



**PRISMA VERİLERİ KULLANILARAK MÜSİLAJ
TESPİTİ İÇİN TEMSİLE DAYALI
SINIFLANDIRMA YÖNTEMLERİNİN
KARŞILAŞTIRMALI ANALİZİ**

Uğur Gökhan BOZO

**Yüksek Lisans Tezi
Elektrik Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Sefa KÜÇÜK

**2025
Her hakkı saklıdır.**



**FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ**

**PRISMA VERİLERİ KULLANILARAK MÜSİLAJ TESPİTİ İÇİN
TEMSİLE DAYALI SINIFLANDIRMA YÖNTEMLERİNİN
KARŞILAŞTIRMALI ANALİZİ**

Uğur Gökhan BOZO

Tez Danışmanı: Dr. Öğr. Üyesi Sefa KÜÇÜK

Anabilim Dalı: Elektrik Elektronik Mühendisliği

Erzurum

2025

Her hakkı saklıdır

T.C.
ERZURUM TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ ONAY FORMU

**PRISMA VERİLERİ KULLANILARAK MÜSİLAJ TESPİTİ İÇİN TEMSİLE
DAYALI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRMALI
ANALİZİ**

Dr. Öğr. Üyesi Sefa KÜÇÜK danışmanlığında, Uğur Gökhan BOZO tarafından hazırlanan bu çalışma 18 / 08 / 2025 tarihinde aşağıdaki jüri tarafından Elektrik Elektronik Mühendisliği Ana Bilim Dalı'nda Yüksek Lisans tezi olarak **Oy birliği ile (3/3)** kabul edilmiştir.

Başkan	: Prof. Dr. Nur Hüseyin KAPLAN	İmza	:
Üye	: Dr. Öğr. Üyesi Sefa KÜÇÜK	İmza	:
Üye	: Dr. Öğr. Üyesi Onur Erdem KORKMAZ	İmza	:

Yukarıdaki sonucu onaylıyorum

Doç. Dr. Bünyamin ÖZGERİŞ
Enstitü Müdürü

*Bu tez çalışması tarafından nolu proje ile desteklenmiştir.

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

18 / 08 / 2025

İmzası

Uğur Gökhan BOZO

ÖZET

YÜKSEK LİSANS TEZİ

PRISMA VERİLERİ KULLANILARAK MÜSİLAJ TESPİTİ İÇİN TEMSİLE DAYALI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRMALI ANALİZİ

Uğur Gökhan BOZO

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Sefa KÜÇÜK

Bu tez çalışmasında, Marmara Denizi'nde meydana gelen müsilaaj oluşumlarının uzaktan algılama yoluyla tespiti amacıyla, hiperspektral uydu verileri üzerinde temsile dayalı sınıflandırma yöntemleri incelenmiştir. Bu kapsamda, İtalyan Uzay Ajansı (ASI) tarafından geliştirilen PRISMA uydusundan, İstanbul ve Bursa kıyılarında kaydedilmiş hiperspektral görüntüler kullanılmıştır. Yüksek spektral çözünürlüğe sahip bu veriler, müsilaajın spektral olarak su yüzeylerinden ayırt edilmesine olanak sağlamaktadır. Sınıflandırma aşamasında, spektral, uzamsal ve spektral-uzamsal bilgileri birlikte kullanabilen temsile dayalı, işbirlikçi temsile dayalı ve altuzay tabanlı sınıflandırma yöntemleri karşılaştırmalı olarak incelenmiştir. Yöntemlerin performansları, genel doğruluk, ortalama doğruluk ve F-skoru gibi metriklerle değerlendirilmiş, ayrıca elde edilen sınıflandırma haritaları görsel olarak da analiz edilmiştir. Deneysel bulgular, özellikle NSC tabanlı ve çok ölçekli süperpiksel segmentasyonu kullanan yöntemlerin hem genel doğruluk hem de sınıflar arası denge açısından üstün performans sergilediğini göstermektedir. Gerçek uydu verileri üzerinde elde edilen bu sonuçlar, yalnızca literatürde yaygın olarak kullanılan standart veri kümelerinin ötesine geçmekle kalmamış, aynı zamanda yöntemlerin gerçek saha koşullarındaki uygulanabilirliğini de güçlü bir şekilde ortaya koymuştur.

2025, 64 sayfa

Anahtar Kelimeler: Hiperspektral Görüntüleme, Müsilaaj, PRISMA, Sınıflandırma, Temsile Dayalı Yöntemler, Uzaktan Algılama

ABSTRACT

MS. Thesis

COMPARATIVE ANALYSIS OF REPRESENTATION-BASED CLASSIFICATION METHODS FOR DETECTING MUCILAGE USING PRISMA DATA

Uğur Gökhan BOZO

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Electrical Electronic Engineering

Supervisor: Assist. Prof. Dr. Sefa KÜÇÜK

In this thesis, representation-based classification methods were investigated on hyperspectral satellite data to detect mucilage formations in the Sea of Marmara through remote sensing. For this purpose, hyperspectral images acquired by the PRISMA satellite, developed by the Italian Space Agency (ASI), from the coastal regions of Istanbul and Bursa were used. These high spectral resolution data enable spectral differentiation of mucilage from water surfaces. During the classification stage, representation-based, collaborative representation-based, and subspace-based classification methods that can use spectral, spatial, and spectral-spatial information together were analyzed comparatively. The performance of the methods was evaluated using metrics such as overall accuracy, average accuracy, and F-score, and the resulting classification maps were also analyzed visually. Experimental findings demonstrate that methods based on NSC and multi-scale super-pixel segmentation exhibit superior performance in terms of overall accuracy and class balance. The results obtained from real satellite data not only go beyond the standard data sets commonly used in the literature, but also strongly demonstrate the applicability of these methods in real-world problems.

2025, 64 page

Keywords: Hyperspectral Imaging, Mucilage, PRISMA, Classification, Representation-Based Methods, Remote Sensing

TEŞEKKÜR

Yüksek lisans eğitimim süresince bilgi, destek ve yönlendirmeleriyle gelişimime katkıda bulunan başta tez danışmanım Dr. Öğr. Üyesi Sefa KÜÇÜK'e en içten teşekkürlerimi sunarım. Kendisi, bu çalışmanın her aşamasında akademik bilgisi ve sabrıyla bana yol göstermiş, değerli önerileriyle araştırmamın şekillenmesine önemli katkı sağlamıştır. Tez çalışmam sırasında motivasyon ve desteğini hiçbir zaman esirgemeyen sevgili eşime sabırla destek verdiği için minnettarım. Son olarak, bu süreçte yanımda olan aile fertlerime, bilgi alışverişinde bulunduğum tüm arkadaşlarıma ve emeği geçen herkese teşekkür ederim.

Uğur Gökhan BOZO
Ağustos, 2025

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR	v
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
1.1. Müsilaj	1
1.2. Uzaktan Algılama.....	3
1.3. Hiperspektral Görüntü.....	4
1.4. Görüntü Tabanlı Sınıflandırma	10
1.5. Tezin Amacı ve Kapsamı	11
2. KAYNAK ÖZETLERİ	12
3. TEMSİLE DAYALI SINIFLANDIRMA YAKLAŞIMLARI	18
3.1. Seyrek Temsile Dayalı Sınıflandırma (SRC).....	18
3.2. İşbirlikçi Temsile Dayalı Sınıflandırma (CRC)	21
3.3. Altuzay Tabanlı Temsil Yaklaşımı: En Yakın Altuzay Sınıflandırıcısı (NSC)	24
4. VERİ KAYNAKLARI ve DEĞERLENDİRME KRİTERLERİ	30
4.1. PRISMA.....	30
4.2. Kullanılan Müsilaj Veri Kümeleri	31
4.3. Performans Ölçütleri	31
5. ARAŞTIRMA BULGULARI ve TARTIŞMA	37
5.1. SRC’ler ile Elde Edilen Bulgular	38
5.2. CRC’ler ile Elde Edilen Bulgular	42
5.3. NSC’ler ile Elde Edilen Bulgular.....	44
5.4. Bulguların Karşılaştırmalı Değerlendirmesi	51
6. SONUÇ ve ÖNERİLER	56
KAYNAKLAR	58

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
$\ \cdot\ _F$	Vektörün Frobenius formu
$\ \cdot\ _0$	Vektörün l_0 normu
$\ \cdot\ _1$	Vektörün l_1 normu
$\ \cdot\ _2$	Vektörün l_2 normu
$(\cdot)^T$	Matrisin devrik hali
$(\cdot)^{-1}$	Matrisin ters hali
N	Toplam eğitim örnek sayısı
T	Pencere boyutu
x_{ij}	i . sınıfa ait j . eğitim verisi
X_i	i . sınıfa ait eğitim verisinin tamamı
y	Test verisi
Y	Sınıflandırmada uzamsal bilgiden yararlanmak için kullanılan piksel kümesi
λ	Temsile dayalı çözümün kararlılığını ve genellenebilirliğini dengeleyen parametre
λ	Bant sayısı
cx	Birinci seyreklik parametresi
cy	İkinci seyreklik parametresi
$\forall$	Evrensel niceleyici
C	Bant sayısı
ℓ_i	i . norm

Kısaltmalar

AA	Average Accuracy (Ortalama Doğruluk)
AFAI	Algal Filamentous Algae Index
CCA	Canoic Correlation Analysis (Kanonik Korelasyon Analizi)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağı)
CRC	Collaborative Representation-based Classification (İşbirlikçi Temsile Dayalı Sınıflandırma)
DESI	DLR Earth Sensing Imaging Spectrometer (DLR Dünya Algılama Görüntüleme Spektrometresi)
ELMM	Enhanced Large Language Model (Geliştirilmiş Büyük Dil Modeli)
FFNN	Feedforward Neural Network (İleri Beslemeli Yapay Sinir Ağı)
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
FNR	False Negative Rate (Yanlış Negatif Oranı)
FPR	False Positive Rate (Yanlış Pozitif Oranı)
GradCAM	Gradient-weighted Class Activation Mapping (Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama)
GF	Guided Filter (Kılavuzlu Filtre)
GT	Ground Truth (Temel Doğru)
HSI	Hyperspectral Imaging (Hiperspektral Görüntüleme)
İHA	İnsansız Hava Aracı
JNSC	Joint Nearest Subspace Classifier (Birleşik En Yakın Altuzay Sınıflandırıcısı)
JSRC	Joint Sparse Representation-based Classification (Ortak Seyrek Temsile Dayalı Sınıflandırma)
k-NN	k En Yakın Komşuluk
LDA	Linear Discriminant Analysis (Doğrusal Ayırtman Analizi)
LLM	Large Language Model (Büyük Dil Modeli)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
m	Metre

MI	Musilage Index (Müsilaj İndeksi)
MODIS	Moderate Resolution Imaging Spectroradiometer (Orta Çözünürlüklü Görüntüleme Spektoradyometresi)
MSBNSC	Multi-Scale Based Nearest Subspace Classifier (Çok Ölçekli Tabanlı En Yakın Altuzay Sınıflandırıcısı)
MSI	Multispectral Imaging
MSS	Multi-Scale Superpixel (Çok Ölçekli Süperpiksel)
NIR	Near Infrared
nm	Nanometre
NOAA	National Oceanic and Atmospheric Administration (Ulusal Okyanus ve Atmosfer İdaresi)
NSC	Nearest Subspace Classifier (En Yakın Altuzay Sınıflandırıcısı)
OA	Overall Accuracy (Genel Doğruluk)
OLCI	Ocean and Land Colour Instrument (Okyanus ve Kara Renk Sensörü)
OISST	Optimum Interpolation Sea Surface Temperature (Optimum Enterpolasyon Deniz Yüzeyi Sıcaklığı)
PCA	Principal Component Analysis (Temel Bileşen Analizi)
PHSI	Palmer Hydrological Drought Severity Index (Palmer Hidrolojik Kuraklık Şiddet İndeksi)
PRISMA	PRecursore IperSpettrale della Missione Applicativa (Uygulama Misyonu Hiperspektral Öncelcisi — İtalyan Uzay Ajansı'na ait hiperspektral uydu sistemi)
RCR	Regularized Collaborative Representation (Düzenlileştirilmiş İşbirlikçi Temsil)
RGB	Red Green Blue (Kırmızı Yeşil Mavi)
RJNSC	Robust Joint Nearest Subspace Classifier (Sağlam Birleşik En Yakın Altuzay Sınıflandırıcısı)
RPNet	Random Patches Network
SCCA	Sparse Canonical Correlation Analysis (Seyrek Kanonik Korelasyon Analizi)
SKCR	Structural-Kernel Collaborative Representation (Yapısal-Çekirdekli İşbirlikçi Temsil)
SRC	Sparse Representation-based Classification (Seyrek Temsile Dayalı

	Sınıflandırma)
SST	Sea Surface Temperature (Deniz Yüzeyi Sıcaklığı)
SVM	Support Vector Machine (Destek Vektör Makineleri)
SWIR	Short Wave Infrared (Kısa Dalga Kızılötesi)
SWOT	Surface Water and Ocean Topography (Yüzey Suyu ve Okyanus Topografyası)
TN	True Negative (Doğru Negatif)
TNR	True Negative Rate (Doğru Negatif Oranı)
TP	True Positive (Doğru Pozitif)
TPR	True Positive Rate (Doğru Pozitif Oranı)
UA	Uzaktan Algılama
U-NET	U-shaped Convolutional Network (U-şekilli Evrişimsel Ağ)
USGS	United States Geological Survey
VIS	Visible Spectrum
WBNSC	Window-Based Nearest Subspace Classifier (Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı)
YOLOv5	You Only Look Once version 5 (Nesne Tespit Algoritması)

ŞEKİLLER DİZİNİ

Şekil 1.1. Marmara Denizi kıyılarında birikinti yapan müsilağ.....	2
Şekil 1.2. Uzaktan algılama sensörlerinin çalışma prensibine ilişkin bir görsel	4
Şekil 1.3. Hiperspektral elektromanyetik spektrum.....	5
Şekil 1.4. RGB ve Hiperspektral görüntülerin farkı	5
Şekil 1.5. RGB ve HS görüntü boyut karşılaştırması	6
Şekil 1.6. Multispektral ve Hiperspektral görüntüler arasında fark.....	7
Şekil 1.7. Temsili Spektrumlar	9
Şekil 3.1. SRC yöntemi problem şeması	20
Şekil 3.2. CRC yöntemi problem şeması	23
Şekil 3.3. NSC yöntemi problem şeması	25
Şekil 4.1. PRISMA uydusu.....	30
Şekil 4.2. Marmara Denizi'nde çalışma yapılan alanlar	31
Şekil 4.3 İstanbul açıklarındaki müsilağ oluşumu	32
Şekil 4.4 Bursa açıklarındaki müsilağ oluşumu.....	32
Şekil 5.1 SRC deneylerinde örnek oranı değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.....	38
Şekil 5.2 SRC deneylerinde örnek oranı değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.....	39
Şekil 5.3. MSS-GF deneylerinde süperpiksel boyut (patches) değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi	40
Şekil 5.4. MSS-MV deneylerinde süperpiksel boyut (patches) değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi	41
Şekil 5.5. MSS-GF deneylerinde süperpiksel boyut (patches) değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi	41
Şekil 5.6. MSS-MV deneylerinde süperpiksel boyut (patches) değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi	42
Şekil 5.7 CRC deneylerinde Lambda değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.....	43
Şekil 5.8. CRC deneylerinde Lambda değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.....	43

Şekil 5.9. Pencere boyutunda yapılan değişimlere göre Bursa veri kümesinde JNSC sınıflandırma başarımları	44
Şekil 5.10. Pencere boyutunda yapılan değişimlere göre İstanbul veri kümesinde JNSC sınıflandırma başarımları	45
Şekil 5.11. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde RJNSC sınıflandırma başarımları	46
Şekil 5.12. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde RJNSC sınıflandırma başarımları.....	46
Şekil 5.13. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde MSBNSC sınıflandırma başarımları	48
Şekil 5.14. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde MSBNSC sınıflandırma başarımları	48
Şekil 5.15. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde WBNSC sınıflandırma başarımları	49
Şekil 5.16. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde WBNSC sınıflandırma başarımları	49
Şekil 5.17. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde SCCA sınıflandırma başarımları	50
Şekil 5.18. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde SCCA sınıflandırma başarımları	54
Şekil 5.19. SRC yönteminde elde edilen sınıflandırma haritaları.....	54
Şekil 5.20. SRC yönteminde elde edilen sınıflandırma haritaları.....	55
Şekil 5.21. MSS-GF ve MSS-MV yöntemlerinde elde edilen sınıflandırma haritaları ..	55
Şekil 5.22. CRC yönteminde elde edilen sınıflandırma haritaları	55
Şekil 5.23. SCCA yönteminde elde edilen sınıflandırma haritaları.....	55
Şekil 5.24. JNSC yönteminde elde edilen sınıflandırma haritaları.....	55
Şekil 5.25. RJNSC yönteminde elde edilen sınıflandırma haritaları	56
Şekil 5.26. WBNSC yönteminde elde edilen sınıflandırma haritaları	56
Şekil 5.27. MSBNSC yönteminde elde edilen sınıflandırma haritaları	56

ÇİZELGELER DİZİNİ

Çizelge 1.1. Üç görüntüleme türünün özelliklerinin karşılaştırması.....	8
Çizelge 3.1. En Yakın Alt Uzay Sınıflandırıcılarının parametrelere göre yaklaşımları..	29
Çizelge 5.1. İstanbul veri kümesi için sonuçların karşılaştırmalı tablosu.....	52
Çizelge 5.2. Bursa veri kümesi için sonuçların karşılaştırmalı tablosu	52



1. GİRİŞ

Son yıllarda, küresel iklim değişikliğinin sebep olduğu önemli problemlerden birisi olan deniz suyundaki sıcaklık artışı dünya genelinde kapalı veya yarı kapalı havzalara sahip olan denizlerde olduğu gibi Marmara Denizi'nde de sorunların belirmesine yol açmıştır. Bu problemlerin başında ise müsilaj yani deniz salyası oluşumları gelmektedir. Müsilaj hidrolojik açıdan durağan olan ve zayıf akıntı durumuna sahip kirlilik oranı fazla olan iç denizlerde daha fazla ortaya çıkmaktadır (Koncağül vd 2022). Marmara Denizi de coğrafi konumu, su yenilenme kapasitesinin düşük oluşu ve yüksek antropojenik baskı olması sebebi ile müsilajın en şiddetli yaşandığı alanlardan biridir.

Bu bağlamda, müsilajın erken tespiti ve devamında da izlenmesi büyük önem taşımaktadır. Geleneksel izleme yöntemleri yetersiz kalırken, uzaktan algılama teknikleri çevresel olayların geniş alanlarda, hızlı ve etkili şekilde analiz edilebilmesine imkân tanımaktadır. Bu çalışmada, hiperspektral görüntüler ile birlikte uzaktan algılama verileri kullanılarak müsilaj tespitine yönelik yaklaşımlar incelenmiştir. Ayrıca, görüntülerin içerdiği spektral ve uzamsal bilgilerin ayırt etme gücünü anlamak için çözünürlük türleri ve spektral imza kavramları ayrıntılı olarak ele alınmıştır. Bu hedefle, çalışmanın ilk bölümünde müsilaj olgusu tanıtılmış, sonrasında kullanılan uzaktan algılama teknikleri ve görüntü türleri hakkında genel bilgiler sunulmuştur.

1.1 Müsilaj

Müsilaj, deniz ekosistemlerinde özellikle fitoplanktonların kontrolsüz çoğalması, artan deniz suyu sıcaklıkları, düşük akıntı hareketleri, organik ve inorganik besin dengesizlikleri ile mikrobiyal parçalanma süreçlerinin etkileşimi sonucunda oluşan; kıvamı yoğun, yapışkan ve jel benzeri fiziksel özelliklere sahip organik bir tabakadır. Küresel ısınmanın etkileriyle beraber artan yüzey ve dip su sıcaklıkları denizdeki ekosistemlerde biyolojik süreçleri olumsuz etkilemiştir, bu durumda fitoplankton patlamalarına yol açmıştır. Çoğunlukla evsel ve endüstriyel atıklar ve tarımsal drenajlar yoluyla azot ve fosfor gibi besin elementlerinin aşırı yüklenmesi su kolonunda eutrofikasyon sürecini hızlandırmaktadır. Bu durumda da plankton organizmalarının aşırı çoğalması ve ölümlerine bağlı olarak çözölmüş organik maddelerin Şekil 1.1'de

1. GİRİŞ

görüldüğü gibi yoğun olarak birikimleri gerçekleşmeye başlamıştır (Öztürk vd 2021). Bu organik madde birikimleri ile deniz ekosistemlerinde etkili olan çeşitli çevresel problemler belirmiştir. Problemlerden birisi olan müsilaj, özellikle Marmara Denizi'nde çok geniş alanlara yayılarak ekolojik dengeyi tehdit edecek boyutlara ulaşmıştır.



Şekil 1.1. Marmara Denizi kıyılarında birikinti yapan müsilaj (egesis.com.tr).

2021 Mayıs-Haziran döneminde Marmara Denizi'nde yaşanan ve deniz yüzeyinde büyük bir alanı kaplayan bu tabaka, suyun ışık geçirgenliğini azaltmakta, fitoplankton dışındaki canlıların fotosentetik faaliyetlerini sınırlamakta, çözünmüş oksijen seviyesinin düşmesine yol açmakta ve özellikle balıklar başta olmak üzere birçok deniz canlısı için yaşam koşullarını olumsuz hale getirmektedir. İlgili dönemde yetersiz olan atık su artırımını, durağanlaşma eğilimindeki meteorolojik şartlar ve su sıcaklıklarında gerçekleşen yükselmeler organik maddeden oluşan müsilajla kaplanan alanın daha da büyümesine sebep olmuştur (Yetilmezsoy 2021). Ayrıca, kıyı bölgelerinde biriken müsilaj kütleleri hem balıkçılık ve turizm gibi ekonomik faaliyetleri hem de insan sağlığını tehdit edebilir hâle gelmektedir. Bu nedenle müsilaj birikintileri, hem ekolojik hem de sosyoekonomik açıdan ciddi çevresel sorunlar ortaya çıkarabilmektedir.


Dolayısıyla Marmara Denizi'nde gerçekleşen ve farklı tarihlerde ortaya çıkabilen müsilaj; iklimsel şartlar, su özellikleri ve antropojenik baskıların etkileşimi sonucunda varlık kazanan çok boyutlu bir çevresel felaket olarak değerlendirilebilir (Yetilmezsoy 2021; Öztürk vd 2021; Koncagül vd 2022).

1.2 Uzaktan Algılama

Uzaktan algılama (UA), yeryüzündeki nesne ve alanlara ait olgulara dair fiziksel özelliklerin, doğrudan temas kurulmaksızın, elektromanyetik spektrumun farklı bantlarında çalışan sensörler aracılığıyla uzaktan ölçülmesi yöntemidir (Karadeniz Teknik Üniversitesi 2020, Vikipedi). Uzaktan algılama sistemleri uydular, hava araçları ve insansız hava araçları (İHA) gibi düzeneklere monte edilebilen pasif veya aktif sensörler yardımı ile; görünür, yakın ve kısa dalga kızılötesi ve mikro dalga bantları ile veriler toplar, gözlerimizin algılayamadığı spektral bölgeler hakkında bilgiler sağlar. Bu teknikler ile birlikte meteorolojik olaylar izlenebilir, orman yangınları tespit edilebilir, tarım alanlarında ürünlerin gelişimi takip edilebilir, denizlerdeki müsilaj oluşumları belirlenebilir. Kısacası pek çok çevresel ve ekonomik alanda önemli uygulamalar gerçekleştirilebilmektedir (Atay Mühendislik 2023). Bir diğer deyişle; bir alanın fiziksel özelliklerinin yansıyan veya yayılan radyasyona göre uydu veya uçaklardan ölçülmesi ve izlenmesi sürecidir (USGS t.y.). Şekil 1.2’de çalışma prensibi gösterilen uzaktan algılama, pek çok alanda kullanılmaktadır.

Hiperspektral uzaktan algılama; uzaktan algılama tekniklerinin gelişmiş bir formudur. Her piksel için elektromanyetik spektrum boyunca yüzlerce dar ve bitişik spektral bantta ölçümleri elde etme imkânı sağlar (Atay Mühendislik 2023). Yüksek spektral çözünürlük, farklı yüzey materyallerinin ve arazi örtüsü tiplerinin spektral imzalarındaki küçük farklılıkların tespit edilmesine olanak tanır. Böylece, multispektral sistemlerin algılayamayacağı ayrıntılar ortaya çıkarılabilir ve sınıflandırma doğruluğu önemli ölçüde artırılabilir.


Uzaktan algılamanın temelinde, elektromanyetik radyasyonun nesneler tarafından yansıtılması, soğurulması veya yayılması süreçleri yer almaktadır. Özellikle hiperspektral uzaktan algılama, her pikselin onlarca ila yüzlerce dar bantta spektral bilgi içermesi sayesinde yüzeydeki malzemelerin yüksek doğrulukla ayırt edilmesine olanak tanımaktadır.




Şekil 1.2. Uzaktan algılama sensörlerinin çalışma prensibine ilişkin bir görsel.

1.3 Hiperspektral Görüntü

Elektromanyetik tayf veya bir diğer ismi ile elektromanyetik spektrum (EMS), herhangi bir yerde fizik kurallarına göre mümkün olan tüm elektromanyetik radyasyonu ve farklı ışıınım türevlerinin dalga boyları veya frekanslarına göre bu tayftaki rölatif yerlerini ifade eden ölçüttür (Vikipedi 2025). Hiperspektral görüntüleme ise (Hyperspectral Imaging-HSI), Şekil 1.3'te gösterildiği gibi elektromanyetik spektrumun görünür, yakın kızılötesi (near infrared-NIR) ve kısa dalga kızılötesi (short wave infrared-SWIR) bölgelerini kapsayan görüntüleri elde etmeye yönelik bir UA tekniğidir. Multispektral görüntülemeden farklı olarak, bu teknik yüzlerce dar ve bitişik banttan oluşan spektral bilgiler sağlar (Bilgin 2009; Çeşmeci vd 2009). Her piksel, yalnızca üç temel renk kanalı, kırmızı yeşil mavi (red green blue-RGB) yerine, 50 ila 400 arasında değişebilen sayıda spektral bantı temsil eden bir spektral imza içerir. Bu sayede, her pikselin fiziksel ve kimyasal bileşimi hakkında ayrıntılı bilgi edinmek mümkün olmaktadır (USGS t.y.).




Şekil 1.3. Hiperspektral elektromanyetik spektrum (Hammond vd 2023).



Şekil 1.4. RGB ve Hiperspektral görüntülerin farkı.

Hiperspektral görüntüler, üç boyutlu veri küpleri (data cube) olarak ifade edilebilir. Şekil 1.4'te, hiperspektral görüntülerin RGB görüntülerle farkının daha kolay anlaşılmasına yönelik bir çizim sunulmuştur. Buna ek olarak, Şekil 1.5'te görüldüğü üzere; x ve y boyutları mekânsal bilgiyi (görüntü boyutları), λ boyutu (bant sayısı) ise spektral bilgiyi temsil etmektedir (Sığırcı vd 2022).

Hiperspektral görüntüleme, malzemelerin ayırt edilmesi ve sınıflandırılması, tür tanımlama ile çevresel değişimlerin izlenmesi ve analizinde, geleneksel multispektral görüntülemeye kıyasla daha yüksek doğruluk ve ayırt etme gücü sunar. Hiperspektral görüntüler, 400 ila 2500 nm gibi geniş bir spektral aralıkta, onlarca ila yüzlerce dar spektral bantta bilgi içerir. Her piksel, kendine has bir *spektral imza* taşıdığı için, yüzeydeki farklı malzeme veya bileşenler çok daha hassas şekilde ayırt edilebilmektedir.



Şekil 1.5. RGB ve HS görüntü boyut karşılaştırması (Shivendra Arısı, 2021).


Materyal düzeyinde ayırt edicilik sağlanırken; su, toprak, bitki, müsilaj gibi doğal malzemelerin özgün spektral tepkilerini analizine olanak tanır. Bu sayede, kimyasal veya biyolojik olayların (örneğin müsilaj oluşumu) izlenmesi ve takibi açısından da etkili bir araçtır (Kocakuşaklar vd 2017; Sığırcı vd 2022).

Tüm bu avantajlarına rağmen, hiperspektral görüntülemenin bazı dezavantajları da bulunmaktadır. Bunlar arasında, veri hacminin çok büyük olması, yüksek hesaplama gücü gerektirmesi, görselleştirmenin daha karmaşık olması, doğrudan insan gözüyle yorumlanamaması, gürültü ve atmosferik etkilerin daha fazla bantta görülebilmesi ve ön işleme gerektiren işlemler olabilmesi dezavantajları olarak sayılabilir.

Multispektral görüntüde, elektromanyetik spektrumun birçok dar bant aralığında yansıyan ışınım algılanarak görüntü elde edilir. Bu yöntemde genelde VIS, NIR ve SWIR gibi farklı spektral bantlarda veriler elde edilebilmektedir (Akyürek 2018). Her bantta, yeryüzündeki farklı nesne ve yüzeyler kendilerine özgü yansıtma özellikleri sergiler ve böylece çıplak gözle algılanamayan ayrıntıların tespiti mümkün hâle gelir (Sığırcı vd 2022). Özellikle çevresel izleme, tarım, orman yangını tespiti, su kalitesi değerlendirmesi ve kirlilik analizleri alanlarında çok fazla kullanılmakta olan multispektral görüntüler; müsilaj gibi çevresel olayların takibinde sağladığı veriler sayesinde yayılım ve yoğunluğu zamansal ve mekânsal olarak izlememize fırsat sağlar. Erken uyarı sistemlerinin kurulmasında ve müdahale planlarının da geliştirilmesinde oldukça önemlidir (Kocakuşaklar vd 2017; Koncagül vd 2022).

1. GİRİŞ

Multispektral ve hiperspektral görüntüler arasındaki temel fark, Şekil 1.6'da görüldüğü üzere, elektromanyetik spektrumun aynı bölgesinde sahip oldukları bant sayısıdır.



Şekil 1.6. Multispektral ve Hiperspektral görüntüler arasında fark (Tan 2017).

RGB görüntüyü açıklamak gerekirse, insan gözü kırmızı, yeşil ve mavi renk bantlarına karşılık gelen üç kanaldan oluşan RGB görüntüleri algılayacak şekilde gelişmiştir. Bu nedenle, RGB görüntüler günlük dijital kameralar, uydu görüntüleri ve harita servisleri gibi birçok alanda yaygın olarak kullanılmaktadır (Akyürek 2018). Her piksel sadece üç spektral değer taşır, bu değerler görsel analiz ve genel amaçlı görüntüleme işlemleri için yeterli bilgi sunar. RGB görüntüler yaygın olarak kullanılan, kolay erişilebilen veriler olup; görselleştirme ve temel analizler için uygundur. Ayrıca, hesaplama yükünün düşük olması ve veri boyutunun küçük olması nedeniyle pratik uygulamalarda tercih edilmektedir (Sığircı vd 2022). Bu avantajlarına rağmen sadece görünür ışık bölgesine ait (yaklaşık 400–700 nm) bilgi içermekte, farklı materyallerin benzer RGB değerlerine sahip olması ise ayırt etmeyi zorlaştırmaktadır. Kimyasal, biyolojik veya fiziksel özelliklere duyarlılığı bundan dolayı sınırlıdır. Çizelge 1.1'de RGB, multispektral ve hiperspektral görüntülerin belli parametrelerde performansları verilmiştir.

Çizelge 1.1. Üç görüntüleme türünün özelliklerinin karşılaştırması.

Özellik	RGB	MSI	HSI
Bant Sayısı	3 (R, G, B)	4-15	50-400+
Spektral Aralık	400-700 nm	400-1000 nm	400-2500 nm
Veri Türü	Görsel renk bilgisi	Yüzeysel spektral bilgi	Fiziksel/spektral imza
Ayırt Etme Gücü	Düşük	Orta	Yüksek
Kullanım Alanı	Genel görüntüleme	Tarım, askeri, çevre gözlemi	Çevresel analiz
Dosya Boyutu	Küçük	Orta	Büyük
Görsel Yorumlama	Kolay	Orta zorlukta	Zor, analiz gerektirir
Maliyet & Karmaşıklık	Düşük	Orta	Yüksek

Uzaktan algılama uydularında üretilen görüntülerde iki önemli çözünürlük türü vardır. Önemli parametrelerden birisi olan uzamsal çözünürlük (spatial resolution), bir uydu görüntüsünde algılanabilen en küçük nesnenin boyutunu ifade eder (Şerifoğlu vd 2021). Başka bir ifadeyle, bir pikselin belli bir alanda temsil ettiği fiziksel alan büyüklüğüdür ve genellikle metre cinsinden ifade edilir. Örneğin; 20 metre uzamsal çözünürlüğe sahip bir görüntüde, her bir piksel yerde yaklaşık 20 m × 20 m’lik bir alanı temsil eder. Yüksek uzamsal çözünürlük, ağaç araç gibi küçük nesnelerin daha ayrıntılı olarak görülebilmesini sağlarken; düşük uzamsal çözünürlük ise daha geniş alanları kapsar ancak detay kaybına yol açar (Irmak vd 2018).


Spektral çözünürlük (spectral resolution) ise elektromanyetik spektrumda algılanabilen bantların sayısı ve her bir bandın genişliği ile ilgilidir. Bir algılayıcı tarafından algılanan dalga boyu dağılımını ifade eden spektral çözünürlük; algılayıcıların toplam dalga boyu dağılımlarında küçük aralıklı algılanması yani toplam dalga boyunun küçük aralıklara bölünmesi durumunda yüksek spektral çözünürlüğün elde edilmesini sağlar (Akoğuz vd 2013). Yüksek spektral çözünürlük, çok dar dalga boyu aralıklarında (örneğin 5-10 nm) ölçüm yapılması demektir. Bununla, farklı yüzey materyalleri arasında çok küçük spektral farklar bile algılanabilecek duruma gelir. Düşük spektral çözünürlük ise sadece geniş bantlarda bilgi sunarken genelde birkaç bant içermektedir.

Hiperspektral sensörler, ayrıntılı veri toplama kapasiteleri ve farklı ortamlar arasında ayırım yapabilme yetenekleri sayesinde yüzey analizine yönelik birçok alanda yaygın olarak kullanılmaktadır. UA yöntemleri; askeri alanlar, mineral bilimi çalışmaları,

okyanus arařtırmaları ve tarımsal arazi ve ürün takibi gibi alanlarda sıkça başvurulanan bir teknolojidir (Yuksel vd 2013; Devi et al. 2015; Liu et al. 2017; Acosta et al. 2019).

Her malzeme, üzerine elektromanyetik enerji geldiğinde bunu belli oranlarda yansıtır, soğurur veya iletir. Bu davranış, nesnenin kimyasal ve fiziksel özelliklerine bağı olarak değışir. Farklı dalga boylarında farklı tepkiler gösteren bu etkileşim biçimleri, her malzeme için karakteristik bir özellik taşır ve *spektral imza* (spectral signature) olarak isimlendirilir. Spektral imza, bir nesnenin çeşitli dalga boylarındaki yansıma (reflektans) oranlarının grafiksel veya sayısal ifadesidir. Hiperspektral görüntüleme ile birlikte her piksel bu imzayı içerdiğinden farklı materyaller uzaktan da olsa birbirinden ayırt edilebilir. Farklı maddeler için örnek spektral imzalar Şekil 1.7’de gösterilmektedir.

Her nesne görünür (400–700 nm), yakın kızılötesi (700–1300 nm) ve kısa dalga kızılötesi (1300–2500 nm) bölgelerde farklı yansıma özellikleri gösterir. Spektral imzalar, yüzey türlerine göre o yüzeye özgü tepki verir. Ortam koşulları, nem oranı, yoğunluk gibi parametreler spektral imzayı etkileyebilse de genel formu büyük ölçüde korunur.



Şekil 1.7. Temsili Spektrumlar (Keleşoğlu 2022).

1.4 Görüntü Tabanlı Sınıflandırma

Görüntü tabanlı sınıflandırma, bir görüntüde yer alan her pikselin ait olduğu sınıfın belirlenmesi amacıyla gerçekleştirilen işlemler tamamına verilen genel bir isimdir. Bu yöntemler özellikle uzaktan algılama uygulamalarında, çevre analizinde, tarımsal planlamalarda, şehir planlaması işlemlerinde ve afet izleme gibi birçok alanda kullanılmaktadır (Lu et al. 2007). Görüntü tabanlı sınıflandırma yaklaşımları, piksel tabanlı, nesne tabanlı ve bölge tabanlı olarak üç ana grupta incelenebilir (Blaschke 2010). Her pikselin bağımsız olarak sınıflandırıldığı piksel tabanlı yöntemler, özellikle hiperspektral görüntüleme temelli çalışmalarda sıklıkla tercih edilmektedir (Bioucas-Dias et al. 2012, 2013). Bu yöntemlerde, her piksele ait spektral imza referans alınarak sınıf tahminleri yapılır. Nesne tabanlı sınıflandırma yöntemlerinde, görüntü öncelikle benzer spektral özelliklere sahip piksellerden oluşan bölütlere ayrılır. Ardından, her bir bölüt sınıflandırılarak sonuç elde edilir. Bu yaklaşım, yalnızca spektral bilgiyi değil, aynı zamanda uzamsal bütünlüğü de dikkate almaktadır (Blaschke 2010). Bölge tabanlı sınıflandırmada ise görüntü önce süperpiksellere ayrılır, sonrasında bu bölgelere sınıf etiketleri atanır (Achanta et al. 2012).

Görüntü tabanlı sınıflandırmalar genellikle aşağıdaki yöntemleri içermektedir.

- i. İstatistiksel yöntemler: Bayes, maksimum olasılık vb. geleneksel yaklaşımlar,
- ii. Makine öğrenmesi yaklaşımları: Karar ağaçları, destek vektör makineleri (support vector machines-SVM), k-en yakın komşu (k-NN) gibi yöntemler (Melgani et al. 2004),
- iii. Derin öğrenme yöntemleri: CNN, LSTM, Transformer tabanlı mimariler (Chen et al. 2016),
- iv. Temsile dayalı yöntemler: SRC, CRC, NSC gibi yaklaşımlar (Wright et al. 2009).

Bu tez kapsamında temsile dayalı sınıflandırma yöntemleri detaylı bir şekilde incelenmiş olup; bu yöntemlerin hiperspektral görüntüler üzerindeki sınıflandırma performansları ayrıntılı olarak değerlendirilmiştir.

1.5 Tezin Amacı ve Kapsamı

Tezde temel amaç, Marmara Denizi gibi kirlilik tehdidi altındaki sularda meydana gelen müsilaj oluşumlarının hiperspektral görüntüler kullanılarak sınıflandırılmasında temsile dayalı yöntemlerin başarımını analiz etmektir. Hiperspektral görüntüler, geniş bir spektral aralıkta çok sayıda bant içermeleri sayesinde müsilaj gibi oluşumların tespiti ve analizi için etkili bir veri kaynağı sunmaktadır.

Tez kapsamında aşağıdaki hedefler ele alınmıştır:

- Temsile dayalı sınıflandırma yöntemlerinin temel yapılarının ortaya konulması ve bu yöntemlerin PRISMA uydusundan elde edilen müsilaj görüntüleri üzerinde sınıflandırma başarılarının detaylı incelenmesi,
- Yöntemlerin farklı varyasyonları (JNSC, MSBNSC, RJNSC vb.) aracılığıyla, spektral ve spektral-uzamsal bilgilerin bütünleştiği yapıların analiz edilmesi,
- Performans ölçütleri olarak genel doğruluk (OA), sınıf ortalaması doğruluk (AA), Kappa katsayısı ve diğer istatistiksel metrikler üzerinden yöntemlerin performans analizinin yapılması.

Tez çalışması kapsamında, İstanbul ve Bursa kıyılarına ait, müsilaj içeren hiperspektral görüntü kümeleri kullanılmıştır. Hem spektral tabanlı hem de uzamsal bilgi içeren yöntemlerle sınıflandırma başarımları sistematik olarak karşılaştırılmıştır.

Mevcut çalışmalar, hiperspektral görüntülerin çevresel olayların izlenmesinde önemli bir potansiyele sahip olduğunu göstermektedir. Bu tez, söz konusu potansiyeli temsile dayalı sınıflandırma yöntemlerinin farklı varyasyonları üzerinden değerlendirerek, bu alana yönelik sistematik ve derinlemesine bir analiz sunmaktadır.

2. KAYNAK ÖZETLERİ

Ekolojik dengenin bozulması ve biyolojik çeşitliliğin azalmasına yol açan kentleşme ve sanayideki hızlı büyüme; önemli ölçüde çevre kirliliğine yol açmaktadır. Bu çevre felaketlerinden birisi de yakın zamanda ülkemizde Marmara Denizi'nde etkisini gösteren müsilaj olayıdır. Müsilajın tespiti ve takibinin yapılması karar vericilerin felaketin boyutunu anlaması, azaltma ve temizleme faaliyetlerinde acil durum stratejilerinde gereklidir. Bu kapsamda uzaktan algılama teknolojileri geniş kapsama alanlarında düşük maliyetle müsilaj oluşumlarının periyodik olarak izlenmesine olanak sağlamaktadır.

Bu bölümde, öncelikle müsilajın UA teknikleriyle tespiti ve izlenmesine yönelik literatürde yer alan güncel çalışmalar ele alınmıştır. İlgili araştırmalar, en eski tarihten en yeniye doğru sırayla sunulmuştur.

Uğur Acar ve arkadaşları Marmara Denizi'nde Sentinel-2 uydu görüntüleri ve Google Earth Engine platformunda Random Forest algoritması kullanarak müsilajın zamansal yayılımını başarılı şekilde tespit etmiştir. Çalışma, uydu tabanlı hızlı ve yüksek doğruluklu müsilaj izleme metodolojisi geliştirmiştir (Acar vd 2021).

Levent Genç vd. Çanakkale Kuzey Ege kıyılarında müsilaj örneklerinin spektral özelliklerini inceleyerek, müsilaj indeksinin (MI) uydu tabanlı izleme için potansiyelini ortaya koymuştur. Çalışma, hiperspektral ölçümlerin müsilaj takibinde bant seçimine rehberlik edebileceğini ve günlük izleme gerekliliğini vurgulamaktadır (Genç vd 2021).

Merve Göral, çalışmasında 2021 yılı Mayıs-Temmuz ayları arası Sentinel-2 görüntüleri ile İzmit Körfezi'nde müsilajın zamanla değişimini analiz etmiştir. Analizde GEE platformu kullanılmıştır. Beş farklı indeksle çalışma yapılmış ve AFAI indeksinin en başarılı sonucu verdiği belirtilmiştir (Goral vd 2022).

Sefa Küçük vd. çalışmasında Sentinel-2A verileriyle Marmara Denizi'ndeki müsilaj oluşumlarını tespit etmiş ve müsilaj indeks haritaları üretmek amacıyla 20m çözünürlüklü bantlar 10m'ye yükseltilerek zaman içindeki değişimleri analiz edilmiştir.

Çalışma, müsilajın zaman içindeki değişimini izleme konusunda uydu verilerinin etkinliğini göstermiştir (Küçük vd 2022).

Bahri Abacı vd. 2022'deki çalışmasında, Sentinel-2 ve PRISMA verileriyle oluşturdukları veri kümesi üzerinde geleneksel ve derin öğrenme algoritmalarıyla müsilajı erken aşamada tespit etmeyi hedeflemiştir. U-NET modeli en başarılı sonuçları vermiş; çalışma, uydu verileriyle yüksek doğrulukta tespitin mümkün olduğunu göstermiştir (Abacı vd 2022).

Chuanmin Hu vd. OLCI ve yüksek çözünürlüklü Sentinel-2 MSI verileri ile deniz yüzeyindeki müsilaj ve yüzen maddelerin detaylı uzamsal ve spektral analizini gerçekleştirmiştir. Çalışmada ayrıca, MODIS, DESIS gibi diğer uydu sensörleri kullanılarak hiperspektral imzalar incelenmiştir (Hu et al. 2022).

Atila Hüsnü Eronat, Sentinel-2 uydu görüntüleri kullanarak Marmara Denizi'ndeki müsilajın optik tanımlayıcı motifini belirlemiş ve bu motifin erken tespit ile ulusal izleme sistemleri geliştirmede önemli katkı sağlayacağını ortaya koymuştur. Çalışma, müsilajın atmosfer üstü radyans değerlerinde anlamlı artışlar olduğunu göstermiştir (Eronat vd 2022).

Filiz Sunar vd. Sentinel-2 uydu verileri ile yerinde su kalitesi ölçümlerini kullanarak müsilajın mekansal dağılımını incelemiş ve tek değişkenli regresyon modelleriyle klorofil-a ve bulanıklık tahmininde başarılı sonuçlar elde etmiştir (Sunar vd 2022).

Gözdenur Keleşoğlu vd. 2021 bahar-yazında Marmara Denizi'nde görülen müsilaj salgını, su yüzeyinde görünürken 30 metre derinliğe kadar yayılarak ciddi su kaynaklı hastalıklara ve ekonomik zararlara yol açabileceği uyarısı yapılmıştır. Bu çalışmada, PRISMA hiperspektral verileri kullanılarak müsilajın mekânsal dağılımı ve birikimi uzaktan algılama ile incelenmiştir (Keleşoğlu vd 2022)

Taşkın Kavzoğlu vd. İzmit Körfezi'nde 2021 yılına ait Sentinel-2A görüntülerini kullanarak piksel tabanlı CNN modelleriyle müsilaj oluşumlarını %98'in üzerinde

doğrulukla sınıflandırmıştır. Çalışma, CNN mimarisinin müsilajın tespiti ve haritalanmasındaki etkinliğini ortaya koymaktadır (Kavzoğlu vd 2023).

Enes Bakış, Marmara Denizi'ndeki müsilajlı ve temiz alanlardan elde edilen Sentinel-1 görüntüleriyle zaman serisi analizi yaparak, müsilajın tespiti için derin ve makine öğrenmesi yöntemlerini uygulamıştır. Çalışmada %84–100 arasında başarı oranları elde edilmiş ve erken müdahale için yöntemlerin etkinliği vurgulanmıştır (Bakış vd 2023).

Alp Ertürk vd. Marmara Denizi'nde 2021 müsilaj salgınına hiperspektral PRISMA verileriyle incelemiş, spektral özelliklerin ve müsilajın birikimden kaynaklanan değişimlerin analizinde karışım giderimi yöntemini kullanmıştır. Önerilen yöntem, eğitim gerektirmeden, farklı veri kümelerinde tutarlı ve yorumlanabilir müsilaj dağılım haritaları sağlamış, temizlik ve izleme çalışmalarına katkı sunmuştur (Ertürk vd 2023).

Çağatay Esi, Alp Ertürk vd. Marmara Denizi'nde 2021 baharındaki müsilaj patlamasının spektral ve mekânsal analizinde lineer karışım modelinin (LMM) sınırlamalarını aşmak için spektral değişkenliği göz önüne alan genişletilmiş lineer karışım modeli (ELMM) tabanlı unmixing yaklaşımını önermiştir. Bu yöntem, manuel doğrulama veya eşik belirlemeye gerek kalmadan müsilajın farklı türlerini daha doğru ayırt etmeye olanak tanımış ve önceki yöntemlere kıyasla daha güvenilir sonuçlar sunmuştur (Esi vd 2023).

Deren Ege Turan vd. 2023'te yaptıkları çalışmalarında, hiperspektral (HS) uzaktan algılama görüntü sınıflandırmalarında derin öğrenme modellerinin açıklanabilirliği üzerine odaklanılmıştır. Özellikle, GradCAM, GradCAM++ ve Kılavuzlu Geriye Yayılım yöntemleri kullanılarak konvolüsyonel sinir ağı (CNN) modellerinin karar verme süreçleri incelenmiştir. Çalışmanın temel katkıları şunlardır: HS yama sınıflandırıcı CNN'in hem uzamsal hem de spektral dikkat dağılımı yorumlanmış, bu dikkat mekanizmasının girdi yaması boyutuna bağlı olarak nasıl değiştiği analiz edilmiştir. Ayrıca, GradCAM ve GradCAM++ yöntemleri karşılaştırılmış ve en yaygın kullanılan HS veri kümesi üzerinde kılavuzlu geri yayılım yöntemiyle spektral bantların sınıflandırmadaki önemi araştırılmıştır (Turan vd 2023).

Kemal Gürkan Toker, hiperspektral görüntü sınıflandırması için spektral ve uzamsal bilgiyi etkin kullanan Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcısı (Spectral-Spatial Nearest Subspace Classifier) yöntemleri geliştirilmiştir. Bu yöntemler, klasik En Yakın Altuzay Sınıflandırıcısı (NSC) modelinin geometrik varsayımını uzamsal komşuluk bilgisiyle genişletir ve bitişik piksellerin aynı altuzayda olduğunu kabul etmektedir. Altuzaylar arası yakınlık Kanonik Korelasyon Analizi ile ölçülmektedir. Tezde dört farklı yöntem önerilmiştir; biri piksel çevresindeki uzamsal pencereleri, üçü ise süperpikselleri kullanmaktadır. Önerilen yöntemler hem literatürde yaygın veri kümelerinde hem de müsilaaj verilerinde test edilmiştir. Avantajları arasında basit ve anlaşılır geometrik yorum, kısa eğitim süresi, kapalı-form çözüm, az etiketli veride iyi performans ve gürültüye karşı dayanıklılık yer almaktadır (Toker 2023).

Aylin Tuzcu Kokal ve arkadaşlarının çalışmasında, uzun dönem deniz yüzeyi sıcaklığı (SST) izleme ve anormalliklerin tespiti, deniz suyu kalitesinin anlaşılmasına önemli katkı sağlamaktadır. Türkiye’de Marmara Denizi çevresinin yoğun nüfuslu illerle çevrili olması sebebiyle, deniz suyu kalitesi bilimsel ve kamuoyu açısından giderek daha fazla önem kazanmıştır. Bu çalışma, 1990-2021 yılları arasındaki 32 yıllık dönemde Marmara Denizi’nin SST eğilimleri ve anormalliklerinin tespiti üzerine odaklanmıştır. Çalışmada, NOAA OISST V2 verisi kullanılarak mevsimsel-trend ayrıştırma yöntemi (STL) uygulanmış ve SST zaman serilerindeki artış eğilimi ve özellikle son yıllarda ilkbahar aylarında anormallikler tespit edilmiştir. Ayrıca, SST’nin mekânsal dağılımı Landsat-8, Sentinel-3 ve NOAA OISST V2 uydusu verileri ile incelenmiş, elde edilen sonuçlar yerinde ölçüm verileriyle doğrulanmıştır. Sonuçlar, Marmara Denizi’nde SST’nin genel olarak artış gösterdiğini ve mevsimsel anormalliklerin var olduğunu ortaya koymuştur (Kokal vd 2023).

Riyaaz Uddien Shaik ve arkadaşlarının çalışmasında, PRISMA uzay tabanlı hiperspektral görüntüleme sisteminin (PHSI) uzaktan algılama alanındaki potansiyeli SWOT analizi ile incelenmiştir. PRISMA, ≤ 12 nm gibi üstün spektral çözünürlüğü ve yüksek mekânsal çözünürlüğü ile özellikle bitki örtüsünün biyofiziksel parametrelerinin çıkarılmasında diğer uygulamalara göre daha avantajlı bulunmuştur. Ancak, veri alımlarının sınırlı olması, uzun tekrar ziyaret süreleri, gürültülü bantlar, atmosfer etkileri ve yüksek hesaplama gereksinimleri gibi zorluklar nedeniyle sürekli izleme için uygun

olmayabilir. PRISMA'nın potansiyel kullanım alanları arasında geniş ölçekli haritalama, teknoloji transferi ve diğer uzaktan algılama verileri ile veri füzyonu yer alırken, uydu ömrü ve disiplinler arası uzman ihtiyacı önemli zorluklar olarak belirtilmiştir. Çalışmada ayrıca bu zayıf yönler ve tehditlere karşı önerilen stratejiler de sunulmuştur (Shaik et al. 2023).

Ufuk Sanver çalışmasında, özellikle Akdeniz Havzası ülkeleri için ekonomik ve ekolojik etkileri nedeniyle güncel bir sorun olan müsilaj oluşumuna odaklanılmıştır. Müsilajın başlıca nedenleri, denizde artan organik ve endüstriyel kirlilik kaynaklı besin yükü, küresel ısınma ve meteorolojik koşullardır. Artan besin yüküne karşı kalıcı önlemler alınmasının önemi vurgulanırken, müsilaj döneminde özellikle deniz yüzeyindeki müsilajın toplanması için bazı müdahaleler önerilmiştir. Bu amaçla, insansız yüzey araçları gibi sistemler için otonom bir müsilaj izleme sistemi tasarlanmıştır. Önerilen sistem, Marmara Denizi'nde müsilaj riskinin sürekli izlenmesini ve kritik parametrelerin kaydedilmesini hedefler. Sistem üç katmandan oluşur: Birinci katmanda, gerçek zamanlı olarak belirli bir çevrede kamera ile deniz yüzeyi taranır; müsilaj olası bölgeler tespit edilince araç o bölgeye otonom olarak yönlendirilir. İkinci katmanda, pH, iletkenlik ve çözünmüş oksijen gibi deniz suyu parametreleri gerçek zamanlı ölçülür. Üçüncü katmanda ise mümkünse üç farklı derinlikten gerçek su örnekleri toplanarak laboratuvar analizine gönderilir. Ayrıca, görüntü işleme, CNN (ResNet50), kNN, SVM ve FFNN yöntemleri karşılaştırılmış ve önerilen müsilaj sınıflandırma yönteminin daha yüksek doğruluk ve umut verici performans sunduğu gösterilmiştir (Sanver 2023).

Tuğcan Dünder önceden eğitim gerektirmeyen Random Patches Network (RPNet) ile hiperspektral görüntülerden derin ve yüzey özellikler çıkarmış, ardından yönlendirilmiş filtre (GF) kullanarak kenar detaylarını korumuştur. Özellik kümeleri, sınıf ayrımını artırmak için LDA ile boyut indirgeme uygulanmış ve süperpiksel segmentasyonu sahte örnekler oluşturularak LDA etkinliği artırılmıştır. Son aşamada, süperpiksel rehberli gevşek işbirlikçi temsil (RCR) ile sınıflandırma yapılmıştır. Önerilen yöntem, gerçek hiperspektral görüntülerde başarılı sonuçlar göstermiştir (Dünder 2024).

Çağatay Esi ve arkadaşları tarafından, hiperspektral uzaktan algılama verileri kullanarak deniz müsilajını izlemek için negatif olmayan matris çarpanlarına ayırma

(NMF) tabanlı bir karışım giderimi yöntemi önermiştir. Yöntem, müsilağın spektral imzasını tanımlayarak yoğunluklarını hassas şekilde tespit eder ve farklı zamanlardaki veri kümeleri müsilağın zamansal dağılımını ve birikimini haritalandırmayı sağlar. Bu yaklaşım, manuel doğrulama veya eşik değeri belirleme gerektirmeden, PRISMA verileriyle doğrulanmıştır ve müsilağ analizinde etkin ve pratik bir çözüm sunmaktadır (Esi vd 2024).

Muhammet Mustafa Yurdakul çalışmasında, küresel ısınmaya bağlı olarak artan deniz suyu sıcaklıklarının neden olduğu müsilağ problemini ele almıştır. Bu kapsamda, Marmara Denizi'nden 14 Mart–4 Temmuz 2021 tarihleri arasındaki Planet uydu görüntüleri kullanılarak müsilağlı ve müsilağsız alanlar manuel olarak etiketlenmiş ve bir veri kümesi oluşturulmuştur. Bu veri kümesi ile, YOLOv5'in segmentasyon versiyonuna dayanan bir derin öğrenme modeli eğitilmiş ve otomatik müsilağ tespiti yapılmıştır. Sonuçlar, önerilen modelin başarılı ve umut verici performans sergilediğini göstermiştir (Yurdakul 2024).

Temsile dayalı yöntemlerde incelenen seyrek temsile dayalı sınıflandırma, işbirlikçi temsile dayalı sınıflandırma ve altuzay tabanlı temsil yaklaşımları bir sonraki bölümde detaylandırılmıştır.

3. TEMSİLE DAYALI SINIFLANDIRMA YAKLAŞIMLARI

Hiperspektral görüntü sınıflandırma işlemlerinde piksellerin yüksek boyutlu spektral bilgilerini doğru bir biçimde modellemek ve sınıf ayrımını güçlendirmek için temsile dayalı yöntemler önemli bir yere sahiptir. Bu yaklaşımlarda esas amaç test örneğinin (piksel veya piksel grubu) eğitim verilerinin doğrusal birleşimleriyle ifade edilmesi ve hangi sınıfa ait bileşenlerin bu ifadeye en fazla katkı sağladığının belirlenmesidir. Temsile dayalı yöntemler, temsil katsayılarının hesaplanma biçimine göre farklılıklara sahiptir. Seyrek temsile dayalı yaklaşımlar (SRC) az sayıda eğitim örneğinin test örneğini temsil edebileceğini varsayar. İşbirlikçi temsile dayalı yaklaşımlar (CRC) tüm eğitim örneklerini işbirliği içinde kullanıp daha dengeli bir temsil elde etmeye çalışmaktadır. Altuzay tabanlı yaklaşımlar (NSC) ise her sınıfın spektral uzayını bir altuzay olarak değerlendirip test örneğini bu altuzaylara olan yakınlığına göre sınıflandırır.

Bu bölümde, temsile dayalı sınıflandırma yöntemlerinin temel prensipleri ve farklı varyantları incelenecek; önce seyrek temsile dayalı sınıflandırma (SRC), ardından işbirlikçi temsile dayalı sınıflandırma (CRC) ve son olarak altuzay tabanlı temsil yaklaşımı olan en yakın altuzay sınıflandırıcısı (NSC) ele alınacaktır.

3.1 Seyrek Temsile Dayalı Sınıflandırma (Sparse Representation-Based Classifier - SRC)

Bu yöntem ilk olarak yüz tanıma çalışmaları için önerilmiş daha sonra makine öğrenme çalışmalarında da kullanılmıştır (Tang et al. 2014; Dong et al. 2015). Yöntemde eğitim örneklerinin bazıları ile test örneği için bir gösterim yapılabileceği üzerine varsayım bulunmaktadır. Bu varsayımın anlamı seyreklik kısıtı demektir (Toker 2023).

Seyrek Temsile Dayalı Sınıflandırıcı (SRC), bir test örneğinin, yalnızca kendi sınıfına ait birkaç örnek kullanılarak temsil edilebileceği varsayımına dayanmaktadır. Test verisi tüm eğitim örneklerinin doğrusal birleşimiyle ifade edilmeye çalışılır. Ancak bu temsilin seyrek (sparse) olması beklenir; yani çoğu temsil katsayısı sifıra yakın olmalıdır. Bu seyrek temsil, genellikle ℓ_1 normu ile minimize edilen bir eniyileme

problemiyle elde edilir. Ardından her sınıfa ait yeniden yapılandırma hataları hesaplanarak test örneği, hatası en düşük olan sınıfa atanır (Wright et al. 2009, Li et al. 2016).

Diğer yöntemlere göre farkı; tüm sınıfların eğitim verisinin aynı anda kullanarak temsil oluşturulması ve bu temsilde yalnızca sınıfa özgü örneklerin belirgin şekilde katkı yapmasını beklenir. Bu yönüyle geleneksel sınıflandırıcılardan farklı olarak temsil temelli ve ayırık bir karar mekanizması kullanır. Ayrıca, altuzay temelli yöntemlerden farklı olarak herhangi bir sınıfa özel model kurmak yerine tüm sınıfları doğrudan karşılaştırır (Toker 2023). Seyrek gösterim tabanlı yöntemlerde seyreklik kısıtı da hesaba katıldığında sınıflandırma için eniyileme problemleri aşağıdaki gibi olmaktadır (Toker 2023).

$$y \approx Xa, \quad \hat{a} = \arg \min_a \|a\|_0 \quad \text{s.t.} \quad \|y - Xa\|_2 \leq \beta \quad (3.1)$$

Burada $\|a\|_0$, a vektörünün ℓ_0 normunu ifade eder. Bu a vektörü içerisinde yer alan sıfırdan farklı elemanların sayısıdır. β ise hata tolerans değerini ifade etmektedir ve sıfırdan büyüktür. Eğitim verisi artınca çok büyük hesap maliyetine yol açtığından aşağıdaki Denklem (3.2)'de görüldüğü üzere ℓ_1 normu üretilmiştir.


$$\hat{a} = \arg \min_a \|a\|_1 \quad \text{s.t.} \quad \|y - Xa\|_2 \leq \beta \quad (3.2)$$

Seyrek çözümlemeler yapıldıktan sonra sınıf etiketi Denklem (3.3)'te verildiği gibi sınıfsal olarak en düşük regresyon hatası alınan sınıf olarak belirlenmektedir.

$$\text{etiket}(y) = \arg \min_i \|y - X_i \hat{a}_i\|_2 \quad \forall i \in \{1, 2, \dots, C\} \quad (3.3)$$

SRC yöntemini örnek üzerinden açıklamak gerekirse, varsayımsal olarak kırmızı, mavi ve yeşil renklerle boyanmış 100 farklı görüntüden oluşan bir veri kümesi bulunduğu kabul edilsin. Yeni bir görüntü (test örneği) geldiğinde ve bu görüntü kısmen kırmızı bileşen içerdiğinde, SRC yöntemi bu görüntüyü söz konusu 100 görüntü içerisinde yalnızca birkaçının doğrusal birleşimi ile temsil etmeye çalışır. Eğer bu temsil ağırlıklı olarak kırmızı sınıfına ait örnekler ile gerçekleştirilebiliyorsa, yöntem “görüntü kırmızı

sınıfına aittir” sonucunu verir. Buradaki $\|\alpha\|_1$ normu, yalnızca birkaç eğitim örneğinin aktif olarak kullanılmasını teşvik ederek seyrekliği sağlar. Problem şemasına ilişkin görsel Şekil 3.1’de sunulmuştur. α ’lar sıfırdan farklı katsayıları göstermektedir.



Şekil 3.1. SRC yöntemi problem şeması (Toker 2023).

SRC türevleri aşağıdaki gibidir:

- **Ortak Seyrek Temsile Dayalı Sınıflandırma (Joint Sparse Representation-Based Classifier - JSRC)**

Tüm piksellerin birlikte temsil edilmesi ile gerçekleştirilen analizdir (Chen et al. 2011). JSRC, spektral-uzamsal sınıflandırma yöntemleri içerisinde yer alan ve aynı sınıfa ait birden fazla örneğin birlikte seyrek temsil edilmesine (joint sparse representation) dayanan bir sınıflandırma yaklaşımıdır. Temel fikir, sınıflandırılacak her pikselin veya uzamsal komşuluk penceresindeki piksel grubunun, eğitim verisi sözlüğü (dictionary) kullanılarak seyrek bir şekilde temsil edilmesidir (Chen et al. 2011). Aynı sınıfa ait piksellerin benzer spektral özellikler taşıdığı ve dolayısıyla benzer temsil katsayılarına sahip olacağı varsayılmaktadır (Cai et al. 2013). Böylece pikseller tek olarak değil komşulukta yer alan tüm pikseller ortak bir seyrek katsayı vektörü ile modellenmektedir. SRC yönteminde her pikselin temsili bağımsız olarak elde edilir. JSRC yönteminde ise uzamsal olarak ilişkili pikseller birlikte çözülmemektedir. Bu yaklaşım, gürültüye karşı daha dayanıklı (robust) sonuçlar üretir ve sınıflandırma doğruluğunu artırır (Zhong et al. 2012).

- **Çok Ölçekli Süperpiksel Yönlendirmeli Filtre & Çoğunluk Oylama Sınıflandırıcısı (Multi-scale Superpixels Guided Filter & Majority Voting – MSS GF & MSS MV)**

MSS-GF çok ölçekli bir süperpiksel segmentasyonu ile elde edilen uzamsal alanların kılavuzlu filtre (guided filter) yöntemiyle iyileştirilmesini baz almaktadır. Süperpiksel segmentasyonunda hiperspektral görüntüde yer alan pikseller spektral benzerliklerine göre homojen bölümlere ayrılıp hem spektral hem de uzamsal bilgi bütünlük olarak kullanılır (Achanta et al. 2012). Kılavuzlu filtre ise bölgelerde kenar yapısını koruyarak gürültüyü azaltır, pikseller arasında spektral varyasyonu yumuşatıp doğrusal olmayan bir filtreleme sağlar (He et al. 2013). MSS-GF yönteminde aynı görüntü farklı ölçeklerde yani farklı süperpiksel sayıları ile işlenerek hem küçük hem de büyük yapısal detaylar korunmaktadır. Kılavuzlu filtre çok ölçekli süperpiksel bölgeler üzerinde uygulanarak sınıflandırmadan önce spektral uzamsal özelliklerin daha temiz ve ayırt edilebilir duruma gelmesini sağlar (Dündar 2019).

MSS-MV de çok ölçekli süperpiksel segmentasyonu kullanılsa da MSS-GF'den farklı olarak çoğunluk oylaması (majority voting) stratejisini uygular. Farklı ölçeklerde süperpiksel tabanlı sınıflandırma sonuçları elde edilir ve her pikselin sonuç etiketi farklı ölçeklerden elde edilen tahminlerin çoğunluk kararına göre belirlenir. Tek bir ölçeğin sınırlamalarını azaltıp daha dengeli sonuçlar üretilerek özellikle sınıf sınırlarında tek ölçekli yöntemlerde görülen hatalar azaltılır ve ölçeklere olan bağımlılık en aza indirgenir (Dündar 2019).

3.2 İşbirlikçi Temsile Dayalı Sınıflandırma (Collaborative Representation-Based Classifier - CRC)

SRC yöntemine benzer olarak, test örneğini tüm sınıflara ait olan eğitim örneklerinin doğrusal birleşimiyle temsil etmeyi hedefler. SRC'den farklı olarak temsil katsayılarını elde etmek için seyrekliği (ℓ_1 normu) zorlamaz bunun yerine ℓ_2 normuna dayalı bir çözüm uygular. Bu yaklaşım, temsil sırasında tüm sınıfların eğitim örneklerinin işbirliği içinde katkı sağlamasına olanak verir ve daha hızlı ve kararlı sonuçlar elde edilir. Sınıflandırma için eniyileme problemi aşağıdaki gibidir (Toker 2023).

$$\hat{a} = \arg \min_a \|y - Xa\|_2^2 \quad (3.4)$$

Yöntemin eniyileme problemleri aşağıdaki gibidir. Denklem (3.4)'te yer alan eniyileme problemi ℓ_2 -norm en küçük kareler yöntemi ile çözüldüğünde kapalı form olarak aşağıdaki çözüm elde edilmektedir.

$$\hat{a} = (X^T X)^{-1} X^T y \quad (3.5)$$


Test pikseli sınıf etiketi Denklem (3.6)'daki gibi en düşük regresyon hatası alınan sınıfa atanır (Toker 2023).

$$etiket(y) = \arg \min_i \|y - X_i \hat{a}_i\|_2 \quad \forall_i \in \{1, 2, \dots, C\} \quad (3.6)$$

Diğer yöntemlere göre farkları şunlardır: CRC, temsile dayalı yöntemlerin hesaplama yükünü azaltmak amacıyla geliştirilmiştir. SRC'de seyrekliğin sağlanması için çözülmesi gereken ℓ_1 tabanlı eniyileme problemi, yüksek hesaplama maliyeti gerektirirken, CRC'de ℓ_2 çözümü kapalı formda elde edilebilir ve bu da daha hızlı çalışmasını sağlar. Ayrıca, seyrekliği zorlamadan da yüksek sınıflandırma performansı elde edilebilmektedir (Toker 2023).

SRC için Şekil 3.1'de verilen senaryoda, bir test örneği yalnızca birkaç eğitim örneğinin doğrusal birleşimiyle temsil edilirken, CRC yaklaşımında test örneği, örneğin kırmızı sınıfa ait tüm eğitim örneklerinin katkılarının birlikte değerlendirilmesiyle temsil edilmektedir. Bu durum Şekil 3.2'de tasvir edilmiştir. CRC'de her örnek belirli bir katkı sağlasa da, aşırı katkı yapan örnekler regülasyon yoluyla cezalandırılır. Avantajı SRC'ye kıyasla çok daha hızlıdır. Büyük veri kümeleri ve gerçek zamanlı uygulamalarda tercih edilebilmektedir. Çözüm kararlı ve deterministiktir. Küçük eğitim örneklerinde dahi iyi performans gösterebilmektedir. Dezavantajları: Seyreklik zorlanmadığı için bazı durumlarda ayrıştırıcılığı SRC kadar güçlü olmayabilir. Tüm sınıfların eğitim örneklerinin katkı sağladığı temsil, sınıf sınırlarının çok iç içe olduğu durumlarda karışıklığa yol açabilmektedir. Yüksek korelasyona sahip sınıflar arasında ayrım gücü SRC'ye göre daha düşebilmektedir.

CRC yönteminde, SRC yöntemini açıklarken örnek verdiğimiz gibi yine kırmızı, mavi ve yeşil renklerle boyanmış 100 görüntüden oluşan aynı veri kümesi düşünölsün. Yeni bir görüntü geldiğinde, bu yöntem temsil için yalnızca birkaç örnek seçmek yerine, tüm sınıflara ait tüm eğitim örneklerini birlikte (işbirliği içinde) kullanır. Her sınıf için elde edilen temsil hatası hesaplanır. Eğer en küçük hata kırmızı sınıfa aitse, “görüntü kırmızı sınıfına aittir” sonucu çıkar.



Şekil 3.2. CRC yöntemi problem şeması (Toker 2023).

CRC varsayımı altında yer alan bazı geliştirilmiş yöntemler ise aşağıdaki gibidir:

- **Yapısal-Çekirdek İşbirlikçi Temsile Dayalı Sınıflandırma (Structural-Kernel Collaborative Representation Classifier - SKCR)**

SKCR, CRC’nin hem çekirdek (kernel) hem de yapısal bilgi ile zenginleştirilmiş bir versiyonudur. CRC’de sınıflandırma, tüm sınıflara ait eğitim örneklerinin birlikte değerlendirilmesiyle, işbirlikçi temsil gücünden yararlanılarak gerçekleştirilir. Ancak doğrusal ayırım yüzeyleriyle sınırlı olduğundan, veri uzayındaki doğrusal olmayan dağılımlar yeterince iyi modellenemez (Wright et al. 2009). SKCR yöntemin, doğrusal olmayan veri dağılımlarını modellemek amacıyla eğitim ve test örnekleri, seçilen bir çekirdek fonksiyonu yardımıyla yüksek boyutlu bir özellik uzayına dönüştürölür (He et al. 2013). Bu yüksek boyutlu uzayda, yalnızca piksel benzerlikleri değil; aynı zamanda sınıf içi yakınlıklar ve sınıflar arası ayrımlar da temsil katsayıları hesaplanırken dikkate alınır (Toker 2023).

Diğer yöntemlerden farklı olarak SKRC, CRC’nin işbirlikçi temsil yaklaşımını korumakla birlikte, çekirdek yöntemi sayesinde doğrusal olmayan ayırım sınırlarını da

öğrenebilir hale gelmektedir. Ayrıca, yapısal düzenleme (örneğin manifold yapılar veya sınıf-temelli ilişki kısıtlamaları) aracılığıyla yalnızca örnekler arasındaki benzerliklere değil, verinin altında yatan yapısal ilişkilere de duyarlıdır. Bu sayede, klasik CRC, SRC gibi yöntemlere kıyasla daha zengin ve esnek bir temsil kapasitesi sunar (Toker 2023).

3.3. Alt Uzay Tabanlı Temsil Yaklaşımı: En Yakın Alt Uzay Sınıflandırıcısı (Nearest Subspace Classifier - NSC)

SRC ve CRC yöntemlerinde, test örnekleri için temsil elde edilirken eğitim örneklerinin tamamı kullanılır. Buna karşın NSC (Nearest Subspace Classifier) yöntemi, her sınıfa ait örneklerden bir altuzay oluşturur ve test verisini bu altuzaylara projeksiyon yoluyla en yakın olan sınıfa atar. Bu yaklaşım, tüm eğitim verilerinin birlikte kullanılmasından ziyade, sınıf bazlı temsile odaklanır (Toker 2023). NSC, spektral yönelim farklarını dikkate almasıyla öne çıkar. Yöntemin temelinde, aynı sınıfa ait örneklerin benzer özellikler taşıması gerektiği varsayımı vardır. SRC ve CRC'den farklı olarak, temsil oluşturma sürecinde eğitim verisinin tamamı yerine sınıf bazlı gösterim kullanılır (Shu vd 2019; Sun vd 2022). Gelişmiş sürümleri olan JNSC (ortak karar), RJNSC (sağlamlaştırılmış), SBNSC/WBNSC/MBNSC (uzamsal/çok ölçekli bilgi kullanan) gibi çeşitler, uzamsal komşuluk ve gürbüzlük gibi faktörleri hesaba katarak performansı artırır.

NSC, doğrudan temsil katsayılarını hesaplamak yerine, veriyi altuzaylara projekte ederek sınıflandırma yapar. Bu sayede, tüm eğitim verisini kullanmak yerine sınıfların temel uzay yapısına odaklanır. Temsile dayalı yöntemlerden farklı olarak, eniyileme veya seyreklik varsayımı kullanılmaz. NSC, özellikle doğrusal altuzay modeline uygun verilerde basit ve hızlı bir çözüm sunar. Her sınıfın doğrudan bir altuzay olarak temsil edildiği bu yöntemde temsile dayalı eniyileme yapılmaz.

NSC yönteminde, SRC ve CRC yöntemlerini açıklarken verdiğimiz örneklerdeki gibi kırmızı, mavi ve yeşil sınıflarının her biri kendi altuzayıyla (örneğin kendi renk tonlarını temsil eden bir matematiksel uzay) tanımlanır. Yeni bir görüntü geldiğinde, bu görüntünün her bir sınıfın altuzayına olan yakınlığı (örneğin projeksiyon mesafesi)

hesaplanır. Eğer görüntü, kırmızı sınıfın altuzayına en yakınsa, yöntem “görüntü kırmızı sınıfına aittir” sonucunu verir.


Aşağıdaki denklemde y test örneğini temsil etmektedir. Sınıflandırma işlemi, her sınıfa ait eğitim alt uzayı X_k üzerine projeksiyon yapılarak gerçekleştirilir. k sınıfa ait alt uzayın projeksiyon hesabı ise aşağıdaki şekilde ifade edilir (Toker 2023).

$$\hat{y}_k = X_k(X_k^T X_k)^{-1} X_k^T y \quad (3.7)$$

Test örneği en küçük e_k değerine sahip sınıfa atanır.

$$e_k = \|y - \hat{y}_k\|_2 \quad (3.8)$$

Denklem (3.7) ve Denklem (3.8)’i örneklendirecek olursak, her sınıfın örneklerinden bir alt uzay oluşturulur. Test örneği her sınıfın düzlemine yani alt uzayına yansıtılır. Hangi sınıfın düzlemine en yakınsa, test örneği o sınıfa ait sayılır. NSC, Şekil 3.3’te tasvir edilen problemle ilgilenir. Burada; X eğitim örneğini, y test örneğini, α ise katsayıları göstermektedir.



Şekil 3.3. NSC yöntemi problem şeması (Toker 2023).

NSC yönteminden türetilmiş diğer varyasyonlar aşağıda sunulmaktadır.

- **Ortak En Yakın Altuzay Sınıflandırıcısı (Joint Nearest Subspace Classifier - JNSC)**

NSC’nin uzamsal bilgiyi içeren bir varyasyonu olan JNSC, komşuluk yapısını dikkate alarak her pikseli tek başına değil, çevresindeki komşu piksellerle birlikte

değerlendirerek sınıflandırma yapar (Toker 2023). Bu sayede spektral-uzamsal bütünlük sağlanmış olur. Bu grubun tamamının ortak bir alt uzayda temsil edilebileceği varsayımına dayanır. Böylece, hem spektral hem de uzamsal bilgiler sınıflandırma sürecine entegre edilir. Kısacası, JNSC, NSC'nin uzamsal bilgiyle zenginleştirilmiş bir uzantısıdır (Bo et al. 2016; Toker 2023).

- **Dayanıklı Ortak En Yakın Altuzay Sınıflandırıcısı (Robust Joint Nearest Subspace Classifier – RJNSC)**

JNSC yönteminin gürbüz (robust) hale getirilmiş bir versiyonudur. RJNSC, hem spektral hem de uzamsal bilgiyi dikkate alırken, aynı zamanda gürültü, kenar bozulmaları ve sınıf içi varyasyonlara karşı duyarlılığı azaltmayı amaçlar. JNSC yönteminde ise eşit katkı varsayımı test pikseli komşuluğunda yer alan aykırı veya gürültülü piksellerin olması durumunda performansı olumsuz olarak etkilemektedir (Toker 2023). Bu yöntemde, uzamsal pencere içerisindeki komşu piksellerin etkisi, adaptif ağırlıklandırma veya filtreleme mekanizmaları ile düzenlenir. Böylece yalnızca benzer komşular etkili olurken, gürültülü veya farklı sınıfa ait piksellerin etkisi bastırılır (Toker 2023). Özellikle kenar bölgelerinde ve gürültülü verilerde daha istikrarlı sonuçların elde edilmesi sağlanır. Test pikselinin komşuluğunda bulunan aykırı durumdaki piksellerin olumsuzluğunu azaltmak için literatürde RJNSC yöntemi önerilmiştir (Bo et al. 2016,).

- **Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı (Window Based Nearest Subspace Classifier - WBNSC)**

Literatürdeki yöntemler, sınıflandırma sırasında uzamsal verilerden sabit veya adaptif komşuluk yapıları aracılığıyla yararlanmaktadır. WBNSC yönteminde, sabit komşuluk bilgisi ile süperpiksel tabanlı segmentasyon uygulanarak her bölgedeki örnekler birlikte sınıflandırılır. Ayrıca, komşuluk ağırlıkları sınıflandırma sürecine dâhil edilerek kararların doğruluğu artırılır (Toker 2023). WBNSC, test pikselinin sınıflandırılmasında test pikselinin yalnızca kendi spektral bilgisine değil, aynı zamanda sabit boyutlu bir uzamsal pencere içinde yer alan komşu piksellerin bilgisine de başvuran bir yöntemdir. Bu yaklaşımda her piksel, çevresindeki piksellerle birlikte değerlendirilir

ve bu grup, NSC mantığına uygun biçimde sınıf alt uzaylarına yansıtılarak sınıflandırma kararı verilir.

Diğer yöntemlere göre farkı; WBNSC, JNSC gibi uzamsal bilgiyi kullanır; ancak altuzayların yakınlığını ölçmek için kanonik korelasyon analizi (canonical correlation analysis-CCA) temelli bir yaklaşımdan faydalanır. Bu sayede iki altuzay arasındaki maksimum doğrusal ilişkiyi tespit ederek sınıflar arası ayırım yeteneğini artırır.

- **Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcı (Superpixel-Based Nearest Subspace Classifier - SBNSC)**

SBNSC, hiperspektral görüntüyü süperpiksel segmentasyonu ile anlamlı bölgelere ayırarak, her bir süperpikseli uzamsal olarak tutarlı bir birim olarak ele alan bir sınıflandırma yöntemidir. Bu yöntemde, her süperpiksel içindeki tüm pikseller birlikte değerlendirilir ve bu grup, NSC mantığıyla sınıf altuzaylarına yansıtılarak sınıflandırılır. Aynı süperpiksel içindeki tüm piksellerin aynı sınıfa ait olduğu varsayımıyla sınıflandırma yapılır. WBNSC yönteminde kullanılan sabit pencere kullanımı büyük homojen alanları üzerinde testler yapılması durumunda daha tercih edilebilir durumda olmasına rağmen eğer alanlar küçükse ve sınıflar arasında da yakınlık varsa sabit pencere kullanımı sorunlara yol açabilmektedir (Toker 2023).

SBNSC, WBNSC'ye benzer şekilde uzamsal bağlamı kullanır. Ancak, sabit boyutlu pencereler yerine içerik bazlı bölgesel yapılar olan süperpikselleri kullanır. Birbirine uzamsal olarak yakın durumda bulunan, birbirine spektral anlamda benzeyen pikseller süperpiksel olarak gruplandırılır. Bu sayede, sınıf sınırlarına daha duyarlı bir uzamsal modelleme yapılabilir. NSC ve WBNSC'den farklı olarak, tüm süperpiksel tek bir karar birimi gibi işlem görür. WBNSC'den kaynaklanan eksiklikleri ortadan kaldırmak hedefiyle uyarlanabilir komşuluk ilişkilerini kullanan üzere geliştirilmiştir. WBNSC'de test piksel komşusu olan pencere içindeki pikseller dikkate alınırken, SBNSC'de aynı süperpiksel içerisinde bulunan pikseller kullanılır (Toker 2023).

- **Çok Ölçekli Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcı (Multi-Scale Superpixel Based Nearest Subspace Classifier - MSBNSC)**

MSBNSC yönteminde, farklı ölçeklerde süperpiksel bölütlemeleri ile her ölçekte sınıflandırma yapılarak farklı uzamsal çözünürlüklerden elde edilen kararlar birleştirilmektedir. Hiperspektral görüntülerde sınıfların farklı boyut ve morfolojilere sahip olması nedeniyle, tek ölçekli süperpiksel segmentasyonu bu yapıları yakalamakta yetersiz kalabilmektedir. Özellikle süperpiksel boyutunun büyük olması, farklı sınıflara ait piksellerin aynı bölgede toplanma olasılığını artırmaktadır. Küçük boyutlar ise yeterli uzamsal bilgi sunamamaktadır (Zhang et al. 2017). Bu nedenle, literatürde çok ölçekli süperpiksel tabanlı yöntemler önerilmektedir. (Li et al. 2016; Zhang et al. 2017; Yang et al. 2022).

MSBNSC, süperpiksel segmentasyonunun farklı ölçeklerde uygulanmasıyla elde edilen çok katmanlı uzamsal bilgiyi NSC tabanlı sınıflandırma sürecine entegre eden bir yöntemdir. Bu yaklaşımda hiperspektral görüntü, birden fazla ölçekte süperpiksel bölgelere ayrılır ve her ölçekten elde edilen uzamsal bilgiyle zenginleştirilmiş sınıflandırma gerçekleştirilir. Son kararlar genellikle bu çok ölçekli sınıflandırma çıktılarının birleştirilmesi (fusion) ile alınır. Literatürde önerilen MSBNSC yöntemi ile farklı ölçeklerde bölütlemeler ile farklı uzamsal özelliklerin yakalanması hedeflenmiştir (Toker 2023).

SBNSC yalnızca tek bir süperpiksel segmentasyonu kullanırken, MBNSC çoklu ölçeklerde (farklı büyüklüklerde) süperpikseller oluşturarak farklı uzamsal çözünürlüklerdeki yapıları yakalar. Bu sayede hem geniş alanları kapsayan yapılar hem de ince detaylar dikkate alınmış olur. Karar birleştirme adımı sayesinde genel doğruluk artışı sağlanır.

CCA temelli yaklaşımlarda, yüksek boyutlu ve gürültülü hiperspektral verilerde gereksiz değişkenlerin etkisi sınıflandırma performansını olumsuz yönde etkileyebilmektedir (Wilms et al. 2015; Suo et al. 2017). Bu durumu aşabilmenin etkili yollarından biri seyrekleştirilmiş (sparse) CCA yöntemini kullanmaktır (Hardoon et al. 2011). Seyrek-CCA (SCCA), klasik CCA yönteminin bir varyantı olup, çözüm sırasında ℓ_1 veya ℓ_2 seyreklik kısıtlamaları uygulayarak yalnızca en anlamlı kanonik değişkenlerin seçilmesini sağlar. Bu tez kapsamında, altuzay yakınlığını ölçmede CCA kullanan yöntemlerde, CCA yerine SCCA'nın uygulanabilirliği araştırılmıştır. Böylece

3. TEMSİLE DAYALI SINIFLANDIRMA YAKLAŞIMLARI

sınıflandırmaya katkısı düşük değişkenler elenerek, modelin hem doğruluğu hem de genelleme yeteneği artırılmıştır. SCCA yapısı, MSBNSC yönteminde olduğu gibi çok ölçekli süperpiksel segmentasyonu ile birlikte uygulanmıştır. Her süperpikselin sınıfı, en yüksek korelasyon katsayısına göre belirlenmiştir. Farklı ölçeklerden elde edilen kararlar çoğunluk oylaması yöntemiyle birleştirilerek nihai sınıflandırma sonucu elde edilmiştir.

Bu alt başlıkta detaylı bir şekilde anlatılan alt uzay tabanlı temsil yaklaşımları, temel özellikleri ve farklılıkları, komşuluk kullanımı, altuzay ölçütü ve uzamsal bilgi entegrasyonu gibi parametreler açısından özetlenerek Çizelge 3.1’de sunulmuştur.

Çizelge 3.1. En Yakın Alt Uzay Sınıflandırıcılarının parametrelere göre yaklaşımları

Yöntem	Uzamsal Bilgi	Süper piksel	Gürbüzlük	Çok Ölçekli	Açıklama
NSC	×	×	×	×	Temel yöntem
JNSC	✓	×	×	×	Komşu pikseller dâhil edilir
RJNSC	✓	×	✓	×	Gürbüz JNSC
WBNSC	✓	✓	×	×	CCA kullanılır ve komşu pikseller dâhil edilir.
SBNSC	✓	✓	×	×	Süperpikseller kullanılır
MSBNSC	✓	✓	×	✓	Farklı ölçekte SBNSC
SCCA	✓	✓	×	✓	SCCA kullanılan MSBNSC

4. VERİ KAYNAKLARI ve DEĞERLENDİRME KRİTERLERİ

Bu bölümde tez çalışmasında kullanılan hiperspektral veri kaynağı, müsilağ olayının gözlemlendiği alanlara ait veri kümeleri, karşılaştırılan sınıflandırma yöntemlerinin başarımlarında kullanılan performans metrikleri açıklanmıştır.

4.1 PRISMA

PRISMA, İtalyan Uzay Ajansı ASI tarafından geliştirilmiş ve 2019 yılında uzaya fırlatılan bir hiperspektral gözlem uydusudur. Uydu, 30 km x 30 km'lik sahnelerde 30 m mekânsal çözünürlükte hiperspektral görüntü toplayan sensörü ve yaklaşık 5 m çözünürlükte görüntü sağlayan pankromatik kamerası ile yenilikçi elektro-optik cihazlara sahip bir dünya gözlem uydusudur. Bu kombinasyon, sahnenin geometrik özelliklerini yüksek doğrulukla belirleme imkanı sunarken hiperspektral sensör sayesinde sahnede yer alan nesnelerin kimyasal ve fiziksel bileşenlerinin analizini mümkün kılar (Loizzo et al. 2018). PRISMA'nın bu özellikleri UA camiasına ve kullanıcılara çevresel izleme, kaynak yönetimi, ürün sınıflandırması, kirlilik kontrolü vb. alanlarda birçok uygulama sunmaktadır (Vikipedi). Yer yüzeyinden yaklaşık 600 km irtifada yörüngede bulunan PRISMA uydusu, 29 gün tekrarlamaya periyoduna sahiptir. Görünümü Şekil 4.1'de verilen uydu, 12 nm spektral çözünürlük ile 400-2500 nm dalga boyu aralığında toplam 239 spektral bantta veri sağlamaktadır (Toker 2023).



Şekil 4.1. PRISMA uydusu – ASI

4.2 Kullanılan Müsilaj Veri Kümeleri

Hiperspektral görüntülerle yapılan çalışmalarda, literatürde yaygın olarak kullanılan standart referans veri kümeleri tercih edilmektedir. Bu veri kümeleri, farklı yöntemlerin karşılaştırmalı olarak analiz edilebilmesine olanak sağlamaktadır. Bu tez kapsamında, PRISMA uydusundan elde edilen, 2021 yılında Marmara Denizi'nde meydana gelen müsilaj olayına ait hiperspektral görüntüler kullanılmıştır. Şekil 4.2'de belirtilen ve Marmara Denizi doğusunda yer alan 35TPF ve 35TPE alanlarından alınan görüntüler üzerinden çalışmalar yapılmıştır. Şekil 4.3'te ve Şekil 4.4'te ise Bursa ve İstanbul müsilaj kümelerine ait örnek gösterimler verilmiştir (Abacı vd 2022; Toker 2023).




Şekil 4.2. Marmara Denizi'nde çalışma yapılan alanlar (Abacı vd 2022; Toker 2023).

Bursa veri kümesi 13.05.2021 tarihinde 35TPE bölgesinden, İstanbul veri kümesi ise 19.05.2021 tarihinde 35TPF bölgesinden elde edilen görüntüler üzerinden analiz edilmiştir. Algoritmaların çalışma sürelerini kısaltmak için alınan görüntüler kırpılmıştır.


4.3 Performans Ölçütleri

Bu tez kapsamında yapılan deneysel çalışmalar, Windows 10 Pro (64-bit) işletim sistemine sahip, Intel Core i7-10510U 1.80–2.30 GHz işlemci, 16 GB RAM ve 512 GB SSD donanım özelliklerine sahip bir bilgisayarda gerçekleştirilmiştir. Analizler MATLAB R2024b ortamında yürütülmüştür.

Hiperspektral görüntü sınıflandırmada yöntemlerin başarımlarını değerlendirmek için literatürde kabul görmüş ve yaygın olan performans metrikleri göz önüne alınmıştır. Bu metriklerle birlikte algoritmaların genel doğruluk, sınıf tabanlı doğruluk, rastgele sınıflandırmaya göre başarımlar, ikili sınıflandırmalarda denge analizleri ölçümlenmiştir. Ayrıca, yöntemlerin sınıflandırma haritaları verilerin temel doğruları (ground truth) ile görsel olarak da karşılaştırılmıştır. Kullanılan metrikler aşağıda maddeler halinde sıralanmıştır. Pozitif örnekler P, negatif örnekler ise N olarak kabul edilmiştir.



Şekil 4.3 İstanbul açıklarındaki musilaj oluşumu (Abacı vd 2022; Toker 2023).



Şekil 4.4 Bursa açıklarındaki musilaj oluşumu (Abacı vd 2022; Toker 2023).

TP (true positive) gerçek pozitif örneklerin doğru şekilde pozitif olarak sınıflandırılmasıdır. Başka bir ifadeyle, ilgili sınıfa ait olan piksellerin model tarafından

doğru biçimde o sınıfa atanmasıdır. TP değeri hassasiyet ve duyarlılık gibi metriklerin hesaplanmasında önemlidir. Tez kapsamında ele alınan hiperspektral görüntü sınıflandırmasında, müsilağ sınıfına ait piksellerin model tarafından da müsilağ olarak doğru biçimde tespit edilmesi TP'ye karşılık gelmektedir.

TN (true negative) gerçek negatif örneklerin doğru şekilde negatif olarak sınıflandırılmasıdır. Yani ilgili sınıfa ait olmayan piksellerin model tarafından da o sınıfa ait olmadığı biçimde etiketlenmesidir. TN değeri modelin yanlış alarm vermeme yeteneğini göstermektedir. Su sınıfına ait olan bir pikselin model tarafından da su olarak sınıflandırılması TN örneğidir.

FP (false positive), gerçekte negatif olan bir örneğin hatalı şekilde pozitif olarak sınıflandırılmasıdır. Yani, ilgili sınıfa ait olmayan bir pikselin model tarafından hatalı bir şekilde o sınıfa ait olarak etiketlenmesi durumudur. FP değeri yüksek olduğunda modelin yanlış alarm verme oranında artış olur, bu durumda da analizlerde hatalı sonuçlara neden olabilir. Su sınıfına ait olan bir pikselin model tarafından hatalı şekilde müsilağ olarak sınıflandırılması FP'ye örnektir.

FN (false negative), pozitif örneklerin hatalı şekilde negatif olarak sınıflandırılmasıdır. Sınıfa ait olan bir pikselin model tarafından hatalı bir şekilde o sınıfa ait değilmiş gibi etiketlenmesidir. FN değeri yüksek olduğunda model gerçek pozitif örnekleri kaçırmaz ve bu durumda kritik tespitlerde performans kaybına sebep verir. Müsilağ sınıfına ait olan bir pikselin su olarak etiketlenmesi FN'ye örnektir.

Aşağıda bu değerlerden elde edilen, deneysel sonuçlarda ve literatürde yaygın olarak kullanılan performans ölçütleri verilmiştir.

- **Genel Doğruluk (Overall Accuracy - OA)**

Tüm test örnekleri içerisinde doğru sınıflandırılan örnek sayısının, toplam test örneği sayısına oranıdır. Genel sınıflandırma başarısını değerlendirmek için kullanılan temel ölçütlerden biridir.

$$OA = \frac{TP+TN}{P+N} \quad (4.1)$$

- **Ortalama Doğruluk (Average Accuracy - AA)**

Her bir sınıfta elde edilen doğruluk oranlarının aritmetik ortalamasıdır. Özellikle dengesiz veri kümelerinde, örnek sayısı az olan sınıfların başarımını da dikkate alarak daha dengeli bir değerlendirme yapılmasını sağlar. C toplam sınıf sayısını ve i ilgili sınıfın indeksini ifade ediyor olsun. Bu durumda AA aşağıdaki eşitlik ile elde edilir.

$$AA = \frac{1}{C} \sum_{i=1}^C \frac{\text{Doğru sınıflandırılan } i.\text{sınıf örnek sayısı}}{\text{Toplam } i.\text{sınıf örnek sayısı}} \quad (4.2)$$

- **Kesinlik (Precision)**

Kesinlik, model tarafından pozitif olarak sınıflandırılan örneklerin ne kadarının gerçekten pozitif olduğunu gösterir.

$$Precision = \frac{TP}{TP+FP} \quad (4.3)$$

- **Duyarlılık/Hassasiyet (Recall)**

Duyarlılık/Hassasiyet, gerçek pozitif örneklerin ne kadarının model tarafından doğru bir şekilde pozitif olarak sınıflandırıldığını gösterir.

$$Recall = \frac{TP}{TP+FN} \quad (4.4)$$

- **F1 skoru**

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olup iki metrik arasındaki dengeli ölçen bir performans metriğidir.

$$F1 = 2 \cdot \frac{Precision \times Recall}{Precision + Recall} \quad (4.5)$$

- **Doğru Pozitif Oranı (True Positive Rate - TPR)**

TPR, gerçek pozitif örneklerin tüm pozitif örnekler içindeki oranıdır. Modelin, pozitif sınıfa ait örnekleri doğru bir şekilde tespit etme başarısını ölçmektedir.

$$TPR = \frac{TP}{TP+FN} = \frac{TP}{P} \quad (4.6)$$

Yüksek TPR değeri modelin pozitif sınıfı kaçırmadan tespit gerçekleştirdiğini gösterir.

- **Yanlış Pozitif Oranı (False Positive Rate - FPR)**

FPR, gerçek negatif örneklerin tüm negatif örnekler içindeki oranıdır. Modelin yanlış alarm verme eğilimi ölçülmektedir. Düşük bir FPR değeri, modelin negatif sınıfı hatalı bir şekilde pozitif olarak etiketleme olasılığının düşük olduğunu göstermektedir.

$$FPR = \frac{FP}{FP+TN} = \frac{FP}{N} \quad (4.7)$$

- **Doğru Negatif Oranı (True Negative Rate - TNR)**

TNR, gerçek negatif örneklerin tüm negatif örnekler içerisindeki oranıdır. Modelin negatif sınıfı doğru tespit etme başarısını ölçer. Yüksek TNR değeri, modelin negatif sınıfı doğru bir şekilde ayırt edebildiğini gösterir.

$$TNR = \frac{TN}{TN+FP} = \frac{TN}{N} = 1 - FPR \quad (4.8)$$

- **Yanlış Negatif Oranı (False Negative Rate - FNR)**

FNR, Gerçek pozitif örnekler arasında, yanlış negatif olarak sınıflandırılanların oranıdır. Modelin pozitif sınıfı gözden kaçırma eğilimini ölçer. Düşük FNR değeri, modelin pozitif sınıfı gözden kaçırma oranının düşük olduğunu gösterir.

$$FNR = \frac{FN}{TP+FN} = \frac{FN}{P} = 1 - TPR \quad (4.9)$$



5. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu bölümde, hiperspektral görüntüler kullanılarak müsilaj tespiti amacıyla uygulanan sınıflandırma yöntemlerinin deneysel sonuçlarına yer verilmiştir. Çalışma kapsamında, MSS-GF, MSS-MV, CRC, SCCA, JNSC, RJNSC, MSBNSC, WBNSC yöntemlerine ait analizler gerçekleştirilmiştir. Her bir yöntem, Bursa ve İstanbul kıyılarına ait PRISMA hiperspektral görüntüleri üzerinde uygulanmıştır. Farklı parametre ayarları sistematik olarak değerlendirilerek yöntemlerin en yüksek sınıflandırma başarımına ulaşması hedeflenmiştir.

İstanbul ve Bursa müsilaj alanlarına ait hiperspektral görüntülerin alt bölgeleri kullanılmıştır. Bu alt bölgeler, yöntemlerin sınıflandırma sürelerini kısaltmanın yanında daha odaklı analizler yapabilmek için orijinal görüntülerin belirli kesitlerinden oluşturulmuştur. İstanbul ve Bursa veri kümeleri için oluşturulan alt bölgeler 110 x 260 x 234 boyutlarındadır. Başka bir ifadeyle, İstanbul ve Bursa kıyılarına ait 234 farklı dalga boyunda 110 x 260 uzamsal çözünürlükte veri kümeleri kullanılmıştır.


Deneylerde yöntemlerin sınıflandırma başarımı; OA, AA, F-Score gibi performans metrikleri üzerinden değerlendirilmiştir. Ayrıca yöntemlerin farklı eğitim veri oranları, süperpiksel sayıları, pencere boyutları ve parametre değerleri (örneğin; lambda, gamma) gibi etkenler altındaki davranışları analiz edilmiştir.

Aşağıda her yönteme ait en iyi performans değerleri ve bu başarıya ulaşılan parametre kombinasyonları detaylı olarak sunulmuştur. Son bölümde ise tüm yöntemler arasında karşılaştırmalı bir değerlendirme yapılarak en başarılı yaklaşım belirlenmiş ve gelecekteki çalışmalar için önerilerde bulunulmuştur.


5.1 SRC'ler ile Elde Edilen Bulgular

- **Klasik SRC deneyleri ve sonuçları**

Temsile dayalı yöntemler arasında yer alan klasik SRC yöntemi referans amaçlı deneyler ile değerlendirilmiştir. SRC yöntemi test örneklerini sınıfların tümünden oluşan eğitim örnekleri üstünden seyrek lineer kombinasyon şeklinde temsil etmektedir. Temsil hatasını en aza indiren sınıf üzerinden karar verilmektedir.



Şekil 5.1. SRC deneylerinde örnek oranı değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.



Şekil 5.2. SRC deneylerinde örnek oranı değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.

Yapılan deneylerde yüzdelik (percentage) = 0.05, 0.1 ve 0.13 değerleri teste tabii tutulmuştur. Bunlar her sınıf için sırasıyla %5, %10 ve %13 oranında örnek seçildiği anlamına gelmektedir. Şekil 5.1 ve Şekil 5.2’de gösterildiği üzere en yüksek başarımlar İstanbul veri kümesinde %10 ile Bursa veri kümesinde ise %13 ile test edildiğinde gerçekleşmiştir. Bu durum SRC yönteminin İstanbul veri kümesinde az sayıda temsil örneği ile test yapıldığında daha iyi çalıştığını göstermektedir. Bursa veri kümesinde ise örnek sayısı artırıldığında daha iyi sonuçların elde edildiği görülmüştür. Daha yüksek eğitim oranları verildiği durumlarda aşırı uyum (overfitting) problemleri gerçekleşebileceği ön görülmüştür.

- **MSS-GF ve MSS-MV deneyleri ve sonuçları**


Çalışmada, çok ölçekli süperpiksel tabanlı farklı iki yöntem olan MSS-MV (Multiscale Superpixel - Majority Voting) ve MSS-GF (Multiscale Superpixel - Guided Filtering) yöntemleri uygulanmıştır. Patches, Sparsity ve Eğitim Oranı (percentage) parametreleri dikkate alınıp testler gerçekleştirilmiştir. MSS-GF yönteminde hiperspektral veri PCA ile 3 bileşene indirgenerek rehber görüntü elde edilmiştir. Bu rehber görüntü ise kılavuzlu filtre için girdi olarak kullanılmıştır. Böylece filtreleme

esnasında sınıf sınırları korunurken, sınıflandırma sonuçları daha düzgün ve gürültüsüz hale getirilmiştir.


Süperpiksel boyutunu belirleyen patches (3, 5, 7, 9, 11, 13), seyreklik düzeyini belirleyen sparsity (1, 1.1, 1.2) ve eğitim örneği oranını belirleyen percentage (0.1, 0.2, 0.3) parametrelerinin kombinasyonları denenmiş ve her bir kombinasyon için sınıflandırma başarı metrikleri hesaplanmıştır.

Elde edilen sonuçlar karşılaştırıldığında en iyi sonucun literatürdeki diğer çalışmalardaki gibi (Dündar 2019) Sparsity=1 ve Percentage= 0.1 değerleri ile yapılan deneylerde elde edildiği tespit edilmiştir.


Şekil 5.3'te ve Şekil 5.4'te, sparsity=1 ve percentage=0.1 seçilerek yapılan deneylerin sonuçlarında elde edilen OA ve AA değerleri ile Bursa ve İstanbul veri kümeleri için süperpiksel boyutunun etkileri sunulmuştur.




Şekil 5.3. MSS-GF deneylerinde süperpiksel boyut (patches) değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.



Şekil 5.4. MSS-MV deneylerinde süperpiksel boyut (patches) değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.



Şekil 5.5. MSS-GF deneylerinde süperpiksel boyut (patches) değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.



Şekil 5.6. MSS-MV deneylerinde süperpiksel boyut (patches) değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.

İstanbul ve Bursa veri kümeleri üstünde yapılan çalışmalarda; süperpiksel boyutunu belirleyen patches parametresi için 3x3, 5x5, 7x7, 9x9, 11x11, 13x13 değerleri test edilmiştir. 1x1 değeri verildiğinde yöntem klasik CRC olarak sınıflandırma yapmaktadır. Ayrıca patches parametresi için 3, 5, 7, 9, 11 değerlerinden oluşan alt gruplar (patches = [3 5 7 9 11] ve patches = [5 7 9 11]) ile de ölçüm kümeleri oluşturulmuş, bu varyasyonlarla yöntemlerin performansı detaylı biçimde analiz edilmiştir. Deneyler sonucunda her iki veri kümesi de en yüksek sınıflandırma başarısı sparsity:1, percentage:0.1 ve patches:3x3 değerleriyle elde edilmiştir. Şekil 5.3 ve 5.4'te İstanbul deneyleri sonuçları; Şekil 5.5 ve 5.6'te ise Bursa için yapılan deney sonuçları gösterilmiştir. Sonuçlar göz önüne alındığında, İstanbul ve Bursa veri kümeleri için OA ve AA değerlerinde en iyi ölçümler 3x3 patches değerinde elde edilmiştir.


5.2. CRC'ler ile Elde Edilen Bulgular

• Klasik CRC deneyleri ve sonuçları


CRC yöntemi için her sınıftan 30 örnek kullanılmıştır. Böylece sabit bir eğitim kümesi oluşturularak düzenleme parametresi olan λ değeri sırasıyla 0.0001, 0.001, 0,01

6. SONUÇLAR ve ÖNERİLER

ve 0,1 alınarak testler yapılmıştır. Yöntemin kararlılığını dengeleyen λ , hem İstanbul hem de Bursa veri kümeleri üstünde yapılan deneylerde en iyi performansın Şekil 5.7 ve Şekil 5.8’den de görülebileceği üzere $\lambda=0.001$ için elde edilmiştir.



Şekil 5.7. CRC deneylerinde Lambda değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.




Şekil 5.8. CRC deneylerinde Lambda değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.

5.3 NSC'ler ile Elde Edilen Bulgular


- JNSC deneyleri ve sonuçları

Bu çalışmada spektral uzamsal bilgileri kullanım perspektifine sahip JNSC (Joint Nearest Subspace Classifier) yöntemi İstanbul ve Bursa hiperspektral veri kümeleri üstünde test edilmiştir. Bu yöntemde test örnekleri ve her sınıfa ait olan altuzaydaki benzerlikler test örneklerinin altuzaya projeksiyonundan sonra oluşan yeniden yapılandırma hatalarının kareleri üzerinden değerlendirilmiştir. Bu hata her örnekte ℓ_2 normu alınarak hesaplanmıştır. Sınıflar arası karşılaştırma bu toplam hatalar üzerinden yapılmıştır.

Her iki veri kümesinde de en iyi sonuçlar 3x3 ve eğitim başına örnek sayısı 20 iken ölçülmüştür. Pencere boyutu 1x1 alındığında tek pikselde test yapılacak ve JNSC özelliğini kaybedecektir. Çift sayılı pencere boyutlarında ise uzamsal bilgiden yeterince yararlanılamayacağı görülmüştür. Eğitim başına örnek sayısı 20 iken pencere boyutundaki değişimlerin sonuçları Şekil 5.9 ve Şekil 5.10'da gösterilmiştir.



Şekil 5.9. Pencere boyutunda yapılan değişimlere göre Bursa veri kümesinde JNSC sınıflandırma başarımları.



Şekil 5.10. Pencere boyutunda yapılan değişimlere göre İstanbul veri kümesinde JNSC sınıflandırma başarımları.


- **RJNSC deneyleri ve sonuçları**

RJNSC yöntemine dair yapılan deneylerde her iki veri kümesinde de sınıflandırma performansını etkileyen belli parametreler bulunmaktadır. Bunlardan pencere boyutu 3, iterasyon sayısı 20 ve düzenleme parametresi olan $\lambda = 0.01$ değerleri seçilmiştir. Bu değerler daha iyi sonuçlar verdiği için sabit tutularak eğitim verisi olarak her sınıftan 10, 20 ve 30 örnek kullanılarak deneyler yapılmıştır. Deneylerde iki veri kümesinde de en yüksek başarı her sınıf için 20 örnek kullanıldığında elde edilmiştir.


Şekil 5.11’de İstanbul veri kümesinde gerçekleştirilen RJNSC tabanlı sınıflandırmada elde edilen genel ve ortalama doğruluk değerleri sunulmuştur. Pencere boyutu 3, $\lambda = 0.01$ ve maksimum iterasyon 20’de sabit tutularak farklı sınıf başına eğitim örnekleri 10, 20 ve 30 olarak denenmiştir. Elde edilene sonuçlar göstermektedir ki sınıf başına 20 eğitim örneği kullanılması hem OA hem de AA açısından en yüksek başarı elde edilmektedir. Eğitimin yeterli örnekle desteklenmesi sınıflandırmada başarı oranını artırmaktadır.

Şekil 5.12’de ise Bursa veri kümesine ait veri kümesiyle yapılan deneysel sonuçlar yer almaktadır. İstanbul veri kümesinde yer alan aynı parametreler ile yapılan deneylerde sınıf başına 20 eğitim örneği kullanıldığında en iyi sonuçlar elde edilmiştir. Ancak genel

doğruluk değerlerinin biraz daha düşük olması; görüntülerde yapılan sınıf ayrımının spektral benzerlik düzeyinden veya sınıflar arası örtüşmeden kaynaklanıyor olabilir.



Şekil 5.11. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde RJNSC sınıflandırma başarımları.



Şekil 5.12. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde RJNSC sınıflandırma başarımları.

• MSBNSC deneyleri ve sonuçları

Bu bölümde temsile dayalı altuzay tabanlı bir sınıflandırma yöntemi olan MSBNSC algoritması kullanılarak deneyler yapılmıştır. Bu yöntemde uzamsal ve spektral bilgiler birlikte değerlendirilir. İstanbul ve Bursa veri kümeleri üstünde

gerçekleştirilen deneylerde; farklı eğitim örneği sayıları ve farklı süperpiksel boyutları kullanılmıştır. Her deneyde PCA ile boyut indirgeme ve sonrasında süperpiksel tabanlı özellik çıkarımı yapılarak sınıflandırma gerçekleştirilmiştir.


Veri kümelerinin ikisinde de farklı sayılarda eğitim verisi ile yapılan testlerde en yüksek başarımlar 20 eğitim örneği kullanıldığında elde edilmiştir.

Bu çalışma ile birlikte İstanbul ve Bursa hiperspektral görüntülerinin sınıflandırma işlemlerinde görüntülerin her biri yayında belirtilen boyutlar doğrultusunda sırasıyla 350×490 ve 421×571 piksel boyutlarına sahiptir (Toker 2023). Yapılan deneylerde en iyi sonuçlar İstanbul ve Bursa için aşağıdaki 5.1 ve 5.2 numaralı denklemlerde belirtilen süperpiksel değerleri aralıklarında test edilmiş ve test başına 20 eğitim verisi kullanıldığında gerçekleşmiştir.


$$num_{superpixels\ istanbul} = 125 \times \sqrt{2}^k, k = 7, 8, 9, 10, 11, 12, 13 \quad (5.1)$$

$$num_{superpixels\ bursa} = 125 \times \sqrt{2}^k, k = 15, 16, 17, 18, 19 \quad (5.2)$$

Şekil 5.13 ve Şekil 5.14'te Bursa ve İstanbul hiperspektral görüntüleri üzerinde farklı sayıda eğitim verisi ile yapılan deneylerin sonuçları gösterilmiştir.



Şekil 5.13. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde MSBNSC sınıflandırma başarımları.




Şekil 5.14. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde MSBNSC sınıflandırma başarımları.


- **WBNSC deneyleri ve sonuçları**

Bu bölümde WBNSC görüntüler üstünde yapılan sınıflandırma sonuçları verilmiştir. 1x1 pencere boyutunda tek pikselin sınıflandırmaya girmesi; 2x2 pencere boyutunda ise komşulardan yeterinde katkı alınamaması öngörüldüğünden, test başına 20

eğitim verisi ve 3x3, 5x5 ve 7x7 pencere boyutu kullanılmıştır. En iyi sonuçlar her iki veri kümesi için de 3x3 pencere boyutu alındığında elde edilmiştir. WBNSC yöntemi kapsamında test örnekleri ve sınıf altuzayları arasındaki benzerlik ölçümünde CCA kullanılmıştır. Yapılan deneylerin sonuçları Şekil 5.15 ve Şekil 5.16’da verilmiştir.



Şekil 5.15. Sınıf başına eğitim örneklerinde yapılan değişimlere göre İstanbul veri kümesinde WBNSC sınıflandırma başarımları.




Şekil 5.16. Sınıf başına eğitim örneklerinde yapılan değişimlere göre Bursa veri kümesinde WBNSC sınıflandırma başarımları.

- **SCCA deneyleri ve sonuçları**


Bu bölümde tez kapsamında araştırılması planlanan, altuzay benzerliğini ölçmek için CCA yerine SCCA kullanılan yönteme ait deneysel sonuçlar verilmiştir. SCCA

özellikle yüksek boyuta sahip verilerde korelasyonu maksimize eden seyrek temsiller oluşturup sınıflandırma başarısını artırmak hedeflenmektedir. Daha önceki çalışmalarda (Toker 2023) olduğu gibi bu çalışmada da en iyi sonuçların eğitim örnek sayısının 20 olduğu durumda alındığı görülmüştür. Ayrıca, bu tez kapsamında da süperpiksel boyutu için en iyi sonuçlar Bursa veri kümesinde $125x\sqrt{2}^{[12:18]}$, İstanbul veri kümesinde ise $125x\sqrt{2}^{[7:13]}$ değerlerinde elde edilmiştir.

Deneylerde İstanbul ve Bursa veri kümeleri üstünde; sırasıyla görüntü verisi ve sınıf etiketleriyle olan ilişkiyi kontrol eden, seyrekliği düzenleyen parametreler olan cx ve cy değerlerinde değişiklikler yapılarak veri kümeleri üzerindeki etkisi analiz edilmiştir.



Şekil 5.17. SCCA deneylerinde cx ve cy değişimlerinin İstanbul veri kümesi üzerindeki sınıflandırma başarımına etkisi.



Şekil 5.18. SCCA deneylerinde c_x ve c_y değişimlerinin Bursa veri kümesi üzerindeki sınıflandırma başarımına etkisi.

Şekil 5.17'den görüldüğü üzere, İstanbul veri kümesinde $c_x = 0.01$ ve $c_y = 0.2$ değerleri ile test yapıldığında en iyi OA ve AA değerlerinin elde edilmiştir. Şekil 5.18'de gösterilen Bursa veri kümesinde ise $c_x = 0.2$, $c_y = 0.01$ değerinde en iyi OA ve $c_x = 0.1$, $c_y = 0.2$ değerlerini aldığı anda ise en yüksek AA değeri ölçülmüştür.

5.4. Bulguların Karşılaştırmalı Değerlendirmesi

Bu çalışmada test edilen sınıflandırma yöntemleri farklı parametre değerleri altında elde edilen TN, FN, TP, FP, TNR, FPR, F-Score, OA ve AA değerleri bakımından karşılaştırılmıştır. Deneylerde her parametre için 3 kez test yapılmış ve ortalama OA ve AA değerleri önceki başlıklarda ilgili yöntem içinde veriler grafiklerde sunulmuştur. Adil bir karşılaştırma için gösterim tabanlı yöntemlerin parametre araştırmasında en iyi sonucu veren parametreler ile bütün yöntemler bir arada değerlendirilmiştir. İstanbul ve Bursa veri kümeleri üzerinde yapılan bu çalışmalarda yöntemlerin performansı çeşitli metrikler penceresinden karşılaştırmaya tabii tutulmuştur. Çizelge 5.1'de İstanbul verileri üzerinde, Çizelge 5.2'de ise Bursa verileri üzerinde yöntemlerin elde etmiş oldukları sonuçlar tablolastırılmıştır.

Çizelge 5.1. İstanbul veri kümesi için sonuçların karşılaştırmalı tablosu.

Varsayım	Yöntem	TNR	FPR	TPR	FNR	OA(%)	AA(%)
SRC	Klasik SRC	99,88	0,12	74,85	25,15	99,38	87,37
	MSSMV	99,73	0,27	83,63	16,37	98,77	92,31
	MSSGF	99,04	0,96	85,58	14,42	99,42	91,68
CRC	Klasik CRC	90,44	9,56	95,25	4,75	90,52	92,85
NSC	SCCA	99,41	1,02	99,57	0	99,33	99,49
	JNSC	99,42	0,57	94,03	5,96	99,41	96,73
	RJNSC	96,32	3,67	99,21	0,79	96,38	97,77
	WBNSC	98,55	1,45	96,68	3,32	96,68	98,55
	MSBNSC	99,26	0,73	100	0	99,24	99,63

Çizelge 5.2. Bursa veri kümesi için sonuçların karşılaştırmalı tablosu.

Varsayım	Yöntem	TNR	FPR	TPR	FNR	OA(%)	AA(%)
SRC	Klasik SRC	99,6	0,4	71,37	28,63	98,43	85,48
	MSSMV	98,67	1,33	76,37	23,63	97,74	87,52
	MSSGF	99,55	0,45	71,52	28,28	98,40	85,64
CRC	Klasik CRC	91,53	8,47	93,24	6,76	91,55	92,38
NSC	SCCA	94,39	2,83	97,16	5,60	97,1	95,78
	JNSC	95,51	4,49	80,32	19,67	95,26	87,92
	RJNSC	93,07	6,92	94,11	5,89	93,12	93,60
	WBNSC	97,02	2,98	95,35	4,65	95,37	96,18
	MSBNSC	95,99	4,01	97,16	2,83	95,99	96,58

Çizelge 5.1’den de görülebileceği üzere, İstanbul ve Bursa veri kümeleri üzerinde elde edilen deney sonuçları sınıflandırma metotlarının performanslarını TPR, FNR, TNR, FPR, OA ve AA açısından detaylı bir şekilde değerlendirmeye imkan sağlamaktadır.

SRC tabanlı yöntemler incelendiğinde her iki veri kümesinde de yüksek TNR, düşük FPR oranları ile su sınıfına ait pikselleri doğru sınıflandırma açısından başarılı olduğu, TPR değerinin düşük olmasından dolayı müsilaaj piksellerinde aynı başarımda olmayıp tespitte sınırlı kaldığı görülmektedir.

Klasik SRC yöntemi iki veri kümesi üzerinde de yüksek TNR ve düşük FPR oranları ile su piksellerini doğru sınıflandırsa da düşük TPR değeri göstermektedir ki müsilaaj sınıfı piksellerini tespitte sınırlı kalmaktadır.

MSS-MV yöntemi TNR oranını yüksek sonuçlandırarak yanlış pozitif oranı FPR’yi düşük seviyede verse de müsilaaj tespitinde klasik SRC’ye göre daha iyi performans göstermiştir.

MSS-GF her iki veri kümesi üzerinde en yüksek TNR değerlerini elde etmiş ve FPR oranını en düşük seviyeye çekmiştir. Su sınıflarında yanlış alarm oranı düşük olsa da TPR değerinin görece daha düşük olması ve bundan dolayı FNR oranının yüksek olması bu yöntemin müsilaaj tespitine göre en iyi sonuçları vermediğini göstermektedir.

Klasik CRC yöntemi iki veri kümesinde de en düşük TNR oranlarından birine sahip olarak FPR değerinin yüksek çıktığı bir yöntem olmuştur. Su piksellerinde yanlış sınıflandırma yapıldığı müsilaaj tespitinde ise başarılı olduğu görülmektedir.

Çizelgelerde, SCCA olarak verilen MSBNSC varyasyonu olan Sparse CCA ile yapılan deneylerde yüksek TPR ve TNR değerleri ölçülerek hem su hem de müsilaaj sınıfında dengeli bir başarı görülmektedir. Düşük FNR ve FPR değerleri yöntemin yanlış sınıflandırmaları en aza indirdiğini göstermektedir. CCA kullanılan çalışmalara göre daha az etkili olduğu deneyler sonucunda ortaya çıksa da, daha homojen ve çok sınıflı dağılımların yer aldığı görüntülerde daha iyi sonuçlar vermesi beklenmektedir.


JNSC yönteminde ise İstanbul veri kümesinde yüksek TPR değeri sağlanarak müsilaaj tespitinde güçlü bir performans sergilenmiş, düşük FPR ile su piksellerinde hatalı tespitler düşük seviyede tutulmuştur.

RJNSC yöntemi yüksek TPR ile müsilaaj tespitinde başarı olmuş görece düşük TNR ve yüksek FPR değerleri ile su sınıfında hatalı tespitler diğer bazı yöntemlere kıyasla daha fazladır.


WBNSC, TPR ve TNR değeri bazında dengeli bir sonuç elde etmiş ve düşük FPR oranı ile su sınıfındaki yanlış alarm oranını minimuma indirmiştir.

MSBNSC yöntemi iki veri kümesinde de en yüksek AA değerini sağlamış müsilaaj tespitinde %100 TPR değeri ile öne çıkmıştır. Yüksek TNR oranı ile su sınıfında da doğruluğu maksimuma getirmiş olan MSBNSC yöntemi düşük FNR ve FPR değerleri ile müsilaaj ve su sınıflarında yüksek güvenilirlik sunmuştur.


Sınıflandırma haritaları incelendiğinde; Şekil 5.20’de sınıflandırma haritası verilen klasik SRC yöntemi su bölgelerinin tespitini doğru yapsa da ince ve dağınık müsilaj alanlarında eksiklikler göstermiştir. Özellikle Bursa veri kümesi üzerinde bazı müsilaj kümelerinin tespiti yapılamamış İstanbul veri kümesinde ise kenar alanlarda parçalı tespitler yapılmıştır. Şekil 5.21’de MSS-MV ve MSS-GF metotları klasik SRC’ye kıyasla daha bütün müsilaj bölgeleri üretmiştir. İstanbul veri kümesinde kenar çizgileri daha net oluşmuş ve Bursa veri kümesinde müsilaj alanları daha homojen bir şekilde tespit edilmiştir. Klasik CRC Şekil 5.22’de müsilaj alanlarını yoğun bir şekilde tespit etmiş fakat yüksek oranda yanlış pozitif tespit etmiştir. SCCA analizi yapılarak geliştirilen yöntemde müsilaj ve su bölgeleri arasında Şekil 5.23’te de görüldüğü üzere dengeli bir ayırım yapıldığı farke edilmektedir. JNSC yöntemi İstanbul veri kümesi üzerinde başarılı müsilaj tespiti yaparken aynı performansı Bursa veri kümesinde gösterememiştir. RJNSC Şekil 5.25’te görüldüğü üzere yüksek TPR ve düşük FNR değerleri ile detayların bütünlüğünü koruduğu görülmüştür. WBNSC su bölgelerinde en başarılı korumaya sahip yöntemlerden biridir. MBNSC yöntemi bazı su sınıfı pikselleri müsilaj olarak etiketlese de müsilaj sınıfı tespitinde başarılı olmuştur.




Şekil 5.19. Bursa ve İstanbul veri kümeleri temel doğruluk haritaları.




Şekil 5.20. SRC yönteminde elde edilen sınıflandırma haritaları.




Şekil 5.21. MSS-GF ve MSS-MV yöntemlerinde elde edilen sınıflandırma haritaları.



Şekil 5.22. CRC yönteminde elde edilen sınıflandırma haritaları.




Şekil 5.23. SCCA yönteminde elde edilen sınıflandırma haritaları.




Şekil 5.24. JNSC yönteminde elde edilen sınıflandırma haritaları.

Bursa RJNSC Sınıflandırma Haritası




İstanbul RJNSC Sınıflandırma Haritası




Şekil 5.25. RJNSC yönteminde elde edilen sınıflandırma haritaları.

Bursa WBNSC Sınıflandırma Haritası




İstanbul WBNSC Sınıflandırma Haritası




Şekil 5.26. WBNSC yönteminde elde edilen sınıflandırma haritaları.

Bursa MSBNSC Sınıflandırma Haritası



İstanbul MSBNSC Sınıflandırma Haritası



Şekil 5.27. MSBNSC yönteminde elde edilen sınıflandırma haritaları.

6. SONUÇLAR ve ÖNERİLER

Bu tez çalışmasında PRISMA uydusundan yararlanılarak elde edilen hiperspektral görüntüler ile Marmara Denizi'nde ortaya çıkan müsilaj oluşumlarının tespiti hedeflenmiştir. Bu doğrultuda, çeşitli temsile dayalı sınıflandırma yöntemleri üzerinde kapsamlı deneyler gerçekleştirilmiş ve yöntemler etkilendikleri parametreler üzerinden ayrıntılı bir şekilde karşılaştırılmıştır. Karşılaştırmalarda, genel doğruluk ve ortalama doğruluk oranlarının yanı sıra hassasiyet, kesinlik, F1 skoru gibi metrikler kullanılmıştır. Bunlarla birlikte, görsel olarak yöntemlerin ürettiği haritalar verilerin temel doğrulukları ile karşılaştırılmıştır.

Temsile dayalı sınıflandırma yöntemlerinin farklı varyasyonları üzerinden elde edilen bulgular, NSC tabanlı yaklaşımların genel olarak daha yüksek performans

sergilediğini ortaya koymuştur. Özellikle, altuzay temelli temsili sınıf içi varyasyonları iyi modellemesi ve sınıf bazlı izdüşüm yapısının, hiperspektral verideki spektral benzerlikleri etkin bir şekilde değerlendirmesi, NSC tabanlı yöntemlerin başarısını artırmıştır. Literatürde de öne çıkan MSBNSC yönteminin her iki veri kümesinde de üstün performans sergileyebildiğini ortaya koymuştur. MSBNSC, İstanbul veri kümesi üzerinde %99.24 OA ve %99,63 AA değerleri ile diğer yöntemler arasında en yüksek doğruluk oranlarına sahip olmuştur. Bursa veri kümesinde ise %95,99 OA ve %96,58 AA değerleri ile müsila sınıfının belirgin yapılarının doğru bir şekilde tespit edildiği görülmüştür. Ayrıca, FNR değerinin sıfıra yakın olması müsila sınıfını yüksek hassasiyetle ayırt edebildiğini ve pozitif sınıfı gözden kaçırma olasılığının son derece düşük olduğunu göstermektedir.

Bulgular ayrıca, çok ölçekli süperpiksel segmentasyonunun hem spektral hem de uzamsal bilginin daha dengeli kullanılmasını sağladığını ve sınıflar arasındaki ayırt ediciliği artırdığını göstermektedir. MSBNSC yönteminin her iki veri kümesinde de yüksek OA ve AA değerleri elde etmesi, çok ölçekli yapının müsila gibi karmaşık ve heterojen yapıya sahip sınıfların tespitinde etkili olduğunu doğrulamaktadır.

Bu çalışmada elde edilen bulgular müsila gibi çevresel felaketlerin uzaktan algılama yöntemleriyle tespit edilmesinde MSBNSC yönteminin etkili bir çözüm sunabileceğini göstermektedir.

Bununla birlikte çalışmalarda kullanılan eğitim örnek sayıları, pencere boyutları, süperpiksel parametreleri gibi ayarlar veri kümelerine ve yöntemlerde yapılan deneylere göre özel olarak seçilmiş ve tüm veri kümelerinde sabit tutulmamıştır. Bundan dolayı benzer uygulamalarda yöntemler test edilirken veri özelliklerine göre yeniden eniyileme yapılabilir.

Tez çalışmasında, CCA yerine alternatif olarak SCCA'nın kullanılabileceği değerlendirilmiştir. SCCA'nın özellikle yüksek boyutlu ve gürültülü verilerde gereksiz değişkenlerin etkisini azaltarak sınıflandırma performansını artırma potansiyeline sahip olduğu bilinmektedir. Ancak elde edilen deneysel sonuçlar, bu çalışmada kullanılan veri kümelerinde SCCA'nın CCA tabanlı yaklaşımın gerisinde kaldığını göstermiştir. Bu

durumun nedenleri arasında, kullanılan veri kümelerinin boyutları, sınıflar arası spektral farklılıkların belirginliği ve seyrekleştirme sürecinde bazı ayırt edici bileşenlerin de elenmesi yer almaktadır. Bu gibi parametreler dikkate alındığında, SCCA teorik olarak avantajlı olsa da mevcut hiperspektral veri yapısı ve parametre ayarları altında CCA kadar yüksek performans sergileyememiştir.

Gelecek çalışmalar kapsamında, çok ölçekli süperpiksel segmentasyonunun sağladığı avantajlar göz önünde bulundurularak, adaptif ölçek seçim mekanizmalarının geliştirilmesi hem spektral hem de uzamsal bilginin daha etkin şekilde kullanılmasına katkı sağlayabilir. Ayrıca, bulguların genellenebilirliğini test etmek amacıyla, farklı coğrafi bölgelerden ve farklı sensörlerden elde edilmiş hiperspektral veriler üzerinde benzer analizlerin yürütülmesi de önerilmektedir.

KAYNAKLAR

- Abacı, B., Dede, M., Yüksel, S. E. ve Yılmaz, M. 2022. Mucilage detection from hyperspectral and multispectral satellite data, Remote Sensing of the Ocean, Sea Ice, Coastal Waters, and Large Water Regions 2022, Proceedings of SPIE, Vol. 12094, 31 Mayıs, 120940E, SPIE, Strasbourg, Fransa.
- Acar, E., Yılmaz, M. S., Ekinci, R. ve Hu, C. 2022. Detection of marine mucilage and floating matters using Sentinel-2 MSI, OLCI, MODIS and DESIS data, 11th International Conference on Agro-Geoinformatics, 18–21 Temmuz, IEEE, Bildiri Özetleri Kitabı, 1–6, Shenzhen, Çin.
- Acar, U., Yılmaz, O. S., Çelen, M., Ateş, A. M., Gülgen, F. ve Balık Şanlı, F. 2021. Determination of mucilage in the Sea of Marmara using remote sensing techniques with Google Earth Engine. International Journal of Engineering and Geosciences, 8(4), 423–434.
- Acar, E., Bakiş, E. ve Yılmaz, M. 2023. Automatic Recognition of Illegal Substations by Employing Logit-Boost Algorithm and LSTM with the Help of Different Landsat-8 OLI Image Spectral Band Parameters: A Case Study in Sason, Turkey. IEEE Access, 11, 112293–112306.
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. ve Süsstrunk, S. 2012. SLIC superpixels compared to state-of-the-art superpixel methods. IEEE Transactions on Pattern Analysis and Machine Intelligence, 34(11), 2274–2282.
- Acosta I. C. C., Khodadadzadeh M., Tusa L., Ghamisi P. and Gloaguen R. 2019. A machine learning framework for drill-core mineral mapping using hyperspectral and high-resolution mineralogical data fusion. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(12):4829–4842.
- Akoğuz, A., Pınar, S. K., Özdemir, A., Bağış, S., Yücel, M., & Kartal, M., 2013. Remote sensing data fusion algorithms with parallel computing, 2013 6th International Conference on Recent Advances in Space Technologies (RAST), 12-14 Haziran 2013, IEEE, İstanbul, Türkiye.
- Akyürek, H. A. 2018. Hiperspektral Görüntülerin Sınıflandırılmasında Uzamsal-Spektral Yaklaşımlar. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 20, Konya.
- Anonim, 2021. Web Sitesi: <https://www.egesis.com.tr>, Erişim Tarihi: 09.08.2025.
- Anonim, 2024. Web Sitesi: <https://tr.wikipedia.org/wiki/M%C3%BCsilaj>, Erişim Tarihi: 04.08.2025.
- Atay Mühendislik, 2023. Web Sitesi: <https://www.ataymuhendislik.com>, Erişim Tarihi: 09.08.2025.

- Bilgin, G. 2009. Hiperpektral Görüntülerin Eğiticisiz Bölütlenmesi. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, 127, İstanbul.
- Bioucas-Dias J. M., Plaza A., Dobigeon N., Parente M., Du Q., Gader P. and Chanussot J. 2012. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):354–379.
- Bioucas-Dias, J. M., Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N. ve Chanussot, J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2), 6–36.
- Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16.
- Bo, C., Lu, H. ve Wang, D. 2016. Robust joint nearest subspace for hyperspectral image classification. *Remote Sensing Letters*, 7(10), 915–924.C.
- Brown, R. 2016. Mangrove monitoring using airborne VNIR in the Espiritu Santo Bay area, Central Texas coast, General Land Office, State of Texas
- Cai, J., Xu, W., & Zhang, X. 2013. Joint sparse representation for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1), 482–497.
- Chen, Y., Nasrabadi, N. M. ve Tran, T. D. 2011. Hyperspectral image classification using dictionary-based sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10), 3973–3985.
- Chen, Y., Jiang, H., Li, C., Jia, X., & Ghamisi, P. 2016. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 54(10), 6232-6251.
- Çamoğlu, G., Demirel, K., Kahriman, F., Akcal, A., Nar, H., Boran, A., Eroğlu, İ. ve Genç, L. 2021. Discrimination of water stress in pepper using thermography and leaf turgor pressure probe techniques. *Scientia Horticulturae*, 287, 110262.
- Çeşmeci, D. ve Güllü, M. K. 2009. Phase correlation based hyperspectral image classification using different number of multiple class representatives, 17. *IEEE Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU 2009)*, 09-11 Nisan, 2165-0608, Antalya, Türkiye.
- Devi G. K., Ganasri B. and Dwarakish G. 2015. Applications of remote sensing in satellite oceanography: A review, *Aquatic Procedia*, 2015. ISSN 2214-241X. *International Conference on Water Resources, Coastal and Ocean Engineering*, 4:579–584, India.

- Dong, G., Kuang, G., Wang, N., Zhao, L. ve Lu, J. 2015. SAR target recognition via joint sparse representation of monogenic signal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7), 3316–3328.
- Duman, M., Küçüksezgin, F., Eronat, A. H., Talas, E., İlhan, T. ve Aydın, Ş. 2022. Combining single and complex indices of pollution with grain size trend analysis of surficial sediments in Edremit Gulf, western Turkey. *Environmental Science and Pollution Research*, 29(37), 55609–55629.
- Dündar, T. ve İnce, T. 2019. Sparse representation-based hyperspectral image classification using multiscale superpixels and guided filter. *IEEE Geoscience and Remote Sensing Letters*, 16(2), 246–250.
- Dündar, T. 2024. Uzaktan algılanan hiperspektral görüntülerin iyileştirilmesi ve sınıflandırılması için makine öğrenmesi algoritmalarının geliştirilmesi. Doktora Tezi, Gaziantep Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Gaziantep.
- Ertürk, A. ve Erten, E. 2023. Unmixing of pollution-associated sea snail in the near surface after its outbreak in the Sea of Marmara using hyperspectral PRISMA data. *IEEE Geoscience and Remote Sensing Letters*, 20, 1–5.
- Esi, Ç., Ertürk, A. ve Karoui, M. S. 2023. Unmixing with spectral variability for marine mucilage analysis, 2023 WHISPERS Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 5-8 Eylül, IEEE, 1–5, Atina, Yunanistan.
- Esi, Ç., Ertürk, A. ve Erten, E. 2024. Nonnegative matrix factorization-based environmental monitoring of marine mucilage. *International Journal of Remote Sensing*, 45(11), 3764–3788.
- Hammond, W. C., Blewitt, G., Kreemer, C., Sanli, D. U., Bakici, S. 2023. Unique insight into the February 6 2023 Türkiye earthquake doublet from GNSS geodesy, San Francisco, CA
- Hardoon, D. R., Szedmak, S. ve Shawe-Taylor, J. 2004. Canonical correlation analysis: An overview with application to learning methods. *Neural Computation*, 16(12), 2639–2664.
- He, K., Sun, J. ve Tang, X. 2013. Guided image filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(6), 1397-1409.
- Hughes, G. 1968. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1), 55–63.
- Irmak, H., Akar G. B., and Yuksel, S. E. 2018. A MAP-based approach for hyper spectral imagery super-resolution. *IEEE Transactions on Image Processing*, 27(6):2942–2951.

- Kavzoğlu, T. ve Goral, M. 2022. Google Earth Engine for Monitoring Marine Mucilage: Izmit Bay in Spring 2021. *Hydrology*, 9(8), 135.
- Kavzoğlu, T., Yılmaz, E. Ö., Çölkesen, İ., Sefercik, U. G. ve Gazioğlu, C. 2023. Detection and Monitoring of Mucilage Formations using Pixel-Based Convolutional Neural Networks: The Case Study of Izmit Gulf, Turkey, In: *Mucilage Problem in the Sea of Marmara*. Albay, M. (ed.), Istanbul University Press, s. 234-247, İstanbul, Türkiye.
- Keleşoğlu, G. 2022. Assessing Sea-Snot Accumulation using Spectral Mixture Analysis of Hyperspectral PRISMA Data, 2022 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2022), 17–22 Temmuz, Kuala Lumpur, Bildiri Özetleri Kitabı, 1616-1617, Malezya.
- Kocakuşaklar, B., Alptekin, B. ve Kahraman, N. 2017. The effect of pre-processing steps on geometric based hyperspectral unmixing algorithms, 25. IEEE Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU 2017), 15-18 Mayıs, Antalya, Türkiye.
- Koncagül, M., Erdem Dülger, N. ve Yinanç, A. 2022. Dünyada ve Marmara Denizi'nde Müsilaj Oluşumu ve Etkileri. *European Journal of Engineering and Applied Sciences*, 5(2), 73-79.
- Küçük, S., Abacı, B., Dede, M., Yüksel, S. E. E. ve Yılmaz, M. 2022. Analysis and Detection of Mucilage Bloom from Multispectral Satellite Images, 30th Signal Processing and Communications Applications Conference (SIU-2022), 1–4, IEEE, Ankara, Türkiye.
- Li, S., Ni, L., Jia, X., Gao, L., Zhang, B. ve Peng, M. 2016. Multi-scale superpixel spectral-spatial classification of hyperspectral images. *International Journal of Remote Sensing*, 37(20), 4905–4922.
- Li, S., Ni, L., Jia, X., Gao, L., Zhang, B. ve Peng, M. 2016. Multi-scale superpixel spectral-spatial classification of hyperspectral images. *International Journal of Remote Sensing*, 37(20), 4905–4922.
- Li, W., Du, Q. ve Zhang, L. 2019. Hyperspectral image classification based on deep learning. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 6690–6709.
- Liu Y., Pu H., and Sun D.-W. 2017. Hyperspectral imaging technique for evaluating food quality and safety during various processes: A review of recent applications. *Trends in Food Science & Technology*, 69:25–35.
- Loizzo, R., Guarini, R., Longo, F., Scopa, T., Formaro, R., Facchinetti, C. ve Varacalli, G. 2018. Prisma: The Italian hyperspectral mission. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 175–178, Valencia, Spain.

- Lu, D. ve Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870.
- Melgani, F. ve Bruzzone, L. 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778–1790.
- Öztürk, i., Yanalak, M., Arslan, Ö., Koyuncu, İ., Dilekgürgen, E., Erşahin, M. E., Türken, T. (2021) Marmara Denizi'nde Deniz Salyası Sorunu ile İlgili Görüş ve Öneriler(Rapor), İstanbul, İstanbul Teknik Üniversitesi, 73 s.
- Sanver, U. ve Yesildirek, A. 2023. An autonomous marine mucilage monitoring system. *Sustainability*, 15(4), 3340.
- Şerifoğlu Yılmaz, Ç., Yılmaz, V. ve Güngör, O. 2021. Çok bantlı görüntülerde pan-keskinleştirme üzerine bir inceleme. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(4), 1340-1357.
- Shaik, R. U., Periasamy, S. ve Zeng, W. 2023. Potential assessment of PRISMA hyperspectral imagery for remote sensing applications. *Remote Sensing*, 15(5), 1378.
- Shivendra, A. 2021. Web Sitesi: <https://shivendra-b180717ee.medium.com>, Erişim Tarihi: 04.08.2025.
- Shu, T., Zhang, B. ve Tang, Y. Y. 2019. Multi-view classification via a fast and effective multi-view nearest-subspace classifier. *IEEE Access*, 7, 49669–49679.
- Sığircı, İ. O., Albayrak, A. ve Bilgin, G. 2022. Detection of mitotic cells in breast cancer histopathological images using deep versus handcrafted features. *Multimedia Tools and Applications*, 81, 13179–13202.
- Sun, Y., Liu, X., Zhao, Z., Zhang, Y. ve Wang, Y. 2022. A weighted block-wise nearest subspace classifier for HSI. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 12109–12120.
- Sunar, F., Dervişoğlu, A., Yağmur, N., Çolak, E., Kuzyaka, E. ve Mutlu, S. 2022. How efficient can Sentinel-2 data help spatial mapping of mucilage event in the Marmara Sea?, *ISPRS Archives – XLIII-B3-2022, ISPRS Congress 2022*, 30 Mayıs, 181–187, Nice, Fransa.
- Tang, Y., Li, X., Xu, Y., Liu, Y., Wang, J. ve Liu, C. 2014. Hyperspectral image classification using sparse representation-based classifier. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2472-2481.
- Toker, K. G. 2023. Hiperspektral görüntüler için spektral-uzamsal en yakın altuzay sınıflandırıcıları. Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı, 182, Ankara.

- Turan, D. E., Aptoula, E., Ertürk, A. ve Taşkın, G. 2023. Interpreting hyperspectral remote sensing image classification methods via explainable artificial intelligence, IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2023), 16–21 Temmuz, 5950–5953, Pasadena, Kaliforniya, ABD.
- Tuzcu Kokal, A., İsmailoğlu, İ., Musaoglu, N. ve Tanik, A. 2023. Detection of surface temperature anomaly of the Sea of Marmara. *Advances in Space Research*, 71(7), 2996–3004.
- Witten, D. M. ve Tibshirani, R. 2009. Extensions of sparse canonical correlation analysis with applications to genomic data. *Statistical Applications in Genetics and Molecular Biology*, 8(1).
- Wright, J., Yang, A. Y., Ganesh, A., Sastry, S. S. ve Ma, Y. 2009. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2), 210–227.
- Yang, X., Zhao, M., Gao, T., Chen, J. ve Zhang, J. 2022. Multiscale-superpixel-based SparseCEM for hyperspectral target detection. *IEEE Geoscience and Remote Sensing Letters*, 19, 1–5.
- Yetilmezsoy, K. 2021. "Marmara'nın Gözyaşı: Deniz Müsilajı,". 2021. In *Marmara Denizi'nin Ekolojisi*, Ankara: Türkiye Bilimler Akademisi (TÜBA), pp.155-162.
- Yuksel S., Dubroca T., Hummel R. and Gader P. 2013. Differential reflection spectroscopy: A novel method for explosive detection. *Acta Physica Polonica A*, 123(2):263–264.
- Yurdakul, M. M. 2024. Örnek segmentasyonu ile uydu görüntülerinden deniz müsilajı tespiti / Marine mucilage detection from satellite images with instance segmentation. Yüksek lisans tezi, İstanbul Gelişim Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, İstanbul
- Zhang, S., Li, S., Fu, W. ve Fang, L. 2017. Multiscale Superpixel-Based Sparse Representation for Hyperspectral Image Classification. *Remote Sensing*, 9(2), 139.
- Tan, SY. 2017. Developments in Hyperspectral Sensing. Pelton, J., Madry, S., Camacho-Lara, S. (eds) *Handbook of Satellite Applications*. Springer, Cham.
- TS2 Tech, 2023. Web Sitesi: <https://www.ts2.space>, Erişim Tarihi: 09.08.2025.
- USGS, t.y. Web Sitesi: <https://www.usgs.gov>, Erişim Tarihi: 09.08.2025.
- Vikipedi, t.y. Web Sitesi <https://tr.wikipedia.org/>, Erişim Tarihi: 09.08.2025.
- Zhong, Y. and Zhang, L. 2012. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(3):894–909.