmalarla analizler yapılmış, örneğin NDVI hesaplamaları gerçekleştirilmiştir. NDVI (Normalized Difference Vegetation Index), bitki örtüsünün sağlık durumunu analiz etmek amacıyla yaygın olarak kullanılan bir indekstir. Sentinel-2 10 metre çözünürlük veri seti için dört spektral bant kullanılmış olup, buna ek olarak Normalized Difference Vegetation Index (NDVI) bandı da dahil edilmiştir. Landsat-9 15 metre çözünürlük veri seti için beş spektral bant kullanılmış olup, buna ilaveten Normalized Difference Vegetation Index (NDVI) bandı da dahil edilmiştir.



Şekil 13. Arcmap'ten google earth'e atılan nokta görüntüsü

3.1.7. Sınıflandırma ve Replikasyonlar

Eğitim veri setinin yapısına bağlı olarak sınıflandırıcı performansındaki olası değişiklikleri araştırmak amacıyla her sınıflandırmanın doğruluğu iki kez kontrol edildi. Sınıflandırmalar, 2,40 GHz Intel(R) Core (TM) i5-9300H CPU, 16,0 GB GDDR5 RAM ve 64 bit işletim sistemi, yani Windows 11HOME çalıştıran x64 tabanlı işlemci ile donatılmış özelleştirilmiş bir iş istasyonunda gerçekleştirildi. İşlem süresi verilerinin analizi, mutlak değil göreceli sayılar açısından yapılmalıdır çünkü sistem mimarisi, CPU tahsisi, bellek kullanılabilirliği ve arka plan sistem işlemleri dahil olmak üzere işlem süresini etkileyen birçok değişken vardır. Ayrıca, eğitim, optimizasyon ve sınıflandırma için gereken süre miktarının yalnızca eğitim örneklerinin miktarına (ki bu makalenin ana odak noktasıdır) değil, aynı zamanda belirli algoritmanın uygulanması gibi diğer unsurlara da bağlı olduğunu unutmamak çok önemlidir. sınıfların sayısı, spektral bantların sayısı ve sınıflandırma durumunda görüntünün boyutu.


3.1.8. Hata Değerlendirmesi

Sınıflandırmaları değerlendirmek için devasa, rastgele örneklenmiş doğrulama veri setindeki 403 görüntü nesnesi kullanıldı. Her sınıflandırmanın sonuçları bir karışıklık matrisinde sunuldu. Kappa katsayısı, kullanıcı ve üretici doğrulukları ve genel harita doğruluğu hesaplandı. Üretici Doğruluğu Bu, gerçek sınıfın doğru bir şekilde sınıflandırılma oranını ifade eder. Yani, belirli bir sınıfın aslında o sınıfa ait olan pikselleri ne kadar doğru bir şekilde sınıflandırıldığını gösterir. Formülü: Üretici Doğruluğu = (Doğru Sınıflandırılan Pikseller/ Gerçek olan piksellerin toplamı) * 100. Kullanıcı Doğruluğu Bu, bir sınıfın sınıflandırıldığı halde gerçekten o sınıfa ait olma oranını gösterir. Yani, belirli bir sınıfın sınıflandırılması sırasında yanlış sınıflandırmaların oranını anlamaya yardımcı olur. Formülü: Kullanıcı Doğruluğu = (Doğru Sınıflandırılan Pikseller / sınıflandırılan piksellerin toplamı) * 100 Bu iki doğruluk türü, sınıflandırmanın ne kadar doğru yapıldığını değerlendirmeye yardımcı olur ve her ikisi de farklı perspektiflerden hataları analiz eder. Her sınıf için doğru şekilde sınıflandırılmış görüntü nesnelerinin toplam sayısı, doğrulama veri kümesindeki görüntü nesnelerinin toplam sayısına bölünerek genel doğruluğu belirlemek için kullanıldı.

3.2. Araştırma Bulguları

3.2.1. Doğruluk Değerlendirmesi

Şekil 14 Örneklem büyüklüğüne göre değerlendirilen dört kategorizasyon tekniğinin ortalama genel doğruluk özetini sunar. Genel doğruluk genellikle örneklem büyüklüğü arttıkça arttı. 403 örnekle set, tüm sınıflandırma yöntemleri için en iyi ortalama genel doğruluğu verirken, 200 örnekle set en düşük ortalama genel doğruluğu sağladı. Ancak her sınıflandırıcının örneklem büyüklüğündeki artışa tepkisi farklılık gösterdi. 403 örnekten oluşan bir grupta öğrenilen Ecognition sentinel_2 kategorileri %96,97 ile en yüksek ortalama genel doğruluğa sahipken, 200 örnekten eğitilen Envi sentinel-2 Minimum Mesafe sınıflandırmaları %51,81 ile en düşük ortalama genel doğruluğa sahipti.



Şekil 14. Denetlenen sınıflandırmaların ve eğitim seti boyutunun ortalama genel doğruluğu

Her sınıflandırma yöntemi de kayda değerdir, veri seti boyutu arttıkça genel doğruluktaki değişkenlik azalır. Beklenen şekilde; küçük bir veri setinin daha geniş bir potansiyel sonuç yelpazesi üretme olasılığı daha yüksektir. Ancak şekil aynı zamanda sınıflandırıcılar arasında önemli farklılıklar olduğunu da göstermektedir. Örneğin, hem SVM hem de ANN, aynı boyuttaki farklı çalışma setlerinin benzer doğruluklar üretmesi anlamında iyi genelleyiciler gibi görünmektedir. Nesne tabanlı sınıflandırma için SVM en yüksek doğruluk oranına sahiptir. Piksel tabanlı sınıflandırma yöntemi için ise ANN, nesne tabanlı sınıflandırma yöntemi olan SVM'ye yaklaşık doğruluk oranına sahiptir. Minimum mesafe sınıflandırması (MDC), SENTINEL-2 uydu verisinde küçük ve büyük örnek boyutlarında düşük doğruluk oranına sahipken, maksimum olasılık sınıflandırması olan (MLC) küçük ve büyük örnek boyutlarında yüksek doğruluk oranına sahip olduğu görüldü. LANDSAT-9 uydu verisinde minimum mesafe sınıflandırması (MDC) küçük ve büyük örnek boyutlarında SENTINEL-2 uydu verilerine göre daha yüksek doğruluk oranına sahip olduğu görüldü. Maksimum olasılık sınıflandırması (MLC) için LANDSAT-9 uydu verileri SENTINEL-2 uydu verilerine kıyasla aralarında çok fark olmamakla birlikte daha yüksek doğruluk oranına sahiptir. Sinir ağı sınıflandırması (ANN), LANDSAT-9 ve SENTINEL-2 uydu verilerinin her ikisinde de yüksek doğruluk oranı göstererek iyi performans sergilemiştir ancak ANN, SENTINEL-2 uydu verisinin küçük örnek boyutu LANDSAT-9 uydu verisinin küçük örnek boyutundan daha iyi sonuç verdi.

Destek vektör sınıflandırması (SVM), ANN'ya yakın sonuçlar vermektedir ancak LANDSAT-9 küçük örnek boyutunda ve büyük örnek boyutunda SENTINEL-2'den daha yüksek doğruluk oranları verdi. Piksel tabanlı sınıflandırmanın en yüksek doğruluk oranlı sonucunu LANDSAT-9 büyük örnek boyutlu SVM verdi. Nesne tabanlı sınıflandırmaya gelirse en iyi sınıflarcılardan birisidir, ve bu sınıflandırmada LANDSAT-9 ve SENTINEL-2 küçük ve büyük örnek boyutları için en yüksek sonucu vermektedir. 403 örnekten eğitilen bir SVM piksel tabanlı sınıflandırmasında gözlemlenen en düşük genel doğruluk %97,62 iken, 403 örnekten eğitilen nesne tabanlı en yüksek oran %98,51'dir. SVM'de nesne tabanlı ve piksel tabanlı sınıflandırmanın en yüksek ve en düşük genel doğruluğu arasındaki fark herhangi bir sınıflandırıcının en küçük aralığı olan %6,7 idi. Hem SVM hem de ANN, tüm örnek boyutları için diğer iki makine öğrenimi algoritmasından tutarlı olarak daha yüksek genel doğruluk elde eder.

SVM, nesne tabanlıda en yüksek ortalama genel doğruluğu 403 örneklik bir setten (%98,51) eğitim alırken, en düşük ortalama doğruluğu ise eğitim örnek boyutu yalnızca 200 (%86,63) olduğunda gördü. Eğitim örnek boyutu arttıkça SVM sınıflandırıcısının genel doğruluğu artmasına rağmen, örnek boyutu 403'e ulaştığında SVM genel doğruluğu düzleşmeye başladı. 200 örnek kullanılarak en kötü performans gösteren SVM sınıflandırması ile eğitilen en yüksek performans gösteren SVM sınıflandırması arasındaki doğruluk farkı 403 örnekte yalnızca %11,88 idi. Önemli bir nokta şudur ki, üreticilerin ve kullanıcıların tüm sınıflar üzerindeki ortalama doğrulukları örnek büyüklüğü arttıkça artmıştır. Bir örnekleme olarak, bir sınıflandırma döngüsünde 200 örnekle eğitildiğinde bina sınıfının kullanıcı doğruluğu %92,0 iken, 403 örnekle eğitildiğinde %99,0'a yükselmiştir.

3.2.2. Piksel Tabanlı Sınıflandırma

SENTINEL-2 küçük örnek boyutu için Piksel bazlı sınıflandırmada SVM, ANN ile karşılaştırılabilir ortalama genel doğruluk sağladı ve genellikle en doğru ikinci sınıflandırıcıydı. 200'den büyük veri seti boyutlarından eğitim alırken, ANN ile SVM arasındaki ortalama genel doğruluk farkı %1,02'idi; ANN, SVM'den biraz daha iyi performans gösterdi; ancak sentinel-2 küçük örnek boyutu piksel bazlı sınıflandırma için ANN'nun ortalama genel doğruluğu SVM'den %4,26 daha yüksekti. LANDSAT-9 küçük örnek boyutu için piksel bazlı sınıflandırmasında ise SVM'nin ortalama genel doğruluğu

ANN'dan %3,95 daha yüksek bulunmaktadır ancak LANDSAT-9 büyük örnek boyutu için ise SVM'nin ortalama genel doğruluğu ANN'dan %0,97 daha yüksek olmaktadır. LANDSAT-9 piksel bazlı sınıflandırmasında SVM, ANN'dan daha yüksek sonuç verirken SENTİNEL-2 piksel bazlı sınıflandırmasında ANN, SVM'den daha doğru sonuç vermiştir. Örneğin, 200 örnek üzerinden eğitim yapılırken SENTİNEL-2 piksel bazlı sınıflandırmasında SVM için bildirilen en yüksek genel doğruluk oranı %90,14 iken ANN için bildirilen en yüksek genel doğruluk oranı %94,40'dı ancak 403 örnek üzerinden eğitim yapılırken ANN için bildirilen en yüksek genel doğruluk oranı %94,97 iken SVM için bildirilen en yüksek doğruluk oranı %93,95'di. LANDSAT-9'a gelirse 200 örnek üzerinden eğitim yapılırken SVM için bildirilen en yüksek doğruluk oranı %97,41 iken ANN için bildirilen en yüksek doğruluk oranı %93,46'dı ancak 403 örnek üzerinden eğitim yapılırken SVM için bildirilen en yüksek doğruluk oranı %97,62 iken ANN için bildirilen en yüksek doğruluk oranı %96,65'di.

ANN, eğitim örneğinin boyutuna ve uydu görüntüsüne en fazla bağlı olan sınıflandırma yöntemidir. ANN sınıflandırıcısı, SENTİNEL-2 piksel tabanlı sınıflandırmada 403 örnek üzerinde eğitildiğinde ortalama %94,97 doğrulukla birinci en doğru sınıflandırıcıydı ancak LANDSAT-9 gelirse 403 örnek üzerinde eğitildiğinde ortalama %96,65 elde ederek ikinci en doğru sınıflandırıcıydı. Bu sentinel-2 piksel tabanlı sınıflandırıcı, SENTİNEL-2 üzerinde 200 örnek üzerinde eğitildiğinde, ortalama %94,40 doğrulukla, küçük örnek boyutlarıyla en iyiler arasında yer aldı. Bununla birlikte, landsat-9 %93,46'lık bir ortalama doğruluğa ulaştı ve bu, dört yöntem arasında en iyi üçüncü ortalama doğruluk oldu. Bu çalışmanın incelediği dört makine öğrenimi algoritması arasında, ANN, SENTİNEL-2'de 403 ve 200 örnekten eğitilen sınıflandırmalar arasında ortalama genel doğruluk açısından küçük bir farkı %0,57 ile elde etti (Şekil 14). Ayrıca, 20 sınıfın tamamı arasında ANN'nun minimum doğruluk oranı %93,46 ile en düşük üçüncü sınıftı (Şekil 15).

SVM sınıflandırıcısı genel olarak sınıflandırma doğruluğu açısından iyiydi ve ortalama genel doğruluk açısından genellikle ilk sırada yer aldı (Şekil 14). LANDSAT-9'da örneklem büyüklüğü 200'den 403'e yükseldiğinde, tüm sınıflandırıcılar arasında SVM %0,21 artışla ortalama genel doğrulukta en büyük artışı gösterirken, SENTİNEL-2 ise %3,81 artış gösterdi. Bu dikkat çekicidir çünkü SVM'nin çok büyük örnek kümelerinden ($n = 403$) faydalandığını ve doğruluk durumunun kararlı olmadığını göstermektedir. Daha büyük örnekler, özellik uzayında daha fazla örnek içerdiğinden,

hiperdüzlemi optimize etmeye ve destek vektör makine öğrenimi (SVM) sınıflandırması için daha ideal bir sınıf karar sınırı bulmaya yardımcı olmak üzere destek vektörleri olarak kullanılabilirler. Diğer dört sınıflandırıcıyla karşılaştırıldığında, SVM tipik olarak belirli veri seti boyutları için genel bireysel doğrulukta orta ila geniş farklılıklar sergiledi(Şekil 15).

MDC, SENTİNEL-2’de 200 örnek boyutunda %51,81 oranında doğruluk oranı vermiştir. 403 örnek boyutunda ise %66,90 doğruluk oranı vermiştir. MDC, SENTİNEL-2’de piksel tabanlı sınıflandırma türleri arasında hem 200 hem de 403 örnek boyutu için en az doğruluk oranını veren sınıflandırma türü olmuştur ancak örnek sayısı arttıkça doğruluk oranı da artmıştır. LANDSAT-9’da ise 200 örnek boyutunda MDC %72,96 doğruluk oranı vermiştir. 403 örnek boyutunda ise %75,62 doğruluk oranı vermiştir. MDC, LANDSAT-9 için de piksel tabanlı sınıflandırma türleri arasında en düşük doğruluk oranı vermiştir ancak SENTİNEL-2’de verdiği doğruluk oranları LANDSAT-9’da verdiği doğruluk oranlarından daha düşük olmuştur.

MDC, 200 örnek boyutunda SENTİNEL-2 ile LANDSAT-9 için doğruluk oranı farkı %21,15 olmuştur. Küçük örnek boyutunda LANDSAT-9 daha yüksek doğruluk oranı vermiştir. 403 örnek boyutunda ise SENTİNEL-2 ile LANDSAT-9 arasındaki doğruluk oranı farkı %8,72 olmuştur. Büyük örnek boyutunda da LANDSAT-9, SENTİNEL-2’den daha yüksek doğruluk oranı vermiştir ancak örnek boyutu arttıkça LANDSAT-9 ile SENTİNEL-2 arasındaki doğruluk oranı farkı azalmaya başlamıştır. MDC ile piksel tabanlı sınıflandırmaların arasında SENTİNEL-2 için en yüksek doğruluk oranını veren ANN arasında 200 örnek boyutunda %38,33 oranında büyük bir fark olmuştur. 403 örnek boyutunda ise %28,07 oranında fark oluşmuştur. SENTİNEL-2 için örnek boyutu arttıkça MDC ile ANN arasındaki doğruluk oranı farkı giderek azalmıştır ancak artış oranı belli bir yerde sabit kalmaktadır. Aradaki fark giderek azalsa bile her zaman ANN, MDC’den daha yüksek oranda doğruluk vermiştir. LANDSAT-9 için piksel tabanlı sınıflandırmaların arasında en yüksek doğruluk oranını veren sınıflandırma türü SVM ile MDC arasında 200 örnek boyutu için %24,45 oranında doğruluk farkı vermişken 403 örnek boyutunda %22 oranında doğruluk farkı vermiştir. SVM ile MDC arasındaki fark azalmaya başlamış olsa bile her zaman SVM, MDC’den daha yüksek doğruluk oranı vermiştir(Şekil 15).

MLC, SENTİNEL-2’de küçük örnek boyutunda %85,58 doğruluk oranı vermiştir. Büyük örnek boyutunda ise %85,91 doğruluk oranı vermiştir. MLC, SENTİNEL-2’de piksel tabanlı sınıflandırma türlerinin arasında hem küçük hem büyük örnek boyutu için en

az ikinci doğruluk oranını vermiştir. MLC, LANDSAT-9’da ise küçük örnek boyutunda %96,02 doğruluk oranı verirken büyük örnek boyutunda %97,62 doğruluk oranı vermiştir. MLC, LANDSAT-9’da piksel tabanlı sınıflandırma türlerinin arasında hem küçük hem de büyük örnek boyutu için en doğru ikinci doğruluk oranını vermiştir. MLC, SENTİNEL-2 için 200 örnek boyutunda MDC’den %33,77 daha fazla doğruluk oranı vermiştir. 403 örnek boyutunda ise MLC, MDC’den %19,01 daha fazla doğruluk oranı vermiştir. SENTİNEL-2 için bakıldığında örnek sayısı arttıkça MLC ile MDC arasındaki fark azalmıştır ancak MLC her zaman MDC’den daha yüksek doğruluk oranı vermiştir. LANDSAT-9 için küçük örnek boyutunda MLC ile MDC arasındaki fark %23,06 oranındadır. Büyük örnek boyutunda ise MLC ile MDC arasındaki fark %21,04 oranındadır. Hem büyük hem de küçük örnek boyutunda MLC, MDC’den daha yüksek doğruluk oranı vermiştir(Şekil 15).


3.2.3. Nesne Tabanlı Sınıflandırma

Nesne tabanlı sınıflandırma sonuçlarına gelirsek, SENTİNEL-2 küçük örnek boyutu için bildirilen en yüksek doğruluk oranı %86,63 olurken büyük örnek boyutu için bildirilen en yüksek doğruluk oranı ise %98,51 oldu ancak LANDSAT-9 küçük örnek boyutu için bildirilen en yüksek doğruluk oranı %83,16 olurken büyük örnek boyutu için bildirilen en yüksek doğruluk oranı ise %95,75 oldu. 200 örnek üzerinden eğitim yapılırken SENTİNEL-2’nin genel doğruluk oranı LANDSAT-9’un genel doğruluk oranından %3,47 daha yüksek sonuç vermiştir. 403 örnek üzerinden eğitim yapılırken SENTİNEL-2’nin genel doğruluk oranı LANDSAT-9’un genel doğruluk oranından %2,76 oranında daha yüksek sonuç vermiştir. Nesne tabanlı sınıflandırma hem SENTİNEL-2 hem LANDSAT-9’da büyük örnek boyutunda verdiği doğruluk oranları küçük örnek boyutunda verdiği doğruluk oranlarından daha yüksektir. Sonuç olarak nesne tabanlı sınıflandırma örnek sayısı arttıkça daha yüksek genel doğruluk oranı vermektedir (Şekil 16).

3.2.4. Piksel Tabanlı Sınıflandırma İle Nesne Tabanlı Sınıflandırma Karşılaştırması

SENTİNEL-2 için piksel tabanlı sınıflandırmaların arasında hem küçük hem de büyük örnek üzerinden ANN en yüksek doğruluk oranı verdi. Bu yüzden piksel ve nesne tabanlı sınıflandırmanın karşılaştırmasını yaparken SENTİNEL-2 için piksel tabanlı sınıflandırma sonuçlarından ANN'nun sonuçlarını kullanarak yapılan karşılaştırma sonuçları aşağıdaki gibidir: 200 örnek üzerinden yapılan sınıflandırmalar arasında piksel tabanlı sınıflandırma, nesne tabanlı sınıflandırmadan %7,77 oranında daha yüksek sonuç vermiştir. 403 örnek üzerinden yapılan sınıflandırmalar arasında ise nesne tabanlı sınıflandırma, piksel tabanlı sınıflandırmadan %3,54 oranında daha yüksek sonuç vermiştir.


Sonuç olarak SENTİNEL-2 için örnek sayısı arttıkça nesne tabanlı sınıflandırma, piksel tabanlı sınıflandırmadan daha yüksek oranda sonuç vermiştir. LANDSAT-9 için piksel tabanlı sınıflandırmaları kendi içerisinde karşılaştırdığımızda hem küçük örnek hem de büyük örnek üzerinden SVM'nin daha yüksek oranda sonuç vermiştir. Piksel tabanlı sınıflandırmayı nesne tabanlı sınıflandırma ile karşılaştırırken LANDSAT-9 için piksel tabanlı sınıflandırmaların arasından SVM'nin oranlarını kullanarak yapılan karşılaştırma sonuçları aşağıdaki gibidir: 200 örnek üzerinden yapılan sınıflandırmalar arasında piksel tabanlı sınıflandırma, nesne tabanlı sınıflandırmadan %14,25 oranında daha yüksek sonuç vermiştir. 403 örnek üzerinden yapılan sınıflandırmalar arasında piksel tabanlı sınıflandırma, nesne tabanlı sınıflandırmadan %1,87 oranında daha yüksek sonuç vermiştir. LANDSAT-9 için yapılan karşılaştırma sonucunda örnek sayısı değişse bile piksel tabanlı sınıflandırma daha yüksek oranda sonuç vermiştir ancak örnek sayısı az olduğunda piksel tabanlı sınıflandırma ile nesne tabanlı sınıflandırma arasında daha yüksek fark varken örnek sayısı arttıkça piksel tabanlı sınıflandırma ile nesne tabanlı sınıflandırma arasındaki fark azalmıştır.



Şekil 15. Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için piksel tabanlı genel doğruluk grafiği

Tablo 5. Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için piksel tabanlı genel doğruluk


SINIF	MDC	MLC	ANN	SVM
200(S)	51,81%	85,58%	94,40%	90,14%
403(S)	66,90%	85,91%	94,97%	93,95%
200(L)	72,96%	96,02%	93,46%	97,41%
403(L)	75,62%	96,66%	96,65%	97,62%



Şekil 16. Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için nesne tabanlı genel doğruluk grafiği

Tablo 6. Sentinel-2 Landsat-9 küçük örnek boyutu (200) ve büyük örnek boyutu (403) için nesne tabanlı genel doğruluk

SINIF	ECO
200(L)	83,16%
200(S)	86,63%
403(L)	95,75%
403(S)	98,51%



Şekil 17. Landsat-9 Sentinel-2'nin Piksel tabanlı ve Nesne tabanlı en yüksek sınıflandırıcının sonuçları

Tablo 7. Landsat-9 Sentinel-2'nin Piksel tabanlı ve Nesne tabanlı en yüksek sınıflandırıcının sonuçları

SINIF	ANN	SVM	NESNE
200(L)	94,40%	90,14%	83,16%
200(S)	94,97%	93,95%	86,63%
403(L)	93,46%	97,41%	95,75%
403(S)	96,65%	97,62%	98,51%

Gösterilen arazi örtüsü sınıflandırmaları, tek bir sınıflandırma yinelemesi ile her sınıflandırma yönteminin genel doğruluk açısından en iyi ve en kötü performans gösteren sınıflandırıcı örnekleridir. Sınıflandırma yöntemi etiketinin altındaki sayılar (ör. SVM), kullanılan eğitim örneklerinin sayısını temsil eder.

Tablo 8. Landsat-9 Piksel Tabanlı 200 örnek boyutundan yapılan Maximum Likelihood Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	91.98	97.55	2386/2594	2386/2446
Bitki	99.13	99.92	2509/2531	2509/2511
Su	94.17	100.00	323/343	323/323
Toprak	96.27	99.92	12302/12779	12302/12312
Yol	96.16	56.62	902/938	902/1593
Overall Accuracy = (18422/19185) 96,0229% Kappa Coefficient = 0.9255				

Tablo 9. Landsat-9 Piksel Tabanlı 200 örnek boyutundan yapılan Minimum Distance Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	66.46	84.30	1724/2594	1724/2045
Bitki	97.67	100.00	2472/2531	2472/2472
Su	93.59	98.17	321/343	321/327
Toprak	68.69	96.31	8778/12779	8778/9114
Yol	74.95	13.45	703/938	703/5227
Overall Accuracy = (13998/19185) 72,9633% Kappa Coefficient = 0.5766				

Tablo 10. Landsat-9 Piksel Tabanlı 200 örnek boyutundan yapılan Neural Net Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	97.30	79.37	2524/2594	2524/3180
Bitki	98.66	99.96	2497/2531	2497/2498
Su	94.75	100.00	325/343	325/325
Toprak	93.65	98.17	11967/12779	11967/12190
Yol	65.78	62.20	617/938	617/992
Overall Accuracy = (17930/19185) 93,4584% Kappa Coefficient = 0.8776				

Tablo 11. Landsat-9 Piksel Tabanlı 200 örnek boyutundan yapılan Support Vector Machine Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	95.95	94.21	2489/2594	2489/2642
Bitki	99.80	99.80	2526/2531	2526/2531
Su	94.75	98.90	325/343	325/325
Toprak	99.59	99.55	12727/12779	12727/12784
Yol	86.67	90.03	813/938	813/903
Overall Accuracy = (18880/19185) 97,4102% Kappa Coefficient = 0.9693				

Tablo 12. Landsat-9 Nesne Tabanlı 200 örnek boyutundan yapılan Sınıflandırma doğruluk oranı

Class	Producer	User	Hellden	Short	KIA Per Class
Bina	0.7868852459	0.88888888889	0.8347826087	0.71641791045	0.70912715995
Bitki	1	1	1	1	1
Su	1	0.5	0.66666666667	0.5	1
Toprak	0.78333333333	1	0.8785046729	0.78333333333	0.7176344086
Yol	0.38461538462	0.2	0.26315789474	0.15151515152	0.29769665363
Overall Accuracy =83,16% KIA = 0.7758					

Tablo 13. Landsat-9 Piksel Tabanlı 403 örnek boyutundan yapılan Maximum Likelihood Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	92.13	96.37	4705/5107	4705/4882
Bitki	99.60	99.64	5531/5553	5531/5551
Su	97.50	100.00	1013/1039	1013/1013
Toprak	97.74	99.60	15337/15691	15337/15398
Yol	89.76	66.84	1429/1592	1429/2138
Overall Accuracy = (28015/28982) 96,6634% Kappa Coefficient = 0.9479				

Tablo 14. Landsat-9 Piksel Tabanlı 403 örnek boyutundan yapılan Minimum Distance Sınıflandırma doğruluk oranı.

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	76.50	73.47	3907/5107	3907/5318
Bitki	98.65	100.00	5478/5553	5478/5478
Su	97.69	100.00	1015/1039	1015/1015
Toprak	65.32	95.54	10250/15691	10250/10728
Yol	79.46	19.63	1265/1592	1265/6443
Overall Accuracy = (21915/28982) 75,6159% Kappa Coefficient = 0.6602				

Tablo 15. Landsat-9 Piksel Tabanlı 403 örnek boyutundan yapılan Neural Net Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	97.55	89.24	4982/5107	4982/5583
Bitki	99.89	99.68	5547/5553	5547/5565
Su	97.98	100.00	1018/1039	1018/1018
Toprak	99.14	98.06	15556/15691	15556/15863
Yol	56.97	95.17	907/1592	907/953
Overall Accuracy = (28010/28982) 96,6462% Kappa Coefficient = 0.9468				

Tablo16. Landsat-9 Piksel Tabanlı 403 örnek boyutundan yapılan Support Vector achine Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	95.83	93.54	4894/5107	4894/5232
Bitki	99.87	99.89	5546/5553	5546/5552
Su	97.98	100.00	1018/1039	1018/1018
Toprak	99.44	98.72	15603/15691	15603/15806
Yol	77.26	89.52	1230/1592	1230/1374
Overall Accuracy = (28291/28982) 97,6158% Kappa Coefficient = 0.9623				

Tablo 17. Landsat-9 Nesne Tabanlı 403 örnek boyutundan yapılan Sınıflandırma doğruluk oranı

Class	Producer	User	Hellden	Short	KIA Per Class
Bina	0.9	0.92307692308	0.91139240506	0.83720930233	0.85865724382
Bitki	1	1	1	1	1
Su	1	1	1	1	1
Toprak	0.98230088496	0.9173553719	0.94871794872	0.90243902439	0.97462492467
Yol	0.72	0.9	0.8	0.66666666667	0.70526315789
Overall Accuracy = 95,75% KIA = 0.9278					

Tablo 18. Sentinel-2 Piksel Tabanlı 200 örnek boyutundan yapılan Maximum Likelihood Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	39.27	56.13	1608/4095	1608/2865
Bitki	99.92	99.55	3763/3766	3763/3780
Su	97.62	100.00	2420/2479	2420/2420
Toprak	92.33	98.79	14453/15653	14453/14630
Yol	86.12	8.30	211/245	211/2543
Overall Accuracy = (22455/26238) 85,5820% Kappa Coefficient = 0.7675				

Tablo 19. Sentinel-2 Piksel Tabanlı 200 örnek boyutundan yapılan Minimum Distance Sınıflandırma doğruluk oranı

class	Prod. Acc Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	25.80	20.99	1675/6492	1675/7980
Bitki	99.91	99.76	7489/7496	7489/7507
Su	98.93	96.24	3434/3471	3434/3568
Toprak	45.72	96.65	26810/58643	26810/27739
Yol	53.01	2.65	818/1543	818/30851
Overall Accuracy = (40226/77645) 51,8076% Kappa Coefficient = 0.3138				

Tablo 20. Sentinel-2 Piksel Tabanlı 200 örnek boyutundan yapılan Neural Net Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	67.01	97.86	2744/4095	2744/2804
Bitki	99.97	99.18	3765/3766	3765/3796
Su	100.00	100.00	2479/2479	2479/2479
Toprak	99.89	94.70	15635/15653	15635/16510
Yol	59.18	22.34	145/245	145/649
Overall Accuracy = (24768/26238) 94,3974% Kappa Coefficient = 0.9031				

Tablo 21. Sentinel-2 Piksel Tabanlı 200 örnek boyutundan yapılan Support Vector Machine Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	39.00	99.50	1597/4095	1597/1605
Bitki	99.95	99.68	3764/3766	3764/3776
Su	99.96	100.00	2478/2479	2478/2478
Toprak	99.95	94.94	15645/15653	15645/16478
Yol	67.76	8.73	166/245	166/1901
Overall Accuracy = (23650/26238) 90,1364% Kappa Coefficient = 0.8315				

Tablo 22. Sentinel-2 Nesne Tabanlı 200 örnek boyutundan yapılan Sınıflandırma doğruluk oranı

Class	Producer	User	Hellden	Short	KIA Per Class
Bina	0.61666666667	0.925	0.74	0.5873015873	0.52201646091
Bitki	1	0.98360655738	0.99173553719	0.98360655738	1
Su	0.90909090909	1	0.95238095238	0.90909090909	0.90435606061
Toprak	1	1	1	1	1
Yol	0.72727272727	0.25806451613	0.38095238095	0.23529411765	0.67783094099
Overall Accuracy = 86,63% KIA = 0.8223					

Tablo 23. Sentinel-2 Piksel Tabanlı 403 örnek boyutundan yapılan Maximum Likelihood Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	69.45	63.85	5335/7682	4145/6492
Bitki	0.31	0.15	23/7508	11/7496
Su	0.00	1.50	0/3419	52/3471
Toprak	0.55	10.48	291/52789	6145/58643
Yol	84.66	37.91	5289/6247	585/1543
Overall Accuracy = (66707/77645) 85,9128% Kappa Coefficient = 0.6973				

Tablo 24. Sentinel-2 Piksel Tabanlı 403 örnek boyutundan yapılan Minimum Distance Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	12.92	26.52	529/4095	529/1995
Bitki	99.95	97.77	3764/3766	3764/3850
Su	100.00	96.35	2479/2479	2479/2573
Toprak	67.73	97.22	10602/15653	10602/10905
Yol	73.06	2.59	179/245	179/6915
Overall Accuracy = (17553/26238) 66,8992% Kappa Coefficient = 0.5321				

Tablo 25. Sentinel-2 Piksel Tabanlı 403 örnek boyutundan yapılan Neural Net Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	70.41	74.67	4571/6492	4571/6122
Bitki	99.99	99.68	7495/7496	7495/7519
Su	98.70	99.97	3426/3471	3426/3427
Toprak	98.13	98.04	57548/58643	57548/58701
Yol	45.37	37.31	700/1543	700/1876
Overall Accuracy = (73740/77645) 94,9707% Kappa Coefficient = 0.8775				

Tablo 26. Sentinel-2 Piksel Tabanlı 403 örnek boyutundan yapılan Support Vector Machine Sınıflandırma doğruluk oranı

class	Prod. Acc (Percent)	User Acc (Percent)	Prod. Acc (Pixels)	User Acc (Pixels)
Bina	59.27	68.59	3848/6492	3848/5610
Bitki	99.97	99.68	7494/7496	7494/7518
Su	98.91	99.74	3433/3471	3433/3442
Toprak	97.92	98.14	57426/58643	57426/58516
Yol	48.61	29.31	750/1543	750/2559
Overall Accuracy = (72951/77645) 93,9545% Kappa Coefficient = 0.8535				

Tablo 27. Sentinel-2 Nesne Tabanlı 403 örnek boyutundan yapılan Sınıflandırma doğruluk oranı


Class	Producer	User	Hellden	Short	KIA Per Class
Bina	0.95967741935	0.99166666667	0.97540983607	0.952	0.9425795053
Bitki	1	1	1	1	1
Su	1	0.89473684211	0.94444444444	0.89473684211	1
Toprak	1	1	1	1	1
Yol	0.95454545455	0.875	0.91304347826	0.84	0.95166706644
Overall Accuracy =98,51% KIA = 0.9794					

3.2.5. Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Google Earth ile Karşılaştırması

Bu sınıflandırmadaki tüm doğruluk oranları bir yazılımın (ENVI & eCognition) sonuçlarıdır ancak bu sonuçların gerçek zeminde ne kadar doğru olduğunu görebilmek için google earth ile karşılaştırıldı. ArcMap 10.5.1’de doğruluk değerlendirme noktasını oluşturduk. Sınıflandırılmış görüntü üzerine 300 rastgele nokta sayısı atıldı (Şekil 13) ve bu noktaları kml dosyasına çevirilip Google Earthe aktarıldı. Doğruluk analizi için seçtiğimiz sınıflandırmanın gerçek dünya durumuyla ne kadar uyumlu olduğunu değerlendirebiliriz. Yazılım kullanarak bulununan doğruluk oranlarının gerçek zeminde ne kadar doğru olduğunu görebilmek için piksel tabanlı ve nesne tabanlı sınıflandırma sonuçlarının arasında hem SENTİNEL-2’de hem de LANDSAT-9’da küçük ve büyük örnek boyutlarında en yüksek çıkan doğruluk oranları google earth ile karşılaştırıldı. SENTİNEL-2’de piksel tabanlı sınıflandırma türleri arasında küçük ve büyük örnek boyutlarında ANN en yüksek doğruluk oranlarını verdiği için google earth ile karşılaştırırken ANN kullanılmıştır. LANDSAT-9’da ise piksel tabanlı sınıflandırma türleri

arasında küçük ve büyük örnek boyutlarında en yüksek doğruluk oranını SVM verdiği için google earth ile karşılaştırma yapılırken SVM kullanılmıştır.

SENTİNEL-2’de 200 örnek boyutunda ANN %94,40 doğruluk oranı verirken google earth ile karşılaştırıldığında ANN %85,38 doğruluk oranı vermiştir. Google earth ile ANN karşılaştırıldığında 200 örnek boyutunda ANN’nun gerçek zemin üzerinde verdiği doğruluk oranı %9,02 azalmıştır. 200 örnek boyutunda nesne tabanlı sınıflandırma %86,63 doğruluk oranı vermiş ancak google earth ile karşılaştırıldığında nesne tabanlı sınıflandırma %85,66 doğruluk oranı vermiştir (Şekil 19). Nesne tabanlı sınıflandırmanın gerçek zemin ile arasındaki doğruluk oranı farkı %0,97’dir. Bu sonuçlara bakıldığında nesne tabanlı sınıflandırma sonucu gerçek zemin ile daha yakın olmuştur ve piksel tabanlı sınıflandırmaya göre daha yüksek oranda doğruluk sağlamıştır. 403 örnek boyutunda ise ANN %94,97 doğruluk oranı verirken google earth ile karşılaştırıldığında %1 oranında azalarak %93,97 doğruluk oranı vermiştir. Nesne tabanlı sınıflandırma ise %98,51 oranında doğruluk vermiş ancak google earth ile karşılaştırıldığında bu oran %1,45 oranında azalarak %96,97 doğruluk oranı vermiştir. Böylece 403 örnek boyutunda nesne tabanlı sınıflandırma gerçek zemin ile karşılaştırıldığında piksel tabanlı sınıflandırmadan daha yüksek doğruluk oranı vermiştir (Şekil 19).




Şekil 20. Sentinel-2 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği

Tablo 28. Sentinel-2 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği

SINIF	ANN	(ANN)_GE	NESNE	(NESNE)_GE
200(S)	94,40%	85,38%	86,63%	85,66%
403(S)	94,97%	93,97%	98,51%	96,97%

LANDSAT-9'da 200 örnek boyutu için SVM %97,41 doğruluk oranı vermiştir. SVM ile google earth karşılaştırıldığında SVM %19,18 oranında azalarak gerçek zemin üzerinde %78,33 doğruluk oranı vermiştir. Nesne tabanlı sınıflandırma ise %83,16 doğruluk oranı vermiştir. Google earth ile karşılaştırma yapıldığında nesne tabanlı sınıflandırma %4,16 oranında azalarak gerçek zemin üzerinde %79 doğruluk oranı vermiştir (Şekil 20). LANDSAT-9'da 200 örnek boyutu için nesne tabanlı sınıflandırma daha yüksek doğruluk oranı vermiştir. 403 örnek boyutunda ise SVM %97,62 doğruluk oranı vermiştir. SVM ile google earth karşılaştırıldığında SVM %6,78 oranında azalarak gerçek zemin üzerinde %90,84 doğruluk oranı vermiştir. LANDSAT-9'da 403 örnek boyutu için nesne tabanlı sınıflandırma daha yüksek oranda doğruluk vermiştir (Şekil 20).



Şekil 21. Landsat-9 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği

Tablo 29. Landsat-9 için piksel ve nesne tabanlı sınıflandırma zemin gerçeği

SINIF	SVM	(SVM)_GE	NESNE	(NESNE)_GE
200(L)	97,41%	78,33%	83,16%	79,00%
403(L)	97,62%	90,84%	95,75%	91,33%

Genel olarak bakıldığında SENTİNEL-2’de ve LANDSAT-9’da nesne tabanlı sınıflandırma gerçek zemin üzerinde daha yüksek doğruluk oranları vermiştir. Cochran formülü kullanılarak gerçek zemindeki doğruluğu ölçerken %95 doğruluk oranına ulaşabilmek için 403 örnek boyutu kullanılması gerektiği sonucuna varılmıştır. Hedeflenen %95 doğruluk oranına SENTİNEL-2’de 403 örnek boyutunda ve nesne tabanlı sınıflandırmada ulaşılmıştır (Şekil 21).

Tablo 30. Sentinel-2’de 200 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]

Tablo 31. Sentinel-2’de 200 örnek boyutu için piksel tabanlı (ANN) sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]

Tablo 32. Sentinel-2’de 403 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]

Tablo 33. Sentinel-2’de 403 örnek boyutu için piksel tabanlı (ANN) sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]

Tablo 34. Landsat-9’da 200 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]

Tablo 35. Landsat-9’da 200 örnek boyutu için piksel tabanlı (svm) sınıflandırmanın gerçek zemin doğruluk oranı


[illegible]

Tablo 36. Landsat-9’da 403 örnek boyutu için nesne tabanlı sınıflandırmanın gerçek zemin doğruluk oranı

OBJECTID	ClassValue	Toprak	Su	Bina	Yol	Bitki	Total	U_Accuracy	Kappa
1	Toprak	59	1	0	0	0	60	0,983333	0
2	Su	8	42	4	1	5	60	0,7	0
3	Bina	2	0	57	1	0	60	0,95	0
4	Yol	2	0	2	56	0	60	0,933333	0
5	Bitki	0	0	0	0	60	60	1	0
6	Total	71	43	63	58	65	300	0	0
7	P_Accuracy	0,830986	0,976744	0,904762	0,965517	0,923077	0	0,913333	0
8	Kappa	0	0	0	0	0	0	0	0,891667

Tablo 37. Landsat-9’da 403 örnek boyutu için piksel tabanlı (svm) sınıflandırmanın gerçek zemin doğruluk oranı

[illegible]




Şekil 22. Sentinel-2 ve Landsat-9 için nesne tabanlı sınıflandırma zemin gerçeği

Tablo 38. Sentinel-2 ve Landsat-9 için nesne tabanlı sınıflandırma zemin gerçeği

NOKTA	SENTINEL-2	LANDSAT-9
200N	85,66%	79%
403N	96,97%	91,33%

ENVI %85,38 doğruluk oranı gösterirken eCognition %85,66 doğruluk oranı göstermiş ve eCognition ENVI'den daha yüksek doğruluk oranı vermiştir (Şekil 22). SENTİNEL-2 için 403 örnek boyutunda ise ENVI %93,97 doğruluk oranı göstermiş ancak eCognition %96,97 doğruluk oranı vermiştir. eCognition, ENVI'den %3 daha yüksek sonuç vermiştir (Şekil 22). 403 örnek boyutu için hedeflenen %95 doğruluk oranına ENVI ulaşamamış fakat eCognition ulaşmıştır.



Şekil 23. ENVI ve eCognition yazılım türlerinin karşılaştırma sonuçları


Tablo 39. ENVI ve eCognition yazılım türlerinin karşılaştırma sonuçları

NOKTA	ENVI	ECOGNITION
200N	85,38%	85,66%
403N	93,97%	96,97%

3.2.6. Görsel Analiz

Örneklem boyutundan bağımsız olarak (örneğin, 200 örnek) tutarlılık sağlamak amacıyla her sınıflandırıcı için aynı eğitim veri seti kullanılmıştır. Sonuçta elde edilen sınıflandırmaların genel doğruluğu, Şekil 14’te grafik olarak gösterilmektedir. Şekil 18 ve 19, SENTİNEL-2’de ve LANDSAT-9’da her sınıflandırıcı için yalnızca en iyi ve en düşük genel doğruluğa sahip sınıflandırmaları gösterir. SENTİNEL-2’de 403 veriden eğitilen SVM ve ANN sınıflandırıcıları, bu sınıflandırma yinelemesinde 200 örnekten eğitilen sınıflandırmalara göre daha yüksek bir genel doğruluk elde etmiştir. Aynı şekilde nesne tabanlı sınıflandırmalarda da 403 örnek boyutunda elde edilen doğruluk verileri 200 örnek boyutundan elde edilen verilerden daha yüksek bir genel doğruluk elde etmiştir. Daha büyük veri setlerinden öğrenilen sınıflandırmadaki net kazanımlar, örnek sınıflandırmaların görsel olarak değerlendirilmesi üzerine açıkça görülmektedir (Şekil 18). Toprak ve yol sınıflarının yanlış sınıflandırılması yanlışlıkların çoğunluğundan sorumluydu. Özellikle, 200 örnek kullanılarak eğitilen MDC sınıflandırmasında çok sayıda

toprak nesnesi hatalı bir şekilde yol olarak sınıflandırılmıştır ve bunun tersi de geçerlidir. MDC sınıflandırmasında oluşan bu hata oranı 403 örnek kullanılarak azaldı. Toprak verileri 200 örnekte üretici %45,01 oranındayken 403 örnek kullanıldığında %22,72 artarak %67,73'e yükseldi. Kullanıcı verilerinde ise 200 örnekte %96,65 oranındayken 403 örnek kullanıldığında %0,57 oranında artarak %97,22'ye yükseldi.



Şekil 24. Araştırma alanının genel arazi örtüsü sınıflandırmasına bir örnek

Genel olarak %96,97'lik bir doğrulukla sınıflandırma, 403 örnek üzerinde eğitilen nesne tabanlı sınıflandırma (SVM) kullanılarak oluşturuldu. Siyah daire, Şekil 19'da sınıflandırma hatasıyla ilişkili cadde konumunu gösterir.

4. TARTIŞMA

Bulgularımız, dört sınıflandırıcı tarafından kullanılan doğruluk ve işleme kaynaklarının, eğitim setinin boyutuna bağlı olarak değiştiğini göstermektedir. Sınıflandırıcı performansının genellikle daha yüksek örnek boyutlarıyla arttığını keşfettik; bu, (Qian ve Zhou, 2015) tarafından bildirilen verilerle tutarlıdır. Bununla birlikte, bazı sınıflandırıcılar, özellikle de MDC, MLC için, örnek kümesi boyutunu belirli bir noktanın üzerine çıkarmanın, iki kat daha büyük bir eğitim kümesi kullanıldığında bile, hesaplama gereksinimleri artarken sınıflandırma doğruluğunu önemli ölçüde iyileştirmediklerini de gözlemledik. Öte yandan, daha büyük veri seti sayıları, genel doğruluğun yanı sıra kullanıcı ve üretici sınıfı doğruluğunu da geliştirerek SVM ve ANN'ya yardımcı olmaya devam etti. Örnek boyutu arttıkça veya azaldıkça her sınıflandırıcı farklı sonuçlar vermektedir. SENTİNEL-2'de küçük örnek boyutu ve büyük örnek boyutu için MLC çok yakın doğruluk oranı vermiş ancak örnek boyutu artınca örneğin bina için üretici ve kullanıcı doğruluk oranları artmış fakat yol için üretici doğruluk oranı azalırken kullanıcı doğruluk oranı artmıştır.

SENTİNEL-2'de örnek boyutu arttıkça MDC doğruluk oranı da artmıştır ancak bazı sınıflarda hem üretici hem kullanıcı oranları artarken bazı sınıflarda üretici ve kullanıcıdan biri artarken biri azalır. Örneğin bina sınıfının doğruluk oranı kullanıcı için artmış fakat üretici doğruluk oranı azalmıştır. SENTİNEL-2'de MDC ve MLC her ne kadar doğruluk oranları arasında artışlar gösterse de diğer sınıflandırıcılar kadar yüksek doğruluk oranı vermemiştir. Yüksek doğruluk oranı veren sınıflandırıcılardan biri olan ANN'da örnek boyutu artınca genel doğruluk oranı çok yakın sonuçlar vermiş ancak üretici oranları her sınıfta artış gösterirken kullanıcı oranları bina ve su sınıflarında azalma göstermiş diğer sınıflarda artış göstermiştir. SVM'de ise örnek boyutu artınca genel doğruluk oranı da artmış ancak üretici oranlarında bina ve bitki doğruluk oranları artış gösterirken su, toprak ve yol doğruluk oranları azalış göstermiştir. Kullanıcı oranlarında ise bitki doğruluk oranı değişmemiş, bina ve su doğruluk oranı azalmış, toprak ve yol doğruluk oranları ise artmıştır. MLC ve MDC her ne kadar örnek boyutu arttıkça genel doğruluk oranında artış gösterse de belli bir yerden sonra artış göstermemeye yani sabit kalaya başlamıştır. SVM ve ANN'da ise örnek boyutu arttıkça sürekli olarak genel doğruluk oranı da artış göstermiştir. ANN ve SVM sınıflandırma yaparken MLC ve MDC'ye göre daha uzun süre

sonra sonuç vermiştir, Ancak tüm sınıflandırıcıların hesaplama süreleri kullanılan programa, diline ve ortama bağlı olarak değişiklik gösterebilmektedir. 200 ve 403 örnekten oluşan iki farklı örnek boyutu kullanılarak sınıflandırma yapılmasının sebebi sınıflandırıcılar arasındaki doğruluk oranları farklılıklarını gözlemlemektir. Yani örneklem büyüklüğü aralığı, sınıflandırma yöntemleri arasındaki farklılıkları gözlemlemek amacıyla seçilmiştir. SENTİNEL-2’de nesne tabanlı sınıflandırmada örnek boyutu arttıkça genel doğruluk oranı da artmıştır. Üretici doğruluk oranlarında bitki ve toprak doğruluk oranı sabit kalırken bina, su ve yol doğruluk oranları artmıştır. Kullanıcı doğruluk oranlarında ise su doğruluk oranı azalırken bina, bitki ve yol doğruluk oranları artmıştır. Toprak doğruluk oranları ise sabit kalmıştır. SENTİNEL-2’de büyük örnek boyutu için nesne tabanlı sınıflandırma yapılırken piksel tabanlı sınıflandırma türlerine göre daha uzun sürede sonuç vermiş ve piksel tabanlı sınıflandırmadan daha yüksek doğruluk oranı vermiştir. Küçük örnek boyutunda ise piksel tabanlı sınıflandırma türü olan ANN nesne tabanlı sınıflandırmadan daha yüksek doğruluk oranı vermiştir.

LANDSAT-9’da ise örnek boyutu arttıkça MLC çok yakın genel doğruluk oranı vermiş ancak MDC’de genel doğruluk oranı daha fazla artış göstermiştir. MLC için üretici doğruluk oranları, örnek boyutu arttıkça yol sınıfı hariç bütün sınıflarda artış göstermiştir. Yol sınıfında ise doğruluk oranı azalmıştır. Kullanıcı doğruluk oranlarında ise yol sınıfının doğruluk oranı artarken bina, bitki ve toprak sınıflarının doğruluk oranı azalmıştır. Su sınıfının doğruluk oranı ise sabit kalmış, değişiklik göstermemiştir. MDC için ise üretici doğruluk oranları örnek boyutu arttıkça toprak sınıfının hariç diğer sınıfların doğruluk oranları artmıştır. Toprak sınıfının doğruluk oranı ise azalmıştır. Kullanıcı doğruluk oranlarında ise bitki sınıfının doğruluk oranı sabit kalırken bina ve toprak sınıfının doğruluk oranı azalmış, su ve yol sınıfının doğruluk oranları artmıştır.

LANDSAT-9’da örnek boyutu arttıkça SVM çok yakın genel doğruluk oranı vermiş ancak ANN’da genel doğruluk oranı daha fazla artış göstermiştir. ANN için üretici doğruluk oranları örnek boyutu arttıkça yol sınıfı hariç tüm sınıflarda artış gösterirken yol sınıfında azalmıştır. Kullanıcı doğruluk oranlarında ise su sınıfının doğruluk oranı sabit kalırken bina ve yol doğruluk oranı artmış ancak bitki ve toprak sınıfının doğruluk oranları azalmıştır. SVM’de ise örnek boyutu arttıkça üretici doğruluk oranları yol ve toprak sınıflarında azalırken bina, bitki ve su sınıflarında artmıştır. Kullanıcı doğruluk oranları ise bitki ve su sınıfında artmışken bina, yol ve toprak sınıflarında azalmıştır. LANDSAT-9’da da SENTİNEL-2’de olduğu gibi MLC ve MDC her ne kadar örnek boyutu arttıkça genel

doğruluk oranında artış gösterse de belli bir yerden sonra artış göstermemeye yani sabit kalaya başlamıştır. SVM ve ANN'da ise örnek boyutu arttıkça sürekli olarak genel doğruluk oranı da artış göstermiştir. SVM ve ANN, MLC ve MDC'den daha uzun sürede sonuç vermiştir bunun sebebi ise sınıflandırıcıların hesaplama sürelerinin kullanılan programa, diline ve ortama bağlı olarak değişiklik gösterebilmesidir. LANDSAT-9'da nesne tabanlı sınıflandırmada örnek boyutu arttıkça genel doğruluk oranı da artmıştır. Örnek boyutu arttıkça üretici doğruluk oralarında bitki ve su sınıfının doğruluk oranları sabit kalırken bina, toprak ve yol sınıflarının doğruluk oranı artmıştır. LANDSAT-9'da nesne tabanlı sınıflandırmaya göre örnek boyutu arttıkça üretici doğruluk oranlarında azalma olan hiçbir sınıf olmamıştır. Kullanıcı doğruluk oranlarında ise bitki sınıfının doğruluk oranı sabit kalırken bina, su ve yol sınıflarının doğruluk oranı artmış, toprak sınıfının doğruluk oranı ise azalmıştır. LANDSAT-9'da hem büyük hem de küçük örnek boyutu için piksel tabanlı sınıflandırma türü olan SVM nesne tabanlı sınıflandırmadan daha yüksek doğruluk oranı vermiştir. SENTİNEL-2'de nesne tabanlı sınıflandırma daha yüksek doğruluk oranı verebilmişken LANDSAT-9'da piksel tabanlıdan daha yüksek doğruluk oranı verememiştir. MDC, Landsat-9'da Sentinel-2'den daha yüksek doğruluk oranı vermiştir. Bunun sebebi ise Sentinel-2'nin yüksek çözünürlük ve daha fazla spektral bant içermesi nedeniyle sınıflandırıcıyı daha karmaşık hale getirir. MDC gibi basit sınıflandırıcılar, bu karmaşıklığı doğru bir şekilde işleyemeyebilir ve yanlış sınıflandırmalara yol açabilir.

Tüm bu sonuçlar gerçek zemin ile karşılaştırıldığında hem SENTİNEL-2 hem LANDSAT-9'da 200 ve 403 örnek boyutu için nesne tabanlı sınıflandırma daha yüksek doğruluk oranı vermiştir. Gerçek zemin ile karşılaştırma yapıldığında piksel tabanlı sınıflandırma türlerinin hiçbirisi nesne tabanlı sınıflandırmadan daha yüksek oranda doğruluk sonucu verememiştir. SENTİNEL-2'de örnek boyutu arttıkça bütün sınıflandırma türleri için doğruluk oranları da artmıştır. ANN'da örnek boyutu artınca doğruluk oranı diğer sınıflandırıcılara göre daha az oranda artış göstermiş olsa bile MLC, MDC ve SVM'den daha yüksek sonuç vermiştir. Ayrıca tüm sınıflandırmalarda oran artışı gözlenmiş olsa bile en yüksek oran artışı nesne tabanlı sınıflandırmada olmuştur. LANDSAT-9'da ise örnek boyutu arttıkça tüm sınıflandırma türleri artış göstermiştir ancak en yüksek doğruluk oranına SVM'de ulaşılmıştır. Her ne kadar en yüksek sonuç SVM'de görülsede örnek boyutu arttıkça doğruluk oranında gözlemlenen en büyük artış nesne tabanlı sınıflandırmada görülmüştür.

Rastgele seçilen eğitim örneklerinin kasıtlı olarak seçilenlerden daha iyi performans gösterme eğiliminde olduğunu gösterdik (Ramezan ve Maxwell, 2019). Bu deneylerde gerçekleştirilen sınıflandırmalar için belirli doğruluk ölçümlerini rapor ediyoruz ancak sınıflandırıcıların performansı, sınıf sayısı, eğitim verilerinin kalitesi ve çalışma alanının boyutu ve bileşimi gibi çeşitli faktörlere bağlı olarak değişebilir. Genel olarak analistler mümkün olduğu kadar çok eğitim örneği toplamalıdır ancak, MDC ve MLC gibi bazı sınıflandırıcılar artan örnek boyutundan yararlanamayabilir. Çeşitli örnek kümelerinden eğitildiklerinde, daha büyük örnek boyutlarından eğitilen sınıflandırmalar, daha küçük örnek kümelerinden eğitilen sınıflandırmalara göre genellikle genel doğrulukta daha az dalgalanma sergilemiştir. Genel doğrulukta sağlamlık için, daha küçük eğitim setleri yerine daha büyük eğitim setleri tercih edilir. Bazı algoritmalar, özellikle daha büyük eğitim setleriyle, eğitim ve sınıflandırma işlemleri için hesaplama süresi açısından diğerlerinden daha pahalıdır; bu nedenle, özellikle daha yüksek eğitim örnek boyutları kullanılıyorsa, analistin hesaplama süresini hesaba katması gerekir. Ek olarak, bu çalışmada sınıflandırmada piksel ve nesne tabanlı sınıflandırma kullanılmıştır. Sınıflandırıcıları ve örnek boyutunu içeren (Shang ve Zhou, 2018) gibi diğer araştırmalar, nesne tabanlı sınıflandırma yaklaşımlarının piksel tabanlı sınıflandırma yaklaşımlardan daha üstün genel doğruluklar sağladığını öne sürse bu çalışmada sınıflandırma türleri ile gerçek zemin doğruluğu karşılaştırıldığında nesne tabanlı sınıflandırma piksel tabanlı sınıflandırmadan daha doğru sonuç vermiştir. Gelecekteki çalışmalar, örnek boyutlarının, özellik eleme ve sıralama prosedürleri gibi sınıflandırmanın diğer yönlerini nasıl etkilediğinin yanı sıra, hesaplama karmaşıklığını artırabilecek ve potansiyel olarak sınıflandırma hatasına neden olabilecek ekstra, yardımcı olmayan tahmin değişkenlerinin eklenmesine bakmalıdır.

Ayrıca bu çalışmada Kerkük şehrinin haritası üzerine çalışma yapılmıştır. Kerkük şehrinde toprak alanı fazla olduğu için sınıflandırma yapılırken bazı sınıflar yanlış sınıflandırıldı. Örneğin bazı yerlerdeki bina ve yollar piksel tabanlı sınıflandırmada toprak gibi görüldü ancak nesne tabanlı sınıflandırma yaparak bina ve yollar ayırt edilebildi. Bu yüzden nesne tabanlı sınıflandırma gerçek zeminle karşılaştırıldığında daha yüksek doğruluk oranı verdi.

5. SONUÇLAR

Bu araştırmada, eğitim örneklerinin miktarına bağlı olarak SENTİNEL-2 ve LANDSAT-9 kullanılarak büyük ölçekli uzaktan algılanan veri kümesini sınıflandırırken beş denetimli algoritmanın (SVM, MLC, MDC, ANN ve ECO-SVM) nasıl performans gösterdiği incelendi. Genel doğruluk oranları 200 ile 403 örnek boyutu arasında değişiyordu. Genellikle büyük eğitim setlerinin küçük eğitim setlerinden daha yüksek doğruluk oranı verdiği diğer çalışmalarda da görülmüştür. Bazı çalışmalarda önemli farklılıklar bulunsa da bu çalışmada beş denetimli algoritmalar kullanılarak hem SENTİNEL-2’de hem LANDSAT-9’da büyük eğitim setleri daha yüksek doğruluk oranı vermiştir. Genel olarak algoritma yöntemlerinin örneklem büyüklüğündeki değişikliklere verdikleri yanıt önemli ölçüde farklılık gösterdi. Doğruluk oranı, aynı sınıflandırıcı ve aynı miktarda eğitim örneği olsa bile, farklı eğitim örnekleri kullanan sınıflandırmalar arasında farklılık gösteriyordu. Bu nedenle eğitim setinin boyutuna bağlı olarak bazı algoritma sınıflandırıcıları diğerlerinden daha fazla doğruluk sunabilir. Uzaktan algılanan verilerin denetimli sınıflandırmasını gerektiren herhangi bir proje için en iyi uygulama olarak çeşitli algoritma sınıflandırıcılarının tekniklerine bakmanızı öneririz. Bu çalışmayı yaparken gördüklerimize bakarsak nesne tabanlı sınıflandırma algoritması piksel tabanlı sınıflandırma algoritmasından daha iyidir. Yani nesne tabanlı sınıflandırma algoritması olan SVM diğer tüm sınıflandırıcılardan daha iyidir. Eğer çeşitli sınıflandırmaları test etmek pratik değilse nesne tabanlı sınıflandırma algoritması olan SVM’nin diğer sınıflandırma algoritmalarından daha yüksek doğruluk oranlarını verdiği göz önünde bulundurularak bu çalışmada incelenen eğitim örnek boyutları için kullanılabilecek en iyi sınıflandırma algoritması ECO-SVM olarak görünüyor.

Hem SENTİNEL-2’de hem de LANDSAT-9’da gerçek zemin ile karşılaştırıldığında en yüksek sonucu nesne tabanlı sınıflandırmanın algoritması olan SVM vermiştir. SENTİNEL-2’de gerçek zemin ile karşılaştırma sonuçlarına baktığımızda piksel tabanlı sınıflandırma algoritması olan ANN en yüksek ikinci sonucu vermiştir. LANDSAT-9 ile gerçek zemin karşılaştırma sonuçlarına baktığımızda piksel tabanlı sınıflandırma algoritması olan SVM en yüksek ikinci sonucu vermiştir. Bu yüzden SENTİNEL-2’de nesne tabanlı sınıflandırma algoritması olan SVM ile piksel tabanlı sınıflandırma algoritması olan ANN karşılaştırılabilir. LANDSAT-9’da ise nesne tabanlı sınıflandırma

algoritması olan SVM ile piksel tabanlı sınıflandırma algoritması olan SVM karşılaştırılabilir. Buna rağmen piksel tabanlı sınıflandırma algoritmaları genel doğrulukta bir avantaj sağlamaz. SENTİNEL-2’de eğitim örneği boyutu ne olursa olsun nesne tabanlı sınıflandırma algoritması olan SVM ve piksel tabanlı sınıflandırma algoritması olan ANN diğer sınıflandırıcılardan daha yüksek doğruluk verdiği bulundu. LANDSAT-9’da ise eğitim örneği boyutu ne olursa olsun nesne tabanlı sınıflandırma algoritması olan SVM ve piksel tabanlı sınıflandırma algoritması olan SVM diğer sınıflandırıcılardan daha yüksek doğruluk verdiği bulundu.

Sonuç olarak hem küçük örnek boyutunda hem büyük örnek boyutunda nesne tabanlı sınıflandırma algoritması olan SVM en doğru seçim olmaktadır. SENTİNEL-2’de piksel tabanlı sınıflandırma algoritması olan ANN ve nesne tabanlı sınıflandırma algoritması olan SVM küçük örnek boyutunda daha düşük doğruluk oranı verse de büyük örnek boyutunda verdiği doğruluk oranı artmaya devam etti. LANDSAT-9’da piksel tabanlı sınıflandırma algoritması olan SVM ve nesne tabanlı sınıflandırma algoritması olan SVM büyük örnek boyutunda verdiği doğruluk oranına kıyasla küçük örnek boyutunda daha düşük doğruluk oranı verdi ve büyük örnek boyutunda verdiği doğruluk oranı artmaya devam etti. Yani eğer imkan varsa araştırmanın büyük örnek boyutunda yapılması tavsiye edilir. Ancak ANN büyük örnek boyutunda kullanıldığı zaman sınıflandırma süresi daha uzun sürecektir. SENTİNEL-2’de ve LANDSAT-9’da piksel tabanlı sınıflandırma algoritmaları olan MLC ve MDC örnek boyutu arttıkça piksel tabanlı sınıflandırma algoritmaları olan SVM, ANN ve nesne tabanlı sınıflandırma algoritması olan SVM’den daha düşük genel doğruluk oranı sağladı. Her ne kadar tüm sınıflandırma türlerinde örnek boyutu arttıkça genel doğruluk oranı artsa da en yüksek genel doğruluk oranını nesne tabanlı sınıflandırma algoritması olan SVM verdi. SENTİNEL-2’de ve LANDSAT-9’da MDC genel olarak en düşük genel doğruluk oranını veren sınıflandırıcıydı ve örnek boyutu arttığında bile verdiği genel doğruluk oranı diğer sınıflandırma türlerinden çok farklıydı. SENTİNEL-2’nin 10 metre çözünürlüğü ile verdiği sonuç, LANDSAT-9’un pan-sharpening yaparak 15 metre çözünürlüğü ile verdiği sonuçtan daha iyi bir sonuç vermiştir.

6. ÖNERİLER

Bu çalışmanın bulgularına dayanarak aşağıdaki öneriler geliştirilmiştir:

- Uzaktan algılanan veri kümesinin sınıflandırılması için en doğru sonuçlar, nesne tabanlı sınıflandırma algoritması olan SVM tarafından sağlanmıştır. Bu nedenle, veri sınıflandırma çalışmalarında öncelikli olarak nesne tabanlı algoritmaların tercih edilmesi önerilmektedir.
- Piksel tabanlı sınıflandırma algoritmalarında ise ANN, özellikle SENTINEL-2 verileri için dikkate alınabilir bir alternatif olarak değerlendirilebilir.
- Büyük eğitim örnek setlerinin, doğruluk oranlarını artırdığı göz önüne alındığında, sınıflandırma projelerinde mümkün olduğunca büyük örnek boyutlarının kullanılması önerilir.
- Ancak büyük eğitim setleri kullanımı daha uzun işlem sürelerine yol açabileceğinden, projelerin zaman ve işlem kapasitesine göre planlanması önemlidir.
- SENTINEL-2'nin 10 metre çözünürlüğü, LANDSAT-9'un 15 metre pansharpening sonrası çözünürlüğüne kıyasla daha yüksek doğruluk sağlamıştır. Yüksek çözünürlüklü sonuçlar gerektiren çalışmalar için SENTINEL-2 verilerinin kullanılması tavsiye edilir.
- Nesne tabanlı sınıflandırma algoritmaları genel olarak piksel tabanlı sınıflandırma algoritmalarından daha iyi sonuçlar vermektedir. Ancak, belirli durumlarda piksel tabanlı algoritmalar (ör. ANN), belirli veri setlerinde alternatif olarak değerlendirilebilir.
- MDC ve MLC gibi daha düşük doğruluk oranı sağlayan sınıflandırıcıların yalnızca kaynak kısıtlamaları nedeniyle veya başka algoritmaların uygun olmadığı durumlarda kullanılması önerilir.
- Eğitim örneği boyutundaki artış, genel doğruluk oranlarını artırsa da düşük çözünürlüklü uydu verilerinde bu artış sınırlı kalabilir. Bu nedenle çözünürlük ile örnek boyutu arasındaki denge dikkate alınmalıdır.
- Hem piksel hem de nesne tabanlı sınıflandırma yöntemlerinin uygulanması mümkünse, en yüksek doğruluk oranına ulaşmak için algoritmaların karşılaştırılması yapılmalıdır.

7. KAYNAKLAR

- Akosman, E. N., & Makineci, H. B. (2023). Sentinel-2A Verileriyle Trabzon İli 2019-2020 Yılları Arasında Ortaya Çıkan Sınıflandırma Farklarının Çeşitli Algoritmalarla Değerlendirilmesi. *Türkiye Uzaktan Algılama Dergisi*, 5(2), 78-88.
- Anwer, R. M., Khan, F. S., Van De Weijer, J., Molinier, M., & Laaksonen, J. (2018). Binary patterns encoded convolutional neural networks for texture recognition and remote sensing scene classification. *ISPRS journal of photogrammetry and remote sensing*, 138, 74-85.
- Arıkan, D., & Yıldız, F. (2023). Sentinel-2 Uydu Görüntülerinde Destek Vektör Makinesi ve Rastgele Orman Algoritmaları Kullanılarak Piksel Tabanlı Arazi Sınıflandırması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(2), 1243-1260.
- Aydemir, A. (2018). Sulama Sonrası Harran Ovası Tarımsal Arazilerdeki Yapılaşmanın Piksel Tabanlı / Nesne Tabanlı Sınıflandırma Yöntemleri İle Belirlenmesi Ve İki Yöntemin Karşılaştırılması, Yüksek Lisans Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü.
- Beste Tavus (2017) Tarımsal Alanlarda İkonos Uydu Görüntüsünden Nesne Tabanlı Ürün Deseni Tespiti, Yüksek Lisans Tezi, Aksaray Üniversitesi Fen Bilimleri Enstitüsü.
- Bilgili A.V., Akıl, R., Aydemir, A., Çullu, M.A., H. M. & Van Es. (2006). The Prediction And Extraction Of Hill Slope Flow Path's And Ephemeral Gullies In A Digitised Harran Watershed. pp.171-173.
- Blaschke, T., & Geoffrey, J. H. (2011). Qihao Weng ve Bernd Resch, Collective Sensing: Integrating Geospatial Technologies to Understand Urban Systems-An Overview, *Remote Sensing*, 2011, 3, 1743-1776.
- Bo, S., & Han, X. (2010). Parameter Selection for Segmentation in Object-Oriented Classification of Remotely Sensed Imagery, *International Conference on Intelligent Computation Technology and Automation*, pp.876-879.
- Boyacı, D. (2012). Cbs-Uzaktan Algılama entegrasyonu ve örnek uygulama: uydu görüntülerinden detay ve otomatik öznitelik tespiti, Doktora Tezi, Selçuk Üniversitesi Harita Mühendisliği Anabilim Dalı, Konya.
- Brownlee, J. (2020). Learning Vector Quantization for Machine Learning. Available online: (accessed on 11 November 2020).
- Carleer, A. P. & Wolff, E. (2006). Region-Based classification potential for landcover classification with very high spatial resolution satellite data, in *Proceedings of 1st International Conference on Object-based Image Analysis*, Austria, Vol. XXXVI, ISSN 1682 1777, 4-5.

- Chanussot, J., Benediktsson, J. A., & Fauvel, M. (2006). Classification of remote sensing images from urban areas using a fuzzy possibilistic model. *IEEE Geoscience and Remote Sensing Letters*, 3(1), 40-44.
- Delen, A., & Şanlı, F.B. (2017). Pamuk Ekili Alanların Nesne Tabanlı Sınıflandırma Yöntemi İle Belirlenmesi: Menemen Örneği. *Journal of New Results in Engineering and Natural Science*, 6:1-8.
- Doğan, Y. (2019). İnsansız Hava Araçları Kullanılarak Multi-Spektral Kameralar İle Bitki Örtüsü Türlerinin Ayırt Edilmesi Ve Sınıflandırılması, Yüksek Lisans Tezi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Drăgut, L., Csillik, O., Eisank, C., & Tiede, D. (2014). Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS J. Photogram. Remote Sens.* 88, 119–127.
- Kalem, E. (2014). Piksel ve Nesne Tabanlı Sınıflandırma Açısından Göktürk 2 Görüntüsünün Değerlendirilmesi: İstanbul Boğazi Örneği, Yüksek Lisans Tezi, Hava Harp Okulu Havacılık Ve Uzak Teknolojileri Enstitüsü.
- Franklin, S. E., Wulder, M. A., & Lavigne, M. B. (1996). Automated derivation of geographic window sizes for use in remote sensing digital image texture analysis. *Computers & Geosciences*, 22(6), 665-673.
- Gaetano, R., Scarpa, G., & Poggi, G. (2009). Hierarchical texture-based segmentation of multiresolution remote-sensing images. *IEEE Transactions on geoscience and remote sensing*, 47(7), 2129-2141.
- Golhani, K. Balasundram, S.K. Vadmalai, G., & (2018). Pradhan, B. A review of neural networks in plant disease detection using hyperspectral data. *Inf. Process. Agric.* 5, 354–371.
- Gupta N., & H.S. Bhaduria,(2014). “Object Based Information Extraction from High Resolution Satellite Imagery using eCognition”, *International Journal of Computer sciences Issues*, 11(3), 139-144.
- Gülersoy, A. E. (2013). Farklı Uzaktan Algılama Teknikleri Kullanılarak Arazi Örtüsü/Kullanımında Meydana Gelen Değişimlerin İncelenmesi: Manisa Merkez İlçesi Örneği (1986-2010). *Electronic Turkish Studies*, 8(8).
- İentürk, Ü. G. (2020). Uzaktan Algılama Teknikleri Kullanılarak Kayısı Bahçelerinin Tespiti Ve Rekolte Tahmini; Malatya Battalgazi Örneği (Master’s thesis, Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü).
- Jain, D., Dubey, S., Choubey, R., Sinhal, A., Arjaria, S., Jain, A., & Wang, H. (2017). An approach For Hyperspectral Image Classification By Optimizing SVM Using Self Organizing. *Journal of Computational Science*, 1-8.
- Kalkan, K. & Maktav, D. (2010). Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği). III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu Ocak 2010.

- Kara, F., & Karatepe, A. (2012). Uzaktan Algılama Teknolojileri ile Beykoz İlçesi (1986-2011) Arazi Kullanımı Değişim Analizi. *Marmara Coğrafya Dergisi*, (25), 378-389.
- Karatzoglou, A. Meyer, D. & Hornik, K., (2006) Support Vector Machines in R. *J. Stat. Softw.* 2006, 15, 1–28.
- Kavzoglu, T., & Yıldız, M. (2015). Segmentasyonda Optimum Ölçek Parametresi Tespitinde Konumsal Otokorelasyon ve Varyansın Etkisinin Analizi, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) VIII. Teknik Sempozyumu, 21-23 Mayıs 2015, Selçuk Üniversitesi – Konya
- Kazu, İ. Y., & Özdemir, O. (2009). Öğrencilerin bireysel özelliklerinin yapay zeka ile belirlenmesi (Bulanık mantık örneği). *Akademik Bilişim*, 11, 13.
- Khatami, R. Mountrakis, G. & Stehman, S.V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sens. Environ.* 177, 89–100.
- Li, C., & Shao, G. (2012). International Journal of Remote Object-oriented classification of land use / cover using digital aerial orthophotography, *International Journal of Remote Sensing*, 33(4), pp.922-938.
- Lillesand, T., Kiefer, R. & Chipman, J., 2007. Remote sensing and image interpretation, Sixth Edition, John Wiley Sons, New York, USA
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). Remote sensing and image interpretation. John Wiley & Sons.
- Ma L., cheng L., Li m., liu Y., & Ma X. (2015). Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 102 pp.14-27.
- Marangoz, A.M., Karakıl, S., Oruç, M., & Büyüksalih, G., (2005). Nesne-Tabanlı Görüntü Analizi Ve İkonos Pan-Sharpned Görüntüsünü Kullanarak Yol ve Binaların Çıkarımı. Sunar Tmmob Harita Ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel Ve Teknik Kurultayı 28 Mart - 1 Nisan 2005, Ankara.
- Mountrakis, G.; Im, J.; & Ogole, C. (2010). Support Vector machines in remote sensing: A review. *ISPRS J. Photogram. Remote Sens.* 66, 247–259.
- Musaoğlu, N., 1999. Elektro-Optik ve aktif mikrodalga algılayıcılarından elde edilen uydu verilerinden orman alanlarına ait meşcere tiplerinin ve yetiştirme ortamı birimlerinin belirlenme olanakları, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., & Weng, Q. H. (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), pp. 1145-1161.

- Ozulu, İ. M. (2005). Uzaktan algılama ve coğrafi bilgi sistemleri yöntemlerinin arkeolojiye uygulanması (Master's thesis, Anadolu University (Turkey)).
- Öğüt, K. (2003). İçsel (Endojen) Büyüme Kuramı Çerçevesinde Azgelişmiş Ülkelerin Küresel Sisteme Entegrasyonu Ve Büyüme. *Aydınlanma* 1923, 44(44), 37-46.
- Özdemir, M. (2013). Uydu görüntülerinden nesne yönelimli yöntemlerle özellik çıkarımı. Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Petropoulos, G., Kalaitzidis, C., & Vadev, K., (2012). Support Vector Machines And Object-based Classification For Obtaining Land-use/Cover Cartography From Hyperion Hyperspectral Imagery. *Computers & Geosciences*, 99–107.
- Qian, Y. Zhou, W. Yan, J. Li, W. & Han, L. (2015). Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. *Remote Sens.*, 7, 153–168.
- Ramezan, C.A., Warner, T.A., & Maxwell, A.E. (2019). Evaluation of Sampling and Cross-Validation Tuning Strategies for Regional-Scale Machine Learning Classification. *Remote Sens.* 11, 185.
- Richards, J. A., & Richards, J. A. (2022). Remote sensing digital image analysis (Vol. 5). Berlin/Heidelberg, Germany: springer.
- Ripley, B. (2016). Venables, W. Feed-Forward Neural Networks and Multinomial Log-Linear Models. R Package Version 7.3-12.
- Serdar Bayburt (2009). Uydu Görüntülerinin Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması (Doğu Trakya Bölgesi Örneği), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Seyrek, E. C., & Uysal, M. (2022). Farklı Platformlardan Elde Edilen Hiperspektral Görüntülerin Sınıflandırılmasında Evrilimli Sinir Ağları, Destek Vektör Makineleri ve Rastgele Orman Algoritmalarının Performanslarının Karşılaştırılması. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 22(6), 1368-1379.
- Shahtahmassebi, A., Yang, N., Wang, K., Moore, N., & Shen, Z. (2013). Review of shadow detection and de-shadowing methods in remote sensing. *Chinese geographical science*, 23, 403-420.
- Shang, M. Wang, S. Zhou, Y., & Du, C. (2018). Effects of Training Samples and Classifiers on Classification of Landsat-8 Imagery. *J. Indian Soc. Remote Sens.* 46, 1333–1340.
- Sharma, A., Liu, X., Yang, X., Shi, D. (2017). A patch-Based Convolutional Neural Network For Remote Sensing Image Classification. *Neural Networks*, 19 28.
- Sharma, V. Baruah, D. Chutia, D. & Raju, P. (2016) Bhattacharya, D.K. An assessment of support vector machine kernel parameters using remotely sensed satellite data. In *Proceedings of the IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, Bangalore, India, 20–21.

- Singh, A., & Singh, K. (2017). Satellite Image Classification Using Genetic Algorithm Trained Radial Basis Function Neural Network, Application To The Detection of Flooded Areas. *J. Vis. Commun. Image*, 173–182.
- Stehman, S.V. (2009). Foody, G.M. Accuracy assessment. In *The SAGE Handbook of Remote Sensing*; Warner, T.A., Nellis, M.D., Foody, G.M., Eds.; Sage Publications Ltd.: London, UK, pp. 129–145. ISBN 9781412936163.
- Sun, S., Dustdar, S., Ranjan, R., Morgan, G., Dong, Y., & Wang, L. (2022). Remote sensing image interpretation with semantic graph-based methods: A survey. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 4544-4558.
- Sunar, F., Özkan, C., & Osmanoğlu, B. (2011). *Uzaktan Algılama*, Eskişehir, Anadolu Üniversitesi Yayınları.
- Tavus, B. (2017). Tarımsal alanlarda IKONOS uydu görüntüsünden nesne tabanlı ürün deseni tespiti (Master's thesis, Aksaray Üniversitesi Fen Bilimleri Enstitüsü).
- Tunay, M., & Ateloğlu, A. (2009). Bartın İli Taşkın Sahalarındaki Değişimin Uzaktan Algılama Verileriyle İncelenmesi. *Turkish Journal of Forestry*, 5(2), 60-72.
- Üstüner, M. (2023). Çekirdek Tabanlı Aİrı Öğrenme Makinesi ile Hiperspektral Görüntü Sınıflandırma. *Turkish Journal of Remote Sensing and GIS*, 4(2), 198-212.
- Yener, H., Ayhan, K. O. Ç., & Çoban, O. (2006). Uzaktan Algılama Verileri Ve Teknik Özellikleri. *Journal of the Faculty of Forestry Istanbul University*, 56(1), 33-48.
- Yiğit, A. Y., & Uysal, M. (2019). Nesne Tabanlı Sınıflandırma Yaklaşımı Kullanılarak Yolların Tespiti. *Türkiye Fotogrametri Dergisi*, 1(1), 17-24.
- Tonbul, H., & Kavzoğlu, T. (2017). Nesne-Tabanlı Sınıflandırmada Segmentasyon (Bölütleme) Kalitesinin Sınıflandırma Doğruluğu Üzerine Etkisinin İncelenmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 118-125.

ÖZGEÇMİŞ

Ahmed isam HUSSEIN, ilk, orta ve lise öğrenimini kerkük’de tamamladı. 2015 yılında Kerkük Teknik Enstitüsü, Harita Bölümünü kazandı. 2017 yılında Harita Bölümündeki lisans eğitimini yüksek onur öğrencisi olarak bölüm beşinciliği ile tamamladı. 2018 yılında Kerkük teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümünü kazandı. 2022 yılında Harita Mühendisliği Bölümündeki lisans eğitimini yüksek onur öğrencisi olarak bölümü tamamladı.

Aynı yıl Türkiye burslusu olarak Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında yüksek lisans eğitimine başladı. Aynı zamanda beşçeşit Arapça,Turkmence ve orta düzeyde İngilizce, farsça bilmektedir.