

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**HİPERSPEKTRAL BANT GÖRÜNTÜLERİ KULLANILARAK FÜZE İZİ
TESPİTİ VE ARKA PLANDAN AYRILMASI**

Koray YILMAZ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

HİPERSPEKTRAL BANT GÖRÜNTÜLERİ KULLANILARAK FÜZE İZİ TESPİTİ VE ARKA PLANDAN AYRILMASI

Koray YILMAZ

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendislik Anabilim Dalı

Danışman: Prof. Dr. Ziya TELATAR

Bu tezde farklı koşullarda alınan 194 adet hiperspektral görüntü kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma için görüntülerde bulunan bulut, yeryüzü, füze, füze egzoz dumanı ve gökyüzü verileri kullanılmıştır. İlk olarak verilere normalizasyon işlemi uygulanmış ve tüm veriler 0 – 1 aralığına ölçeklendirilmiştir. Sonrasında her sınıf için farklı sayılarda veriler toplanarak referans veri seti oluşturulmuştur. Referans veri setine temel bileşenler analizi (PCA), bağımsız bileşenler analizi (ICA), maksimum gürültü oranı (MNF) ve sinir ağları (NN) yöntemleri kullanılarak boyut azaltımı işlemi uygulanmıştır. Boyutu azaltılan verilere Kırmızı/Mavi uç (Red/Blue Spike) oranı sınıflandırma doğruluğunu artırmak için öznitelik olarak eklenmiştir. Boyutu azaltılan verilerin bir kısmı SVM ve AdaBoost sınıflandırıcılarının eğitiminde kullanılmıştır. Eğitim aşamasında kullanılmayan veriler ise sınıflandırıcıların test aşamasında girdi olarak verilmiştir. Eğitilen sınıflandırıcılar kullanılarak 194 adet hiperspektral görüntü sınıflandırılmıştır. Sınıflandırma aşamasında her sınıfa bir etiket değeri atanmış ve bu etiket değerine göre pikseller renklendirilmiştir. Elde edilen renklendirilmiş görüntüler hiperspektral görüntüler kullanılarak oluşturulan radyometrik görüntüler ile görsel olarak kıyaslanmıştır. Sınıflandırma algoritmalarının sonuçları alıcı işletim karakteristiği eğrileri (ROC curve), eğri altındaki alan (AUC) ve hata matrisleri gibi yöntemlere göre değerlendirilmiştir. Bu yöntem ile elde edilen incelemeler umut verici sonuçlar vermiştir.

Haziran 2022, 133 sayfa

Anahtar Kelimeler: Hiperspektral görüntüleme, Kızılötesi, Boyut azaltımı, Sınıflandırma, Füze izi, Elektronik harp

ABSTRACT

Master Thesis

DETECTION OF MISSILE SIGNATURE AND SEPERATION FROM BACKGROUND USING HYPERSPECTRAL BAND IMAGES

Koray YILMAZ

Ankara University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Ziya TELATAR

In this thesis, classification are performed using 194 hyperspectral images taken on different days. For classification, cloud, ground, missile, plume and sky data in the images are used. Firstly, normalization process was applied to the data and all data were scaled to the range of 0 - 1. Afterwards, different numbers of data are collected for each class and a reference data set is created. The dimension reduction process is applied to the reference data set by using PCA, ICA, MNF and NN methods. The Red/Blue spike ratio is added as a feature to the reduced size data to increase the classification accuracy. Some of the reduced size data is used in the training of SVM and Adaboost classifiers. The data that is not used in the training is given as input in the testing phase of the classifiers. 194 hyperspectral images are classified using the trained classifiers. During classification, a label is assigned to each class and pixels are colored according to this label. The obtained colored images are visually compared with the radiometric images created using hyperspectral images. The results of the classification algorithms are evaluated according to methods such as ROC, AUC and confusion matrices. The studies obtain with this method have yielded promising results.

June 2022, 133 pages

Key Words: Hyperspectral imaging, Infrared, Dimension reduction, Classification, Missile signature, Electronic warfare

ÖNSÖZ ve TEŞEKKÜR

Tez boyunca akademik bilgi ve tecrübelerinden fazlasıyla yararlandığım, akademik anlamda beni sürekli destekleyen ve emeğini esirgemeyen değerli hocam Prof. Dr. Ziya TELATAR'a,

Yüksek lisans çalışmam sırasında bana maddi ve manevi destek olan canım annem Beyhan YILMAZ'a, babam Mehmet Akif YILMAZ'a ve kardeşim Berkay Buğra YILMAZ'a

Çalışanlarının kişisel ve akademik gelişimine verdiği destekten ötürü TÜBİTAK BİLGEM İLTAREN'e, değerli takım arkadaşlarıma, çalışma boyunca bana güç veren ve daima destekleyen Mehmet Cihan ŞAHİNGİL, Gülay ÖZŞAHİN ve Zafer SOYBAŞ'a, sonsuz minnet ve teşekkürlerimi sunarım.

Koray YILMAZ,
Ankara, Haziran 2022

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ ve TEŞEKKÜR.....	iv
SİMGELER DİZİNİ	vii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Elektromanyetik Spektrum.....	5
1.3 Kızılötesi Bölge	6
1.4 Kızılötesi Güdümlü Füzeler	7
1.4.1 KÖ güdümlü füzelerin tarihçesi	7
1.4.2 KÖ füze bölümleri ve görevleri.....	10
1.4.2.1 Kubbe	10
1.4.2.2 Optikler	11
1.4.2.3 Kıyıcılar.....	11
1.4.2.4 Detektör.....	13
1.4.2.5 Soğutma.....	14
1.4.2.6 Kanat ve kanatçıklar	14
1.4.2.7 Roket motoru.....	15
1.4.2.8 Tapa – Harp başlığı.....	17
1.5 Füze İkaz Sistemleri.....	17
1.5.1 UV detektör kullanan füze ikaz sistemleri.....	17
1.5.2 KÖ detektör kullanan füze ikaz sistemleri	18
1.5.3 UV ve KÖ detektör kullanan füze ikaz sistemleri arasındaki farklar	19
1.6 Hiperspektral Görüntüleme	21
2 . LİTERATÜR ÖZETİ	23
3. MATERYAL VE YÖNTEM.....	30
3.1 Veri Seti	30
3.2 Hiperspektral Verilerin İncelenmesi	32
3.2.1 Sınıflandırma modellerinin eğitim safhası.....	33

3.2.1.1 Normalizasyon işlemi	34
3.2.1.2 Piksel örnekleme	35
3.2.1.3 Boyut azaltımı	35
3.2.1.3.1 Temel bileşen analizi (PCA)	38
3.2.1.3.2 Bağımsız bileşenler analizi (ICA)	40
3.2.1.3.3 Maksimum gürültü oranı (MNF)	44
3.2.1.3.4 Sinir ağları (NN)	48
3.2.1.4 Kırmızı/Mavi uç (Red/Blue spike) oranı	52
3.2.1.5 Sınıflandırma algoritmalarının eğitilmesi	52
3.2.1.5.1 Destek vektör makinaları (SVM) algoritması	53
3.2.1.5.2 AdaBoost algoritması	55
3.2.2 Sınıflandırma adımlarının sonuçları	61
3.2.2.1 Destek vektör makinaları algoritmasının sonuçları	62
3.2.2.2 AdaBoost algoritmasının sonuçları	89
4. TARTIŞMA VE SONUÇ	117
5. GELECEKTE YAPILABİLECEK ÇALIŞMALAR	128
KAYNAKLAR	129
ÖZGEÇMİŞ	133

SİMGELER DİZİNİ

λ	Dalga Boyu
ν	Dalga Frekansı
c	Işık Hızı
h	Plank Sabiti
K	Kelvin

Kısaltmalar

AAM	Havadan Havaya Füze (Air to Air Missile)
ASM	Havadan Karaya Füze (Air to Surface Missile)
AUC	Eğri Altındaki Alan (Area Under Curve)
CCD	Yük Bağlantılı Cihaz (Charge Coupled Device)
CCM	Karşı Karşı Tedbir (Counter – Counter Measure)
DIRCM	Yönlendirilebilir Kızılötesi Karşı Tedbir (Directional Infrared Countermeasure)
EPFs	Kenar Koruma Özellikleri (Edge Preserving Features)
FİS	Füze İkaz Sistemi (Missile Warning System)
FPA	Odak Düzlem Dizini (Focal Plane Array)
HS	Hiperspektral (Hyperspectral)
ICA	Bağımsız Bileşenler Analizi (Independent Component Analysis)
IFRF	Görüntü Birleştirme ve Özyinelemeli Filtreleme (Image Fusion and Recursive Filtering)
LWIR	Uzun Dalga Kızılötesi Bölge (Longwave Infrared Region)
km	kilometre

KÖ	Kızılötesi (Infrared)
MANPADS	Taşınabilir Hava Savunma Sistemi (Man-portable air-defense system)
MNF	Maksimum Gürültü Oranı (Maximum Noise Fraction)
MWIR	Orta Dalga Kızılötesi Bölge (Midwave Infrared Region)
NN	Sinir Ağları (Neural Network)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
RF	Rastgele Ormanlar (Random Forest)
ROC	Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SAE	Yığın Otomatik Kodlayıcı (Stacked Autoencoder)
SAM	Karadan Havaya Füze (Surface to Air Missile)
SNR	Sinyal Gürültü Oranı (Signal to Noise Ratio)
SSM	Karadan Karaya Füze (Surface to Surface Missile)
SVM	Destek Vektör Makineleri (Support Vector Machine)
SWIR	Kısa Dalga Kızılötesi Bölge (Shortwave Infrared Region)
UV	Ultraviyole (Ultraviolet)

ŞEKİLER DİZİNİ

Şekil 1.1 Bir savaş uçağının 3-5µm dalga bandı görüntüsü örneği	2
Şekil 1.2 2009 – 2012 ve 2013 – 2016 Yılları Arasında HS Veriler Üzerine Yapılan Çalışmaların Oranları	3
Şekil 1.3 Elektromanyetik Spektrum	5
Şekil 1.4 KÖ Füze Bölümleri	10
Şekil 1.5 Yarım Küre Şeklinde Kubbe	11
Şekil 1.6 Dönü Taramalı Kıyıcı	12
Şekil 1.7 Koni Taramalı Kıyıcı	13
Şekil 1.8 Açılır Kanatlar ve Katlanır Kanatçıklar	14
Şekil 1.9 Roket Motoru	15
Şekil 1.10 a) Gökyüzü Spektral Yoğunluk Değeri b) Bulut Spektral Yoğunluk Değeri c) İki Farklı Tür Füze Egzoz Dumanı için Spektral Yoğunluk Değeri	16
Şekil 1.11 Güneş Körü Bölgede Alınan Görüntü Örneği a) güneşli, ~2 km b) bulutlu, ~2km	18
Şekil 1.12 (a) Hiperspektral Data küp Örneği, (b) Bir Piksele ait Spektral İmza	22
Şekil 3.1 Hiperspektral Verileri Oluşturan 41 Bandın Elektromanyetik Spektrumdaki Aralıkları	31
Şekil 3.2 Sınıflandırma modellerinin eğitimi için kullanılan metodoloji	33
Şekil 3.3 Farklı sayılarda öznitelikler için füze verilerinin sınıflandırma doğruluğu	37
Şekil 3.4 Öznitelik çıkarımı akış şeması	38
Şekil 3.5 İki bağımsız gauss değişkeninin dağılımı	43
Şekil 3.6 Otomatik kodlayıcı mimarisi	49
Şekil 3.7 Yığın Otomatik Kodlayıcı Mimarisi	50
Şekil 3.8 SAE Kullanılarak Spektral Öznitelik Çıkarma	51
Şekil 3.9 Destek Vektörü Kavramının Gösterilmesi	54
Şekil 3.10 Karar Kütüğü Yapısı	57
Şekil 3.11 Hata Oranına göre Alfa Değeri Grafiği	59
Şekil 3.12 Performans değerlendirme akış şeması.....	61
Şekil 3.13 Sınıf etiketleri	63
Şekil 3.14 PCA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	64
Şekil 3.15 NN ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	67

Şekil 3.16 ICA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	69
Şekil 3.17 MNF ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	71
Şekil 3.18 PCA ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	75
Şekil 3.19 MNF ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	76
Şekil 3.20 NN ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	77
Şekil 3.21 ICA ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	78
Şekil 3.22 PCA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	81
Şekil 3.23 MNF ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	83
Şekil 3.24 NN ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	85
Şekil 3.25 ICA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	87
Şekil 3.26 5 Sınıf için Skor Matris Örneği	90
Şekil 3.27 PCA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	91
Şekil 3.28 NN ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	94
Şekil 3.29 ICA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	96
Şekil 3.30 MNF ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri	98
Şekil 3.31 PCA ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	102
Şekil 3.32 MNF ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	103
Şekil 3.33 NN ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	104
Şekil 3.34 ICA ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi	105
Şekil 3.35 PCA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	108
Şekil 3.36 MNF ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	110
Şekil 3.37 ICA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	112
Şekil 3.38 NN ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler	114

Şekil 4.1 Gauss cnotch Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları	122
Şekil 4.2 Gauss cnotch ve Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları	123
. Şekil 4.3 renotch Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları	124
Şekil 4.4 renotch ve Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen	125
Şekil 4.5 Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları	126



ÇİZELGELER DİZİNİ

Çizelge 1.1 KÖ Spektrum Bölgeleri (Schowengerdt 2012).....	7
Çizelge 1.2 UV ve KÖ FİS Avantajları ve Dezavantajları	21
Çizelge 3.1 PCA ve SVM Sonucunda Elde Edilen AUC Bilgileri	66
Çizelge 3.2 NN ve SVM Sonucunda Elde Edilen AUC Bilgileri	68
Çizelge 3.3 ICA ve SVM Sonucunda Elde Edilen AUC Bilgileri.....	70
Çizelge 3.4 MNF ve SVM Sonucunda Elde Edilen AUC Bilgileri	72
Çizelge 3.5 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları	73
Çizelge 3.6 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri	73
Çizelge 3.7 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri	74
Çizelge 3.8 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen AUC Değerleri	74
Çizelge 3.9 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları	78
Çizelge 3.10 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri.....	79
Çizelge 3.11 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri.....	79
Çizelge 3.12 PCA ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri.....	93
Çizelge 3.13 NN ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri.....	95
Çizelge 3.14 ICA ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri.....	97
Çizelge 3.15 MNF ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri.....	99
Çizelge 3.16 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları....	100
Çizelge 3.17 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri.....	100
Çizelge 3.18 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri.....	101
Çizelge 3.19 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen AUC Değerleri.....	101
Çizelge 3.20 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları....	105

Çizelge 3.21 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri.....	106
Çizelge 3.22 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri.....	106
Çizelge 4.1 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Doğruluk Değerleri	120
Çizelge 4.2 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Kesinlik Değerleri	121
Çizelge 4.3 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Duyarlılık Değerleri	121
Çizelge 4.4 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen AUC Değerleri	121




1. GİRİŞ

1.1 Tezin Amacı

Karadan havaya atılan füzeler (SAM), hedef hava platformunun kızılötesi emisyonuna kilit atan bir kızılötesi arayıcıya sahiptir. Hedefe kilit atılarak füze fırlatıldıktan sonra arayıcı, füzeye güdüm bilgisi sağlar ve bir operatöre ihtiyaç kalmaz. Bu SAM'lere ateşle ve unut (fire and forget) yeteneği kazandırmaktadır (Richardson 2007).

Bir hava taşıtının Kızılötesi (KÖ) ışımasının ana kaynağı yaptığı KÖ emisyonudur. Hava taşıtının yaptığı ısıma miktarı, taşıtın gerçek sıcaklığına bağlıdır ve bir nesne ne kadar sıcaksa o kadar çok ısıma yapmaktadır. Yüksek sıcaklığa sahip bölgeler, motor ve egzoz dumanını temsil ederken, daha düşük sıcaklıklı bölgeler bir hava taşıtının yüzey alanını ifade etmektedir.

Hava taşıtlarının yüzey parçaları düşük salıcılık değerlerine sahiptir ve bu nedenle yansıtıcılık değerleri yüksektir. Bu durumda soğuk gökyüzünde hareket eden bir uçağın yüzeyi de yansıtıcılık değeri nedeniyle soğuk görünecektir. Su buharı (H_2O) ve karbon dioksit (CO_2) gibi gazlar sıcak egzoz dumanında bulunmaktadır. H_2O , 2 - 2.7 μm dalga boyunda güçlü ışıma yaparken CO_2 , 3 - 5 μm arasında güçlü ısıma yapmaktadır. Ancak, CO_2 'in 8 - 12 μm dalga boyunda ısıma şiddeti düşüktür. Şekil 1.1 ile yukarıda bahsedilen etki 3 - 5 μm dalga boyu aralığında bir savaş uçağı görüntüsü ile gösterilmiştir (Richardson 2007). Hedeften gelen KÖ emisyon füzenin görüş açısına bağlı olduğundan, füzenin hedefe başarılı olarak kilit atma ihtimali de görüş açısına bağlıdır.



Şekil 1.1 Bir savaş uçağının 3-5µm dalga bandı görüntüsü örneği (Richardson 2007)

Sovyetler Birliği - Afganistan savaşında, farklı tiplerdeki yaklaşık 250 adet Sovyet uçağı mücahit savaşçıların fırlattığı SAM'ler tarafından düşürülmüştür. Hatta tüm savaş uçağı kayıplarının çoğunun, KÖ güdümlü karadan havaya ve havadan havaya füzelerden (AAM) kaynaklandığı iddia edilmiştir (Richardson 2007).


İsrail'e ait bir ticaret uçağını hedef alacağı iddia edilen Sovyet yapımı 2 adet SAM, 1973 yılında Roma'da ele geçirilmiştir. O zamandan beri yaklaşık 30 adet sivil uçağın SAM'ler tarafından düşürüldüğü ve 1000'e yakın can kaybı olduğu iddia edilmektedir (Richardson 2007).

Şubat 2003'te yayınlanan bir ABD kongre raporu Taşınabilir Hava Savunma Sistemi (MANPAD) olarak kullanılan SAM'lerin dünya çapındaki envanterinin beşyüz binden fazla olduğunu ve 27 farklı milis ve terör örgütünün bunları kullandığını ifade etmiştir (Richardson 2007).

SAM'lerin kullanımı için basit bir eğitimin yeterli olması ve füze fırlatıldıktan sonra bir operatöre ihtiyaç kalmaması teröristler ve aykırı gruplar için taşınabilir hava savunma sistemi (MANPAD) olarak tercih edilebilecekleri anlamına gelmektedir. Küresel olarak kolay temin edilebilirliği, kullanımı için temel düzeyde eğitimin yeterli olması ve hedefi vurma oranları nedeniyle SAM'lerin ticari ve askeri hava taşıtlarına yönelik oluşturduğu tehditin ciddiye alınması gerekmektedir.

Yukarıdaki bilgiler ışığında, füze teknolojisinin ve oluşturduğu tehditin gün geçtikçe ilerlediği anlaşılmaktadır. Ülkeler gerek savunma gerek çaydıcılık vb. farklı amaçlar için çok sayıda füze edinmektedir. Günümüz şartları düşünüldüğünde çeşitli füzelerin ülkeler için büyük bir tehdit oluşturduğu görülmektedir. Askeri platformların ve içerisindeki yetişmiş değerli personelin kaybı, maddi ve manevi olarak, ülkeleri etkilemektedir. Bu tür tehditlerin etkisini en aza indirebilmek amacıyla çeşitli sistemler ve yöntemler kullanılmaktadır. Füze İkaz Sistemi (FİS) gibi sistemler ile füzelerin mümkünse ilk ateşleme anında hedefe henüz ulaşmamışken tespit edilmesi amaçlanmaktadır. Füzenin tespit edilebilmesi için FİS içerisinde çeşitli görüntü işleme algoritmaları kullanılmaktadır. Bu algoritmalar, füzenin hız, ışıma vb. gibi farklı özniteliklerini kullanarak tespit yapmaktadır.

Hiperspektral görüntüler kullanılarak sahne içerisindeki farklı nesnelerin tespiti ve sınıflandırılması yapılabilmektedir. Tespit ve sınıflandırma işlemlerinde, hiperspektral veriden sağlanan nesnelere ait spektral imzalar kullanılmaktadır. Hiperspektral görüntüler, görüntüleyicinin çözünürlüğüne göre sayısı değişen çeşitli dalga boylarında alınmaktadır. Çok sayıda dalga boyunda görüntü alınması spektral çözünürlüğü artırırken, birbirine ardışık benzer bantların bir işleme sokulmadan kullanılması işlem yükünü artırabilmektedir. İşlem yükünü azaltmak için hiperspektral görüntülerin boyutu çeşitli yöntemler kullanılarak düşürülmektedir. Hiperspektral görüntülerde, boyut azaltımı ve sınıflandırma yöntemlerinin diğer konularda yapılan çalışmalara göre oranı Şekil 1.2 ile gösterilmiştir. Bu iki çalışma alanının araştırmacılar tarafından tercih edilen yöntemler olduğu verilen grafiklerden anlaşılmaktadır.



Şekil 1.2 2009 – 2012 ve 2013 – 2016 Yılları Arasında HS Veriler Üzerine Yapılan Çalışmaların Oranları (Ghamisi vd. 2017)


Bu tezde farklı zamanlarda alınan hiperspektral görüntüler kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma için görüntülerde yer alan bulut (cloud), yeryüzü (ground), füze (missile), füze egzoz dumanı (plume) ve gökyüzü (sky) verileri kullanılmıştır. Bu 5 sınıf için öznitelik çıkarımı, sınıflandırıcı eğitimi ve test aşamalarında kullanılmak üzere çeşitli sayılarda referans veriler görüntüler üzerinden toplanmıştır. Görüntüler sınıflandırıcıya girdi olarak verilmeden önce temel bileşen analizi (PCA), bağımsız bileşenler analizi (ICA), maksimum gürültü oranı (MNF) ve sinir ağları (NN) yöntemleri kullanılarak boyut azaltımı/öznitelik çıkarma işlemi gerçekleştirilmiştir. Boyutu azaltılan verilere Kırmızı/Mavi uç oranı da ek öznitelik olarak eklenmiştir. Boyutu azaltılan veriler, önceden referans örnekler kullanılarak eğitilen AdaBoost ve Destek Vektör Makineleri (SVM) sınıflandırıcılarına girdi olarak verilmiştir. Sınıflandırma işleminden sonra her sınıfa farklı bir etiket atanarak, bu etiket değerine göre renk atanmıştır. Böylece, sınıflandırma sonuçları görsel hale getirilmiştir. Ayrıca farklı öznitelik çıkarım ve sınıflandırma algoritmalarının sonuçları alıcı işletim karakteristiği eğrileri (ROC curve), eğri altındaki alan (AUC) ve hata matrisleri gibi yöntemlere göre değerlendirilmiştir.

Bu çalışma, hiperspektral kamera ile alınan verilerin sınıflandırılması amacı ile gerçekleştirilen çalışmaların sonuçlarını ve ilgili sonuçlara ulaşmak için kullanılan metodolojiyi detaylandırmak üzere yapılmıştır. Daha önce, kurumsal bazda hiperspektral verilerin bu anlamda incelenmesi üzerine herhangi bir çalışma yapılmaması ve açık literatürde füze-sahte hedef ayrımının hiperspektral video kayıtları kullanılarak incelenmesi üzerine yeterli çalışma/kaynak bulunmaması sebebiyle veriye çok farklı açılardan bakma ihtiyacı duyulmuştur. Bu bakış açılarından doğan incelemeler umut verici sonuçlar vermiştir.

Bu tezde ilk olarak çalışmalarda kullanılan hiperspektral görüntülerden ve bu görüntü verilerinin özelliklerinden bahsedilmiştir. Ardından bu görüntüler üzerine uygulanan boyut azaltımı metotları özetlenmiştir. Son olarak elde edilen öznitelik verilerinin sınıflandırılması ile elde edilen sonuçlara yer verilmiştir.

1.2 Elektromanyetik Spektrum

Işık, sinüzoidal bir elektromanyetik dalgadır ve bir ortamda veya boşlukta hareket edebilmektedir. Dalga boyu, sinüzoidal bir dalganın kendisini tekrar ettiği mesafe olarak belirtilmektedir. Elektromanyetik ışıma, dalga boyunu kullanarak tanımlanmaktadır. Dalgaboyuna göre sınıflandırılan elektromanyetik ışıma Şekil 1.3 ile gösterilen bölgelerden birine dahil olmaktadır. Elektromanyetik spektrumun bölgeleri arasındaki sınırlar yaklaşıktır ve bu sınırlar detektör teknolojisi, insan gözü tepkisi ve atmosferik aktarıma dayanmaktadır. (Boreman 1998)



Şekil 1.3 Elektromanyetik Spektrum (Anonymous 2021)

Optik ışıma, tüm elektromanyetik spektrumun radyo dalgalarından X ışınlarına kadar olan bölgeyi kapsamaktadır. İnsan gözünün tepki verdiği elektromanyetik ışıma, yaklaşık olarak $0.4 \mu\text{m}$ ve $0.7 \mu\text{m}$ dalga boylarına sahiptir. Görünmez ışıma, mor dalga boyundan daha kısa dalga boylarına sahip ultraviyole (UV) ışımayı ve kırmızı dalga boyundan daha uzun dalga boylarına sahip kızılötesi (KÖ) ışımayı içermektedir. (Boreman 1998)

Bir fotonun enerjisi denklem (1.1) ile hesaplanmaktadır (Boreman 1998).

$$E = \frac{hc}{\lambda} = h\nu \quad (1.1)$$

Yukarıdaki denklemde E, foton enerjisini, $h = 6.67 \times 10^{-34}$ J, Plank sabitini, c, boşluktaki ışık hızını, λ , dalga boyunu ve ν , dalga frekansını temsil etmektedir (Boreman 1998).

Dalga boyu, dalga frekansı ile ilişkilidir. Bu ilişki denklem (1.2) ile verilmiştir (Boreman 1998).

$$\nu = c/\lambda \quad (1.2)$$

Denklem (1.2)'den görüldüğü gibi dalga boyu ve dalga frekansı ters orantılıdır.

1.3 Kızılötesi Bölge

Dünya yüzeyindeki veya atmosferdeki çeşitli nesneler, spektrumun KÖ bölgesinde elektromanyetik enerjiyi farklı oranlarda yansıtmaktadır veya yaymaktadır. Nesnelerin elektromanyetik enerji ile bu şekilde farklı etkileşimlerinin sonucunda nesnelere özgü özellikler belirlenebilmektedir.

KÖ spektrumu oluşturan bölgeler Çizelge 1.1 ile verilmektedir (Schowengerdt 2012). Yakın Kızılötesi ve Kısa Dalga Kızılötesi Bölgeleri güneşten gelen ışımanın nesnelerden yansımalarının baskın olduğu spektral aralıktır. Dünya yüzeyine güneşten gelen enerji, dünyanın kendisi tarafından yayılan enerjiyi aşmaktadır. Orta Dalga Kızılötesi bölge, yansıtıcılıktan termal ışımaya geçiş bölgesidir. 5 μ m'nin üzerinde genellikle yeryüzünden yayılan termal enerji baskın olmaktadır. Termal görüntüler kaynak olarak doğrudan güneşi kullanmadıklarından geceleri de elde edilebilmektedir (Schowengerdt 2012).

Çizelge 1.1 KÖ Spektrum Bölgeleri (Schowengerdt 2012)

Elektromanyetik Spektrum Bölgesi	Dalga Boyu Aralığı	Işıma Kaynağı	Nesne Özelliği
Yakın Kızılötesi Bölge	0.7 – 1.1 μm	Solar	Yansım
Kısa Dalga Kızılötesi Bölge (SWIR)	1.1 – 1.35 μm 1.4 – 1.8 μm 2 – 2.5 μm	Solar	Yansım
Orta Dalga Kızılötesi Bölge (MWIR)	3 – 4 μm 4.5 – 5 μm	Solar, Termal	Yansım, Sıcaklık
Uzun Dalga Kızılötesi Bölge (LWIR)	8 – 9.5 μm 10 – 14 μm	Termal	Sıcaklık

1.4 Kızılötesi GÜDÜMLÜ Füzeler

KÖ güdümlü füzeler, son zamanlardaki tüm çatışmalarda en ölümcül tehditler arasında yer almaktadır. KÖ füzeler havadan havaya (AAM), havadan karaya (ASM), karadan havaya (SAM) ve karadan karaya (SSM) içermektedir. KÖ bir füze, döner ve sabit kanatlı hava platformlarının arka plana göre KÖ izini algılar. İlk dönem KÖ füzelerin yüksek oranlarda başarı elde edebilmeleri için hava platformlarının yüksek sıcaklığa sahip motorlarını hedef almaları gerekmekteydi. Bu nedenle genellikle hava platformlarının arka tarafını hedef alacak şekilde ateşlenirlerdi ve saldırılar çoğunlukla arka taraf ile sınırlıydı. Yeni nesil füzeler motor bölgesine göre daha soğuk ancak aerodinamik sürtünme sonucu ısınan platform gövdesi vb. kısımlar, yakıt yanması sonucu oluşan egzoz dumanı veya egzoz gibi bölgelerden de hedefi tespit edebilmektedir. Bu durum hava platformlarının yeni nesil tehditlere karşı tüm yönlerden zaafiyet göstermelerine neden olmaktadır.

1.4.1 KÖ güdümlü füzelerin tarihçesi

1950'lerden bugüne kadar KÖ detektör teknolojisi, bilimsel, endüstriyel ve askeri uygulamalar da dahil olmak üzere çeşitli alanlarda giderek daha fazla kullanılmaktadır. KÖ teknolojisindeki gelişmeler sayesinde askeri uygulamalarda gece görüşü gibi sistemlerin yanı sıra bir hedefe KÖ güdümü kullanarak yönlenen füzelerin geliştirilmesine neden oldu (Pastor 2020).

20. yüzyılın başlarında Avrupa'daki bilimsel çalışmalar sonucunda, uçaksavar gibi cihazlar için ilk KÖ algılama elemanlarını geliştirdi. 1933'te Berlin Üniversitesi'ndeki E.W. Kutzscher kurşun sülfürün (PbS) fotoiletken malzeme olduğunu keşfetti. PbS, İkinci Dünya Savaşı sırasında çeşitli uygulamalarda kullanılan ilk KÖ detektördü (Pastor 2020).

Döner ve sabit kanatlı hava platformlarında yer alan motor, KÖ tespit sistemlerinin algılayabildiği büyük miktarda ışıma üretir. Hava platformlarının en yüksek KÖ ışımaya sahip parçaları, SWIR ve MWIR bölgelerinde en yüksek sıcaklıklara sahip egzoz borusu ve egzoz dumanıdır. Bir hava platformundan gelen diğer ışıma kaynakları, metal parçalar ve pilot kubbesinden gelen güneş yansımalarıdır. Buna ek olarak yüksek hızlarda ilerleyen jetlerde aerodinamik ısınma da önemli miktarlarda ışıma yapmaktadır (Pastor 2020).

Soğutmasız PbS detektörünün kullanıldığı KÖ sistemlerin ilk örneği, 50'li yılların ortalarında ABD Donanması tarafından geliştirilen AIM 9 Sidewinder havadan havaya füzesidir. 1956'da AIM-9B olarak hizmete girdi ve 60 yıl boyunca birincil savaş silahı oldu. Benzer şekilde, Sovyet Hava Kuvvetleri, PbS dedektörlerine dayalı pasif KÖ güdümlü havadan havaya füze Kaliningrad K-5'i 1957'de tanıttı. 1960 yılında gelişmiş bir varyant Vympel K-13 KÖ güdümlü havadan havaya füzesi hizmete alındı. 60'ların sonlarından itibaren, AIM 9D Sidewinder ve Vympel K13M füzelerinde soğutmalı PbS KÖ detektörleri kullanıldı ve bu durum detektörde oluşan gürültüyü azalttı (Pastor 2020).

1959'da HgCdTe alaşımının keşfi, KÖ detektörün spektral tepkisinin çeşitli uygulamalar için özel olarak ayarlanmasına olanak sağladı. Bant aralığı enerji ayarlanabilirliği, SWIR (1–3 μm), MWIR 3–5 (μm), LWIR (8–14 μm) bölgelerini kapsayan KÖ detektör uygulamaları ile sonuçlandı (Pastor 2020).

1955'te ABD, taşınabilir hava savunma sistemi (MANPADS) olan FIM-43 Redeye üzerinde çalışmalara başladı. İlk Redeye füzesinde AIM-9B Sidewinder'da kullanılan soğutmasız PbS KÖ detektör ünitesi kullanılmıştır (Pastor 2020).

Sovyetler 1964'te Strela-1 ve Strela-2'yi geliřtirmeye bařladı. SA-7b olarak da bilinen 9K32 Strela-2, 1968'de hizmete girdi ve bu o dnem tasarımılarının en bařarılılarından biri olarak kabul edilmektedir (Pastor 2020).

Redeye iin ykseltme programı 1967'de Redeye II olarak bařlatıldı. Testler 1975'e kadar bařlamadı ve FIM-92 Stinger ismiyle yeniden adlandırılarak ilk teslimatlar 1978'de yapıldı (Pastor 2020). Sovyetler de benzer řekilde kendi versiyonlarını geliřtirerek, 9K34 Strela 3' 1974'te ve ift bant K detektre sahip 9K38 Igla ve Igla-S sistemlerini sırasıyla 1983 ve 2004'te tanıttı (Pastor 2020).

Yetmiřlerin ortalarında, pasif K grntleme uygulamaları iin fotodiyotlar kullanılmaya bařlandı (Pastor 2020). Fotoiletken detektrlerin ana sınırlaması, odak dzlemi zerine kolay bir řekilde ok sayıda yerleřtirilememesidir. Buna karřılık, fotodiyotların odak dzlemi zerine kolay řekilde ok sayıda yerleřtirilebilmesi, megapikselden daha fazla eleman ieren iki boyutlu dizilerin birleřtirilmesine olanak saęlamıřtır (Pastor 2020). Yk baęlantılı cihazların (CCD) icadından sonra, iki boyutlu K dedektr dizisi fikri, dikkatlerin HgCdTe fotodiyotlara evrilmesine neden olmuřtur (Pastor 2020). Odak dzlem dizilerindeki (FPA) geliřme, K grntlemede devrim yaratmıřtır. Entegre devre tasarımı ve retim tekniklerindeki ilerleme, bu katı hal dizilerinin boyutunda ve performansında srekli hızlı byme ile sonulanmıřtır (Pastor 2020).


Bu sistemler, daha fazla sayıda piksel, daha yksek ereve hızı, daha iyi termal znrlk ve birden fazla bantta alıřabilme gibi geliřmiř yetenekler saęlamaktadır. Ayrı K spektral bantlarda veri toplayan sistemler, sahnedeki nesnelerin hem mutlak sıcaklıęını hem de spektral imzalarını ayırt edebilmektedir. ok bant algılayan sistemler, tek bant algılayanlara gre daha geliřmiř sinyal iřleme algoritmaları kullanmaktadır (Pastor 2020).

Kızıltesi fzelerin ıřmasını kullandıkları yakıt tr etkilemektedir. Yaygın olarak kullanılan alminyum katkılı yakıtlar UV ve K blgelerde gl bir ıřıma ile birlikte yksek itki gc meydana getirmektedir. İtki gcn arttırmak iin yakıtı eklenen

alüminyum, egzoz gazlarının yüksek sıcaklığı yoluyla yüksek bir ışımaya neden olmaktadır (Neele ve Schleijpen 2003). Ancak alüminyum katkısı olmayan düşük ışımaya ve düşük görünürlüğe sahip yakıtlar da geliştirilmiştir.

1.4.2 KÖ füze bölümleri ve görevleri

Şekil 1.4 ile KÖ güdümlü füzenin bölümlerini gösteren bir şema verilmektedir. Füzenin ön uç kısmında KÖ kubbe yer almaktadır. Bu yapı, KÖ enerjiyi yüksek oranda ileten malzemeden yapılmış küresel bir koruyucu kaplamadır. Arayıcı kısmı, KÖ kaynağın açısal konumunu algılamaktadır ve hata sinyalinin güdüm kontrol grubuna göndermektedir. Güdüm kontrol grubu, kontrol komutlarıyla ön kanatları kullanarak füzeyi hedefe yönlendirir (Pastor 2020).



Şekil 1.4 KÖ Füze Bölümleri (Pastor 2020)

1.4.2.1 Kubbe

KÖ füzelerin ön yüzeyinde bir kubbe yapısı bulunmaktadır. Bu, arayıcının çarpışma dalga bandında KÖ ışımayı ileten bir malzemeden yapılmıştır. Kubbe aynı zamanda füzeye, füze maksimum hızına ulaştığında oluşan füzenin termal şoku, aşınma direnci ve herhangi bir mekanik şok gibi aerodinamik etkilerden koruma sağlar. Üretilmesi kolay bir optik yüzey olduğundan kubbe genellikle yarım küre şeklindedir. Ancak bu, kötü süpersonik performans göstermekte ve bazı sistemlerde çıkıntılı yapılar şeklinde de üretilmektedir (Richardson 2007). Şekil 1.5 ile yarım küre şeklinde bir kubbe gösterilmiştir (Richardson 2007).



Şekil 1.5 Yarım Küre Şeklinde Kubbe (Richardson 2007)


1.4.2.2 Optikler

Kubbenin arkasındaki optik sistem, gimbal özelliğine sahip bir kaskren teleskopudur. Gimbal sayesinde geniş bakış alanı (field of regard) korunurken nispeten küçük bir anlık görüş alanı (instantaneous field of view) sağlanabilir (Richardson 2007).

1.4.2.3 Kısıcılar

Gimbal içersinde, KÖ ışımayı detektör üzerine düşmeden modüle eden bir kısıcı bulunmaktadır. Döner kısıcı (spin scan) ve sabit kısıcı (con scan) olmak üzere iki temel versiyon vardır (Richardson 2007).


Döner Taramalı Kısıcı (spin scan): Kısıcı döndürülür ve bu, hedef görüntünün genlik modülasyonunu ve faz değişimini verir. Şekil 1.6 ile gösterildiği gibi, hedef görüntünün kısıcıdan geçerken oluşturduğu kare dalganın genliği, radyal mesafeye bağlıdır. Kısıcının kenarında, hedef eksenin dışında, kare dalga tam genliğe sahipken, hedef merkezde, eksen üzerinde, genlik sıfırdır (Richardson 2007).



Şekil 1.6 Dönü Taramalı Kıyıcı (Richardson 2007)

Kıyıcının yarı dairesel %50 iletim kısmından faz değişimi elde edilir. Bu tip kıyıcılar, hedef konumunun arayıcının görüş alanı içinde sabitlenmesine olanak sağlar. Dönü taramalı kıyıcıların önemli bir dezavantajı vardır. Hedef tamamen eksen üzerinde olduğunda üretilen kare dalganın genliği sıfır olmaktadır. Bu durum, hedef eksen üzerindeyken hata sinyalinin kaybolmasına ve füzenin hedefi kaybetmesine yol açmaktadır. Koni taramalı kıyıcılar kullanılarak bu sorun azaltılmıştır (Richardson 2007).

Koni Taramalı Kıyıcı (con scan): bu sistemde kıyıcı sabit kalır ve görüntü, optiklerin hareket etmesiyle döndürülür. Bu, hedef görüntünün nütasyon/yönelim çemberini verir. Şekil 1.7 ile bu kıyıcı kullanıldığında görüntünün frekans modülasyonunu verdiği gösterilmiştir (Richardson 2007). Şekil 1.7 (a), eksen üzerinde mükemmel bir şekilde merkezlenmiş nütasyon/yönelim çemberini göstermektedir ve sonucunda düzgün bir frekans kare dalga gözlemlenir. Nütasyon/yönelim çemberi eksen dışına kayarken, Şekil 1.7 (b), eksen dışında hareket eden hedefe karşılık gelir, çıkışında frekans modülasyonu gözlemlenir. Frekans değişiminin büyüklüğü, hedefin eksen dışı mesafesiyle orantılıdır. Frekans modülasyonu kullanılarak hedefin, arayıcı görüş acısı içerisindeki konumu bulunabilir (Richardson 2007).



Şekil 1.7 Koni Taramalı Kıyıcı (Richardson 2007)

1.4.2.4 Detektör

Eski nesil SAM'lar, arayıcıda genellikle soğutmasız kurşun sülfür (PbS) detektörleri kullanırdı. Bu foton detektörleri $3\text{ }\mu\text{m}$ 'den küçük dalga boyları için hassasiyete sahiptir. Bu sistemler genellikle $2 - 2.7\text{ }\mu\text{m}$ aralığında çalışmaktadır (Richardson 2007). Bu dalga boyu aralığında, detektör sadece motorun sıcak parçalarını ve sıcak egzoz dumanını algılayabilmektedir. Bu durum, bu tür füzelerin hedefe her yönden değil, sıcak kısımlarının görülebilmesi için hedefin arka tarafından fırlatılmasına neden olmaktadır.

Yeni nesil SAM'larda soğutma sistemi kullanılmaya başlanmıştır ve bu durum füzenin her yönden hedefe fırlatılmasına olanak sağlamıştır. Bu detektörlerde, $3 - 5\text{ }\mu\text{m}$ aralığında çalışan indiyum antimonite (InSb) gibi malzemeler kullanılmaya başlanmıştır. Daha uzun dalga boylarında çalışılarak, motorun daha soğuk parçalarının,

uak gvdesinin ve egzoz dumanındaki farklı bileşenlerin de algılanmasına neden olmuştur (Richardson 2007).

1.4.2.5 Soğutma


SAM’larda kullanılan en yaygın soğutma yöntemi, argon, nitrojen ve kuru hava içeren bir Joule-Thomson (JT) soğutucusudur (Richardson 2007).

1.4.2.6 Kanat ve kanatıklar

Detektrn elektriksel ıkışı bir hata sinyali retir. Kanat ve kanatıklar, hedef grnty grş alanının merkezine alacak şekilde hareket ederek hatayı en aza indirmeye alışır. Fzenin kontrol ve aerodinamik yzeyleri aılır veya katlanır kanatlar ve kuyruk kanatıklarıdır. Şekil 1.8 ile Kanat ve kanatıklar gsterilmiştir.



(a)



(b)

Şekil 1.8 Aılır Kanatlar ve Katlanır Kanatıklar (Richardson 2007)


1.4.2.7 Roket motoru

SAM'lar, genel olarak itki – destek (boost – sustain) türünde katı yakıtlı bir roket motoruyla çalışır. Füze, operatörü korumak için yumuşak ateşleme gerçekleştirir. Bu genellikle bir gaz jeneratörü veya çok kısa süre yanan bir darbe motoru ile sağlanır. Tüpten uzaklaşıp yeterli menzile ulaştıktan sonra, ana itki motoru (main boost motor) ateşlenir ve füzeyi maksimum hıza çıkarır. Sonrasında, destek motoru (sustain motor), hedefi vurana veya tam yanmaya kadar füzeyi bu hızda tutar. MANPAD'ler için füze hızları yaklaşık 1.5 – 2 mach ve menzil 3 – 5 km arasındadır (Richardson 2007). Şekil 1.9 ile roket motoru gösterilmiştir (Richardson 2007).




Şekil 1.9 Roket Motoru (Richardson 2007)


Açık literatürde MWIR aralığında arkaplan ışımasının füze egzoz ışımasından farklı olduğu belirtilmiştir. Şekil 1.10 ile gökyüzü, bulut ve iki farklı türdeki füze için spektral yoğunluk değerleri verilmiştir (Huang ve Huang 2018). Şekil incelendiğinde gökyüzü, bulut ve füzelerin spektral yoğunluk değerlerinin 2 – 5 μm bant aralığında farklılık gösterdiği anlaşılmaktadır. Bu tez çalışmasında da bu spektral farktan faydalanılarak çalışmalar gerçekleştirilmiştir.



a)



b)



c)

Şekil 1.10 a) Göküzü Spektral Yoğunluk Değeri b) Bulut Spektral Yoğunluk Değeri c) İki Farklı Tür Füze Egzoz Dumanı için Spektral Yoğunluk Değeri (Huang ve Huang 2018)

1.4.2.8 Tapa – Harp başlığı

Harp başlığı 1- 3 kg arasında patla ve parçalan (blast fragmentation type) tipindedir. Tapa, genellikle temas/etki (contact/impact) tipindedir. Bu nedenle füzenin harp başlığını tetiklemek için hedefin bir kısmına çarpması gerekmektedir (Richardson 2007). Yakınlık tapasının kullanımıyla, hedefe temas etmeye gerek kalmamış ve belirli bir mesafe kala harp başlığının tetiklenmesi sağlanmıştır.

1.5 Füze İkaz Sistemleri

Kızılötesi güdümlü füzeler, 1979'dan 1993'e kadar uçakların ve helikopterlerin %89'undan fazlasının düşürülmesine neden olmuşlardır. KÖ bölgede çalışan detektörlerdeki gelişmeler, kızılötesi güdümlü füzelerin hedef platformları algılama yeteneklerini arttırmaktadır (Rao ve Mahulikar 2005). KÖ güdümlü tehditlere karşı sabit-döner kanatlı hava platformlarını ve yetişmiş personeli koruması amacıyla füze ikaz sistemlerine gereksinim oluşmuştur. Füze ikaz sistemleri, hedef platforma yönlendirilmiş tehdidi algılayan, platform operatörünü sesli ve görsel olarak uyanan sistemlerdir. Füze ikaz sisteminin tehdidi algılaması sonucunda tehdide farklı elektronik taarruz yöntemleri ve kaçış manevraları uygulanabilir.

Füze ikaz sistemleri tehdidi pasif olarak algılamasına göre ikiye ayrılmaktadır. Bunlar:

1. UV Detektör Kullanan Sistemler
2. KÖ Detektör Kullanan Sistemler

1.5.1 UV detektör kullanan füze ikaz sistemleri

UV detektör kullanan füze ikaz sistemleri, 200 – 300 nm bant aralığında çalışmaktadır. Bu bant aralığı güneş körü bölge olarak adlandırılmaktadır. Bahsi geçen dalga boyu aralığında, güneşten gelen ışımının neredeyse tamamı atmosferde bulunan ozon tarafından emilmektedir ve bunun sonucu olarak doğal kaynakların ışması sıfıra yakındır. UV detektörler, tehdidi egzoz dumanının tespit edilmesiyle bulmaktadır (Yao vd. 2011). Güneş körü bölgede, tehdit egzoz dumanı ve arka plan arasında UV ışıma tespiti için iyi bir zıtlık oluşabilir. Bu bölgede arka plan ışması koyu renkte oluşur ve

bu bölgede füze yüksek miktarda UV ışıma yapar ise koyu arka plan sayesinde tespit edilebilir. Tehdit koyu arka plan üzerinde parlak noktalar gibi görünmektedir. Şekil 1.11 ile güneş körü bölgede yaklaşık 2 km mesafeden farklı hava şartlarında alınan hedefe ait görüntü örneği verilmektedir (Yao vd. 2011).



Şekil 1.11 Güneş Körü Bölgede Alınan Görüntü Örneği a) güneşli, ~2 km b) bulutlu, ~2km (Yao vd. 2011)

1.5.2 KÖ detektör kullanan füze ikaz sistemleri

Bir füzenin kızılötesi imzasının ana kaynağı egzoz dumanından kaynaklı ışımadır. Füzenin gövdesi ise füzeye önden bakılan görüş açılarından füze yaklaştıkça baskın hale gelmektedir ve bu açıdan egzoz dumanının görülmesi füze gövdesi tarafından engellenmektedir. Füze gövdesinin KÖ imzasının aerodinamik ısınmadan kaynakladığı düşünülmektedir. KÖ detektör kullanan füze ikaz sistemleri tehdidi egzoz dumanından ve aerodinamik ısınmadan kaynaklı olarak tespit etmektedir. Bu sistemler 3 – 5 μm bant aralığında çalışmaktadır (Neele 2005).

1.5.3 UV ve KÖ detektör kullanan füze ikaz sistemleri arasındaki farklar

Günümüzde kullanılan füze ikaz sistemlerinin çoğu UV bölgede çalışmaktadır. KÖ bölgede çalışan uyarı sensörleri genellikle mevcut sistemlerin halefleri olarak görülmektedir (Neele 2005). Her iki uyarı sensörünün performansını etkileyen parametreler ile beraber bu sistemlerin avantajları ve dezavantajları alt paragraflarda açıklanmıştır.

Ultraviyole bandını kullanan FİS'ler, KÖ bandında çalışan FİS'lere göre daha düşük yanlış alarm oranına sahiptir. KÖ bandında çalışan FİS'ler arka plan gürültüsünden muzdariplerdir ve yüksek arka plan gürültüsü nedeniyle sistem performansında azalma (yüksek yanlış alarm oranı) meydana gelebilir. UV FİS'ler güneş körü bölgede çalıştığından dolayı doğal ışıma kaynaklarından oldukça az etkilenirler ve arka plan ile tehdit daha kolay bir şekilde ayrıştırılabilmektedir (Neele 2005). Ancak güneş körü bölgede çalışan UV FİS'ler doğal ışıma kaynaklarından daha az etkilenmelerine rağmen fabrika bacası, şehir ışıkları gibi insan yapımı UV kaynaklarından etkilenecek yanlış alarm verebilirler.

UV FİS'lerde arka plan gürültüsü olmadığından daha basit sinyal işleme algoritmaları kullanarak füzeyi tespit ederler. KÖ FİS'ler ise arka plan gürültüsünü azaltmak için daha karmaşık sinyal işleme algoritmaları kullanırlar (Neele 2005). Karmaşık sinyal işleme algoritmalarına ihtiyaç duyulması soğutma ihtiyacını ortaya çıkarır ve bu durum sistemin daha maliyetli ve ağır hale gelmesine neden olur.

UV ve KÖ bantlarında çalışan FİS'lerin menzilini ve etkinliğini füzede kullanılan yakıtın bileşenleri etkilemektedir. Yaygın olarak kullanılan alüminyum katkılı yüksek itki kuvveti sağlayan yakıt; yüksek oranda egzoz gazı yaymakta ve ilgili bant aralıklarında yüksek değerlerde salınım yapmaktadır (Neele ve Schleijpen 2003). Fakat yakıt teknolojisinin gelişimiyle daha az salınım yapan yakıtların füzelerde kullanılmaya

başlanması FİS'lerin tehdit takibinin zorlaştırılması, sistemin hedef tespit performansının ve menzilinün düşürölmesi amaçlanmaktadır.

UV FİS füzeyi egzoz dumanından tespit ederken, KÖ FİS ise egzoz dumanı ve aerodinamik ısınmalardan füzeyi tespit etmektedir (Neele 2005). Tehdidin hedefi takibi sırasında yakıtı tükendiğinde UV FİS tehdit tespiti yapamazken, KÖ FİS füzenin yakıtı bitse dahi tehdidi motor sıcaklığı ve aerodinamik ısınmalardan tespit edebilmektedir.

UV ve KÖ FİS'lerin performansını etkileyen diğeri bir etken ise atmosferik iletimdir (Neele ve Schleijsen 2003). Atmosferde bulunan ozonların UV ışımayı zayıflatması nedeniyle UV iletimi atmosferik saçılma ile sınırlıdır. Yüksek irtifalara çıkıldıkça ozon miktarının artmasından dolayı arka plan gürültüsünde de artış görülürken, kentsel bölgeler gibi ozon yoğunlaşmasının yüksek değerlere ulaştığı kentsel bölgelerde sistem performansında azalma görölmektedir. Bu etkenler UV FİS'lerde kısıtlı hedef tespit menziline neden olmaktadır. KÖ FİS'lerin çalıştığı MWIR'da ise sera gazları etkindir ve sera gazlarının yüksek değerlere çıktığı bölgelerde sistemin performansında azalmalar görölmektedir. KÖ FİS'ler UV FİS'lere göre atmosferik zayıflatmadan daha az etkilendiklerinden daha yüksek menzillerde tespit yapabilmektedirler.

Yukarıda detaylı olarak bahsedilen UV ve KÖ FİS'lerin avantajları ve dezavantajları, Çizelge 1.2 ile maddeler halinde gösterilmektedir.

Çizelge 1.2 UV ve KÖ FİS Avantajları ve dezavantajları


SİSTEM	AVANTAJ	DEZAVANTAJ
Kızılötesi FİS	• Uzun tespit menzili • Karşı önlemler için uzun tepki süresi • Tehdidin yakıtı tükense bile tespit yapabilme	• Yüksek yanlış alarm oranı • Karmaşık sinyal ve görüntü işleme algoritmaları kullanımı • Karmaşık arka plan gürültüsü • Soğutma ihtiyacı • Daha fazla boyut ve hacim
Ultraviyole FİS	• Düşük arka plan gürültüsü • Basit sinyal ve görüntü işleme algoritmaları kullanımı • Düşük yanlış alarm oranı • Olgunlaşmış teknoloji • Soğutma ihtiyacı olmaması • Düşük maliyet • Küçük boyut ve hacim	• Düşük atmosferik iletim • Kısa tespit menzili • Karşı önlemler için kısa tepki süresi • Tehdidin yakıtı tükendiğinde tespit edememe

1.6 Hiperspektral Görüntüleme

Hiperspektral görüntüleme, nesne tarafından yayılan ve yansıtılan ışığın, ardışık ve çok sayıda bantta ölçümünün alınmasıdır. Görüntüleme için kullanılan sensörün çözünürlüğüne göre dalgaboyu aralıkları değişmektedir.

Hiperspektral görüntülerde çeşitli dalga boylarındaki görüntüleri ifade etmek için birçok kanal mevcuttur ve elde edilen görüntülerin dalga boyu aralıklarında süreklilik bulunur. Hiperspektral görüntüleme sonucu elde edilen veriye data küp/hiper küp denmektedir. Data küpte ilk iki boyut uzamsal bilgiyi (x, y), üçüncü boyut ise dalga boyuna bağlı spektral bilgiyi bulundurur. Görüntünün her pikselinde bulunan spektral ve uzamsal bilgilerin analiz edilmesiyle, sahnede yer alan nesnelerin spektral imzaları belirlenebilir. Her nesne kendine özgü spektral imzaya sahiptir. Bu nedenle hiperspektral görüntüleme

uzaktan algılama, sınıflandırma, tespit ve teşhis gibi uygulamalarda tercih edilmektedir. Şekil 1.12 ile hipersektrel görüntü üzerinden seçilen bir piksel için oluşturulan spektral imza ve data küp yapısı gösterilmiştir (Ghamisi, Yokoya, vd. 2017).



Şekil 1.12 (a) Hiperspektral Data küp Örneği, (b) Bir Piksele ait Spektral İmza (Ghamisi vd 2017)

Hiperspektral görüntülemenin uygulama alanlarından bazıları şunlardır:

1. Askeri gözetleme, keşif ve sınır kontrolü
2. Tarım ürünlerinin gelişiminin ve veriminin takip edilmesi
3. Doğal kaynak ve minarellerin keşfi
4. Çevresel değişimin takip edilmesi
5. Fabrika ve tesislerin hasar meydana gelmeden önce tespiti
6. Zararlı gazların tespiti

2. LİTERATÜR ÖZETİ

Bu çalışma kapsamında incelenen ve faydalanılan kaynakların özetleri aşağıda verilmiştir.

Rodarmel ve Shan (2002) çalışmasında, HS görüntülerin sınıflandırılması için ön işleme olarak PCA tekniğinin kullanımı incelenmiştir. Çalışma için iki HS veri seti kullanılmıştır. PCA uygulanması sonucu elde edilen bantlar arasından, ilk 5 bandın tüm HS verisinde bulunan bilgilerin çoğunu barındırdığı ve ilk 10 banttan sonra hemen hemen tüm bantların gürültü içerdiği söylenmiştir. Doğru sınıflandırma oranının, sınıflandırmaya daha fazla PCA bandı dahil edildiğinde doğrusal olarak yavaşça arttığı gösterilmiştir. En önemli 5 ve 10 PCA bandı kullanımının, yaklaşık yüzde 70 ve yüzde 80 veya daha yüksek doğru sınıflandırma oranı sağladığı deneyler ile verilmiştir. Tüm bu bulgular, hiperspektral görüntü sınıflandırması için PCA yaklaşımının kullanılmasının faydalı ve etkili olduğunu göstermiştir. PCA, işlenecek veri miktarını önemli ölçüde azaltır ve tüm hiperspektral görüntü verileri kullanılarak elde edilen sınıflandırma sonuçlarıyla karşılaştırıldığında, pratik olarak kabul edilebilir ve doğru sınıflandırma sonuçları elde edilmiştir.

Bajcsy ve Groves (2004), hiperspektral bantları ve sınıflandırma yöntemlerini seçmek için kullanılan sınıflandırma doğruluğu ve hesaplama gereksinimi kısıtlamaları altında denetimsiz ve denetimli yöntemleri birleştirmek için yeni bir metodoloji sunmuştur. Hesaplama açısından verimli ve doğru bir bant seçim sistemi oluşturmak için denetimsiz ve denetimli bant seçim yöntemleri birleştirilmiştir. Önerilen metodolojiyi test etmek için yedi denetimsiz ve üç denetimli yöntem geliştirilerek, yöntemler birleştirilmiştir. Optimal bant sayısını, bant merkezi dalga boylarını elde etme sürecini ve sınıflandırma doğruluğu ve hesaplama gereksinimleri kısıtlamaları altında sınıflandırma yöntemlerinin seçimini gösteren deneysel verilere dayalı bir çalışma yürütülmüştür.

Kawaguchi ve Nishii (2007), temel sınıflandırıcılar olarak kütük fonksiyonuyla AdaBoost kullanılarak hiperspektral verilerin denetimli sınıflandırması yapılmıştır. Kararlılığı ve doğruluğu artırmak ve aşırı eğitimi azaltmak için bootstrap yöntemi değiştirilmeden kullanılmıştır. Veriler, eğitim ve doğrulama olarak iki kümeye ayrılmıştır. Sınıflandırıcıların çoğunluk oyu ile nihai sınıflandırıcıyı elde etmek için alt örnekleme eğitim/doğrulama adımları tekrarlanmıştır. Multispektral ve hiperspektral verilerle yapılan deneyler, önerilen yöntemin son derece iyi performans gösterdiğini ve destek vektör makineleri, yapay sinir ağları ve diğer iyi bilinen sınıflandırıcılardan üstün olduğu gösterilmiştir.

Sotoca, Pla, ve Sánchez (2007), hiperspektral görüntüler için bir bant seçim tekniği önermişlerdir. Önerilen yöntem bilgi ölçümlerinin kullanımına dayanmaktadır. Mevcut yaklaşım, bir dizi örnek görüntüden ilgili spektral bantları elde etmek için denetimsiz bir öznitelik seçim kriteri gibi davranmaktadır. Önerilen yöntem, spektral bantlar arasındaki bağımlı bilginin minimizasyonuna dayanmaktadır. Spektral bantlar arasındaki bilgi içeriği analiz edilerek, seçilen bantların koşullu entropileri maksimize edilmeye çalışılmaktadır.

Kang vd. (2013), kenar koruyucu filtrelemeye dayalı yeni bir spektral uzamsal sınıflandırma yaklaşımı önerilmiştir. Önerilen yaklaşım sınıflandırma haritalarını optimize etmeyi amaçlamaktadır ve üç adımdan oluşmaktadır. İlk olarak, HS görüntü, SVM gibi piksel tabanlı bir sınıflandırıcı kullanılarak sınıflandırılır. Daha sonra, elde edilen sınıflandırma haritası çoklu olasılık haritaları olarak temsil edilmektedir ve HS görüntünün birinci ana bileşeni veya ilk üç ana bileşeni gri veya renkli kılavuz görüntü olarak kullanılarak her olasılık haritasına kenar koruma filtresi uygulanır. Son olarak, filtrelenmiş olasılık haritalarına göre, her pikselin sınıfı, maksimum olasılığa göre seçilir. Deneysel sonuçlar, önerilen kenar koruma filtreleme tabanlı sınıflandırma yönteminin sınıflandırma doğruluğunu iyileştirebileceğini göstermiştir.

Renuka ve Reddy (2013), füze KÖ imzalarının ve arka plan verilerinin oluşturulması için uyarlanacak metodolojiyi açıklamışlardır. Füze, füze egzoz dumanı ve arka plan

KÖ izlerinin çeşitli kayıt cihazları ile elde edilmesi, bunların etkin olduğu dalga boyları ve izleri etkileyen faktörler hakkında bilgiler verilmiştir. Tehdidi arka plandan ayırt etmek için, yeterli miktarda arkaplan verisi kullanımıyla sistemin yanlış alarm oranının düşürülebileceği ifade edilmiştir. Aynı zamanda yanlış alarm oranını azaltmak için füze ışımasının diğer sıcak kaynakların ışımasına göre farklılık gösterdiği, kırmızı band (3 - 4 μm) ve mavi band (4 - 5 μm) adı verilen iki spektral bandın kullanılabileceği ifade edilmiştir. Füze uyarı sisteminin verimli olarak çalışması için KÖ arkaplan ve füze izi veri tabanlarının oluşturulmasının amaçlandığı söylenmiştir.

Kang, Li, ve Benediktsson (2014), görüntü birleştirme ve özyinelemeli filtrelemeye (IFRF) dayanan basit ama güçlü bir öznelilik çıkarma yöntemi önermiştir. Önerilen yaklaşım, verilerin boyutunu azaltmak için IF uygulanmasına ve uzamsal bilginin elde edilen IFRF öznelilikleriyle birleştirilmesi için özyinelemeli filtreleme işlemine dayanmaktadır. İlk olarak HS bantlar alt kümelerine bölünmüştür. Daha sonra, her alt kümedeki bantlar, ortalamaları alınarak birbiriyle birleştirilmiştir. Son olarak, ortalaması alınarak birleştirilen bantlara, sınıflandırma için kullanılacak özneliliklerin elde edilmesi için özyinelemeli filtreleme işlemi uygulanmıştır. Üç farklı HS veri setinde deneyler gerçekleştirilmiştir. Deneylerin sonuçları, önerilen yöntemin, yaygın olarak kullanılan piksel tabanlı (SVM vb...) sınıflandırıcılardan ve spektral-uzamsal tabanlı sınıflandırıcılardan daha iyi sonuçlar verdiği ve hesaplama verimliliğini artırdığını göstermiştir.

Gagnon vd. (2015), çalışan bir teknenin baca dumanının görüntülenmesi, orta dalga boyu (3 - 5 μm) KÖ HS görüntüleme kullanılarak gerçekleştirmiştir. Yanma sonucu oluşan gazların kantitatif kimyasal görüntülemesi, ışımsal transfer modeli uygulanarak elde edilmiştir. Herhangi bir ek ekipman kurulmasına gerek kalmadan yanma işlemi karakterize edilerek, gemi dumanı karakterizasyonu için kullanılmıştır. Karakterizasyon esnasında kırmızı ve mavi CO₂ uç bölgelerinden faydalanılmıştır.

Boggavarapu ve Prabukumar (2017), sınıflandırma için hiperspektral görüntülere uygulanan çeşitli yeni teknolojileri incelemiştir. Bu yazıda, geleneksel denetimli,

denetimsiz ve yarı denetimli yöntemlerden, aktif öğrenme ve dönüştürme öğrenme gibi çeşitli sınıflandırma algoritmaları tartışılmıştır.

Ghamisi vd. (2017), yedi geniş başlıkta kategorize edilen, özellikle hiperspektral veri analizine odaklanan kapsamlı bir bakış sunmuştur. Yedi ana başlık: sınıflandırma, spektral ayrıştırma, boyut azaltımı, çözünürlük iyileştirme, gürültü giderme – restorasyon, değişiklik algılama ve hızlı hesaplama olarak verilmiştir. Her konu için, farklı metodolojilerin doğrulanması ve değerlendirilmesi için son teknoloji yaklaşımların ve sayısal sonuçların bir özeti, karşılaşılan zorluklar ve araştırma yönergelerinin bir tartışması sunulmuştur.

Ghamisi, Plaza, vd. (2017), çeşitli algoritma konfigürasyonları, hızları ve otomasyon yetenekleri gibi özellikler üzerinde durularak denetimli hiperspektral sınıflandırma yöntemlerinin bir incelemesini yapmıştır. Sınıflandırma yaklaşımlarının avantajları ve dezavantajları çeşitli açılardan değerlendirilmiştir. SVM, RF, sinir ağları, derin yaklaşımlar, lojistik regresyon temelli yaklaşımlar ve seyrek temsil tabanlı sınıflandırıcılar gibi sık kullanılan yöntemler karşılaştırılmıştır. Bu çalışmanın sonucunda, sürekli olarak en iyi performansı gösteren bir sınıflandırıcının olmadığı ve farklı senaryolar için farklı yöntemlerin iyi sonuçlar verdiği değerlendirilmiştir.

Kang vd. (2017), hiperspektral görüntü sınıflandırma için yeni bir temel bileşen analizine (PCA) dayanan kenar korumalı (EPFs) öznitelik çıkarımı önermişlerdir. Önerilen yöntem, standart kenar koruma filtreleme tabanlı öznitelik çıkarma ve PCA tabanlı öznitelik birleştirme olmak üzere iki aşamadan oluşmaktadır. PCA'nın avantajı, farklı parameter ayarları ile elde edilen EPF'leri etkin bir şekilde birleştirebilmesinin yanı sıra EPF'lerdeki sınıf ayrılabilirliğini de artırabilmesidir. Elde edilen PCA-EFP'ler, destek vektör makinesi (SVM) kullanılarak sınıflandırılmıştır. Deneysel sonuçlar, standart EPF'ler ve yakın zamanda önerilen diğer HS görüntü sınıflandırma yöntemleri ile karşılaştırıldığında, önerilen PCA-EFP'ler yönteminin, özellikle eğitim örneklerinin sayısı sınırlı olduğunda, üç gerçek hiperspektral veri setinde çok daha yüksek sınıflandırma doğrulukları elde edebildiğini göstermiştir. Önerilen yöntemin

parametrelerinin manuel olarak ayarlanması, gerçek zamanlı uygulamalarda uygulanabilirliğini azaltmaktadır.

Vaddi ve Prabukumar (2017), birkaç öznitelik çıkarım yaklaşımının avantajlarını ve dezavantajlarını belirtilen kısa bir karşılaştırılma sunmuşlardır. Hiperspektral uzaktan algılamada sınıflandırma işleminin başarısı, öznitelik çıkarımı yöntemine bağlı olarak değişebilir. Bu inceleme, spektral, uzamsal, spektral ve uzamsal temelli özniteliklerin kombinasyonunu ve daha birçok yeni yöntemi içeren öznitelik çıkarma yöntemlerinin analizine odaklanmaktadır.

Han vd. (2018), hedef tespiti için alt blok düzeyinde oran-fark ortak yerel kontrast ölçümü (SRLDCM) adlı bir yöntem önermişlerdir. Bu teknik, gerçek küçük hedefi belirgin hale getirirken arka planı bastırabilmektedir. Bu yöntem her piksel için değil alt bloklar için hesaplanmaktadır. Bu nedenle hesaplama hızı artmaktadır. Sekiz KÖ çerçeve üzerindeki deneysel sonuçlar, önerilen algoritmanın algılama hızı ve yanlış alarm oranında iyi bir performans elde edeceğini göstermiştir.

Huang ve Huang (2018), hedef tespiti için fuzzy fusion ve fusion segmentation yöntemleri önerilmiştir. Fusion, arka planı ortadan kaldırabilen, gürültüyü kısıtlayabilen ve hedefi geliştirebilen karakteristik bantlardan görüntülerin bir kombinasyonudur. Son algılamayı tamamlamak için threshold segmentasyonu ve fuzzy algoritması, fusion algoritması ile birlikte kullanılmıştır. Simülasyon deneyinde, füze bulutu tespit edilecek hedef olarak, atmosfer, bulut ve jet egzoz gazı tespit arka planı olarak kabul edilmiş ve karakteristik spektrum tespiti ve önerilen algoritmanın avantajları SNR, SCR, ROC eğrilerinden ve zaman grafiğinden doğrulanmıştır.

Audebert vd. (2020), hiperspektral görüntülerin sınıflandırılmasında önceden kullanılan makina öğrenmesi yöntemlerini ve şuanda kullanılan derin öğrenme yöntemlerini gözden geçirerek karşılaştırmasını yapmışlardır. Sınıflandırma işlemi çeşitli hiperspektral verilere uygulanmış ve sonuçlar incelenmiştir. Çeşitli ağ mimarisi ailelerinin karşılaştırmalı bir çalışması yapılmış ve bu yöntemlerin kullanılabilmesini sağlayacak bir yazılım araç kutusu oluşturulmuştur. Sınıflandırma işleminden önce

yapılacak normalizasyon, bant seçimi ve boyut azaltımı gibi ön işlemlerden de çalışmada bahsedilmiştir. Aynı zamanda bu çalışmada hiperspektral görüntülerin kullanımında karşılaşılan sorunlar ve zorluklar da belirtilmiştir.

Ji, Wang, ve Geng (2019) çalışmasında, gürültülü bant kaldırma ve hedef tespiti arasında bir bağ kurulmuştur. Eşleşen filtre ağırlık katsayılarının, hedefin arka plandan ayırt edilmesinde bantların önemini göstermektedir. Bu gerçeğe dayanarak, bir sahneden rastgele seçilmiş çoklu hedef piksellerin ortalama ağırlıkları kullanılarak otomatik gürültülü bant kaldırma yöntemi geliştirilmiştir. Bu yöntem normalize edilmiş eşleşen filtre yöntemi olarak isimlendirilmiştir. Seçilen hedeflerin yüzdesinin toplam veriye göre %1'den daha büyük olması durumunda istikrarlı sonuçlar elde edildiği söylenmiştir. Beş farklı bant seçim yöntemiyle, önerilen yöntemi kıyaslamak için üç adet HS görüntüsü kullanılmıştır. Deneysel sonuçlar, gürültülü bantları bulmada iyi sonuçlar verdiğini, etiketlenmiş gürültülü bantlar ile birlikte etiketlenmemiş gürültülü bantları tespit ettiği ve sınıflandırma doğruluğunu iyileştirdiğini göstermiştir.

Sun ve Du (2019), altı ana kategoride sınıflandırılabilen mevcut hiperspektral bant seçim yöntemlerini gözden geçirmiştir. Bu yöntemler: sıralama tabanlı, arama tabanlı, kümeleme tabanlı, seyreklik tabanlı, öğrenme tabanlı ve hibrit tabanlıdır. Yaygın olarak kullanılan iki hiperspektral veri seti kullanılarak bir kaç bant seçim yönteminin sınıflandırma performansı gösterilmiştir. Hiperspektral bant seçim yöntemlerinin zorlukları ve araştırma yönleri de tartışılmıştır.

Kim vd. (2020), orta dalga spektral görüntülemeye karbon dioksit çift uç (carbon dioxide double spike, CO₂-DS) adı verilen bir yaklaşım önerilmiştir. Önerilen yaklaşım, sıcak CO₂ yayılım bandının CO₂ emilim bandından daha geniş olmasına ve CO₂ emilin bandı etrafındaki çift uça dayanmaktadır. CO₂ bandının spektral iletimi 4.21 – 4.31 μm (2375 – 2320 cm^{-1}) bant aralığında mesafeye de bağlı olarak azalmaktadır. Sıcak CO₂ yayılımı, yaklaşık olarak 4.16 μm (2400 cm^{-1}) ve 4.34 μm (2300 cm^{-1}) etrafında yükselme yapmaktadır. İlk yükselme 4.347 – 4.587 μm (2300 – 2180 cm^{-1}) aralığında ve ikinci yükselme 4.081 – 4.201 (2450 – 2380 cm^{-1}) μm aralığında gerçekleşir. Yönlü ortalama çıkarma filtresi uygulanarak CO₂ emilim bandının etrafındaki her iki uç

algılanır ve nihai hedefler, bu algılamanın ortak kullanımıyla tespit edilir. Deniz ortamında Telops firmasına ait MWIR HS görüntüleme sisteminin kullanımıyla yapılan deneylerde, önerilen yöntemin gemi hedeflerinin tespitini iyileştirdiği gösterilmiştir.

Kumar vd. (2020), çeşitli öznitelik çıkarma tekniklerinin bir incelemesini sunmuşlardır. Bu çalışmada, öznitelik çıkarma yöntemleri üç ana başlık altında toplanmıştır. Bunlar, spektral, uzamsal ve spektral – uzamsal öznitelik çıkarma yöntemleridir. Bu yöntemlerin güçlü ve zayıf yönleri belirtilmiştir. Farklı öznitelik tekniklerini değerlendirmek için iki hiperspektral görüntü deneyler için kullanılmıştır. Teknikleri değerlendirmek için yöntemler uygulandıktan sonra sınıflandırma işlemi görüntülere uygulanmıştır. Uzamsal özniteliklerin, sınıflandırma doğruluğunu arttıracak tamamlayıcı bilgileri sağladığı gözlemlenmiştir. Derin öğrenme tekniklerinin de umut verici performanslar sergilediği görülmüştür.

Pathak, Kumar Kalita, ve Bhattacharya (2020) çalışmasında, HS görüntü sınıflandırılmasında kullanılan ensemble öğrenme teknikleri için karşılaştırma yapılmıştır. Hem spektral hem de uzamsal özniteliklerin çıkarılmasında RF, XGBoost ve AdaBoost yöntemlerinden faydalanılmıştır. AdaBoost iki öğrenici ile kullanılmıştır. Bunlar, karar ağacı ve SVM'dir. Deneyler iki HS veri seti üzerinde gerçekleştirilmiştir. Temel öğrenici olarak SVM ile AdaBoost kullanımının iyi sonuçlar verdiği gösterilmiştir.


3. MATERYAL VE YÖNTEM

Bu bölümde hiperspektral görüntülerdeki nesnelerin sınıflandırma aşamasında kullanılan veriler ve yöntemler hakkında bilgiler alt başlıklar ile verilmiştir.

3.1 Veri Seti

Hiperspektral verilerin sınıflandırılması amacıyla gerçekleştirilen bu çalışmada, gerçek füze atışı denemesinden elde edilen hiperspektral veriler kullanılmıştır. Kullanılan veriler farklı günlerde, çeşitli noktalardan ve değişen mesafelerden alınmıştır. Kamera, kullanıcı tarafından ayarlanabilen spektral çözünürlüğe sahiptir. Toplanan kızılötesi ışımlar Michelson interferometresi tarafından sağlanan modülasyon ile elde edilir. Ardından bir odak düzlemi dizisinin (FPA, Focal Plane Array) her pikselinde yüksek çözünürlüklü bir spektrum kaydedilir.

Elde edilen hiperspektral verilerin kapsadığı en geniş bant aralığı 1.5-5.5 μm 'dir. Hiperspektral görüntüler ilgili bant aralığının 41 alt bantta sezimi sonucunda oluşmuştur. Başka bir ifade ile, elde edilen hiperspektral görüntüler 41 banda sahiptir. Bu bantlarda aynı görüntü her bir bant için farklı imzalara sahip olmaktadır. İlgili alt bantlar, elektromanyetik spektrumda farklı aralıklara denk gelmektedir. Hiperspektral verileri oluşturan 41 bandın elektromanyetik spektrumdaki aralıkları Şekil 3.1 ile gösterilmiştir. Elde edilen ışıma değerlerinin birimi $\text{watt}/(\text{steradian} * \text{cm}^{-1}) \mu\text{m}$ olarak elde edilmiştir.



Şekil 3.1 Hiperspektral Verileri Oluşturan 41 Bandın Elektromanyetik Spektrumdaki Aralıkları

Hiperspektral verilerin sınıflandırılmasında eğitim ve test verisi olarak kullanmak amacı ile hiperspektral görüntülerden piksel değerleri toplanmıştır. Sınıflandırma sonucunda tespit edilmeye çalışılan sınıfların etiketleri ise aşağıda listelenmiştir:

- Füze (Missile)
- Yeryüzü (Ground)
- Gökyüzü (Sky)
- Bulut (Cloud)
- Egzoz Dumanı (Plume)

Bu çalışmada 194 adet hiperspektral görüntü kullanılmıştır. Kullanılan her görüntü 256 satır 320 sütun ve 41 dalga boyuna sahip bir hiperküp veridir. Bu üç boyutlu veri, sınıflandırma amacıyla kullanılacağı için 41 x 81920 boyutlarına sahip iki boyutlu bir veriye dönüştürülmüştür. 81920 değeri 256 x 320 çarpımının sonucudur. Dolayısıyla elde edilen 41 x 81920 boyutlu matrisin her satırı, hiperspektral görüntünün bir bandını temsil etmektedir. Kullanılan görüntüler 3 farklı tipte ifade edilebilir:

- Füze verisi bulunduranlar
- Sadece arkaplan verisi bulunduranlar
- Hem arkaplan hem de egzoz dumanı verisi bulunduranlar

3.2 Hiperspektral Verilerin İncelenmesi


Açık literatür incelendiğinde, hiperspektral olarak alınmış kamera kayıtları kullanılarak çok çeşitli işlemlerin gerçekleştirilebildiği görülmektedir. Fakat bu işlemler içerisinde güdümlü füze tespiti özelinde yapılmış çok fazla çalışma bulunmamaktadır. Bu çalışma kapsamında özellikle güdümlü füzelerin hiperspektral veriler kullanılarak tespiti üzerine yoğunlaşmıştır. Çalışmada temel anlamda hiperspektral görüntüler içerisindeki spektral öznitelikler dikkate alınarak sahnedeki varlıkların eğitilmiş sınıflandırılması işlemi gerçekleştirilmiştir.

Bu çalışma kapsamında hiperspektral görüntülerdeki yeryüzü, gökyüzü, bulutlar, güdümlü füze ve güdümlü füzenin ardında bıraktığı duman birbirinden ayrılmaya

çalışılmıştır. Yukarıda belirtilen araştırma konusu ile ilgili detaylı bilgiler ve incelemeler/analizler neticesinde elde edilen sonuçlar takip eden alt ayrımlarda verilmiştir.

3.2.1 Sınıflandırma modellerinin eğitim safhası

Hiperspektral verilerin sınıflandırılması amacı ile çeşitli incelemeler gerçekleştirilmiştir. Gerçekleştirilen incelemelerin ilki olan hiperspektral kamera ile kayıtları alınan sahnedeki nesnelerin birbirinden ayırt edilme çalışması, kendi içerisinde de alt adımlardan oluşmaktadır. Nihai olarak kullanılan metodolojinin şematik gösterimi Şekil 3.2 ile verilmiştir.



Şekil 3.2 Sınıflandırma modellerinin eğitimi için kullanılan metodoloji

Bu bölümde hiperspektral görüntülerden elde edilen veriler kullanılarak çeşitli sınıflandırma algoritmalarının eğitilmesi üzerine yapılan çalışmalar özetlenmiştir. Yapılan işlemler kapsamında temel olarak iki ana işlem gerçekleştirilmiştir. İşlemlerden birincisi çok boyutlu veri üzerinde boyut azaltımının gerçekleştirilmesidir. Bu işlem, genel itibarıyla çok daha yüksek sayıda boyuta sahip olan hiperspektral veriler üzerinde (örneğin 200 bant) uygulanan bir işlemdir. Bununla birlikte, sınıflandırma başarımını artırmak amacıyla bu uygulamada da kullanılmıştır. Uygulama kapsamında gerçekleştirilen ikinci ana işlem ise sınıflandırma algoritmalarının eğitilmesidir.

İncelemelerde ilk olarak hiperspektral görüntüler nomalize edilerek sahnedeki nesnelerin ışıma değerleri 0 – 1 arasına ölçeklendirilmiştir. Daha sonra hiperspektral görüntülerden, sahnedeki nesnelere ait örnek pikseller toplanmış sınıflandırma algoritmalarında eğitim ve test verileri olarak kullanılacak hale getirilmiştir. İlgili nesneler füze, yeryüzü, gökyüzü, bulut, egzoz dumanı olarak etiketlenmiştir. Füze olarak etiketlenen pikseller görüntüdeki füzenin en sıcak bölgesinden, yeryüzü olarak etiketlenen pikseller görüntüdeki yeryüzü bölgesinden, gökyüzü olarak etiketlenen pikseller görüntüdeki bulutsuz mavi gökyüzü bölgesinden, bulut olarak etiketlenen pikseller görüntüdeki bulut bölgesinden ve egzoz dumanı olarak etiketlenen pikseller ise görüntüdeki füze egzoz dumanı bölgesinden alınan piksel örnekleridir.

Çalışmanın ikinci kısmında ise, sınıflandırma modellerinin hiperspektral veriler kullanılarak eğitilmesi aşaması başlamaktadır. Bu aşamada öncelikle öznitelik çıkarımı, ardından sınıflandırma modellerinin eğitilmesi gerçekleştirilmiştir. Öznitelik çıkarımı ve sınıflandırma işlemleri sonucunda hiperspektral verilerin füze, yeryüzü, gökyüzü, bulut ve egzoz dumanı sınıflarına ayrılması beklenmektedir. İlgili işlemler ile ilgili detaylar takip eden alt ayrımlarda verilmiştir.

3.2.1.1 Normalizasyon işlemi

Çalışmada farklı zamanlarda, farklı noktalardan ve farklı mesafelerden alınan 194 adet görüntü kullanılmıştır. Alınan görüntülerin hepsinde füze verisi bulunmamaktadır. Bazı veriler sadece arkaplan görüntüsünden oluşurken bazı veriler ise arkaplana ek olarak füze egzoz dumanı verisi bulunmaktadır. Belirli bir günde alınan tek bir görüntü veya tek bir günde alınan görüntü dizisi kullanılmadığından, incelenecek hiperspektral verilerin belirli bir skalaya ölçeklendirilmesi gerekmektedir. Böylece farklı sınıflara ait verilerin benzer aralıklara ölçeklendirilmesi sağlanmıştır.

Bu çalışmada hiperspektral görüntülerin ışıma değerleri normalize edilerek 0 – 1 aralığına ölçeklendirilmiştir. Normalizasyon işlemi için tüm hiperspektral görüntüler art arda eklenerek 2 boyutlu bir matris oluşturulur. Elde edilen matrisin boyutu (194 x 81920) x 41'dir. Sonrasında, 41 dalga boyu için minimum ve maksimum değerler

bulunarak, tüm dalgaboyları için minimum ve maksimum değerleri bulunduran 2 adet 1 x 41'lik vektör elde edilmiştir. Elde edilen minimum ve maksimum vektörler kullanılarak hiperspektral veriler aşağıdaki formüle göre 0 – 1 arasına ölçeklendirilmiştir:

$$\text{NormalizeHS}_{2D} = \frac{\text{HS}_{2D} - \text{MinVek}}{\text{MaxVek} - \text{MinVek}} \quad (3.1)$$

burada HS_{2D} ile 2 boyutlu hiperspektral veri, MaxVek ve MinVek ile maksimum ve minimum ışıma değerleri ifade edilmiştir.

3.2.1.2 Piksel örnekleme

Veri setinin oluşturulması amacıyla görüntü üzerinden çok sayıda piksel seçimi yapılarak sahnedeki farklı tipte kaynaklara ait piksel ışıma değerleri toplanmıştır.

Çalışma sonucunda veri setinde;

- Füze için 5292
- Yeryüzü için 145799
- Gökyüzü için 359629
- Bulut için 139651
- Egzoz Dumanı için 12873

adet piksel ve bu piksellere ait ışıma değerleri toplanmıştır. Veri seti yapısı her sınıf için,

- Hiperspektral görüntü ve seçim yapılan piksel isimleri
- Piksel değerlerine ait dalga boylarına göre ışıma değerleri

şeklinde düzenlenerek, kaydedirilmiştir.


3.2.1.3 Boyut azaltımı

Boyut azaltımı işlemi, özellikle yüksek bant sayısına sahip veriler kullanılarak yapılan sınıflandırma çalışmalarının daha verimli ve hızlı bir şekilde gerçekleştirilmesi amacıyla

kullanılan bir yöntemdir. Bu çalışmada da nispeten yüksek boyutlu bir veri ile çalışılması sebebiyle, üzerinde çalışılan hiperspektral veriye boyut azaltımı işlemi uygulanmıştır.


Boyut azaltımı işlemi gerçekleştirilirken cevap verilmesi gereken iki temel soru vardır. Bunlardan birincisi boyut azaltımı için hangi algoritmanın kullanılacağı, ikincisi ise çok boyutlu verinin kaç boyuta düşürüleceğidir. Birinci sorunun cevabını bulabilmek amacıyla literatürde kullanılan dört farklı algoritma denenmiş ve başarımları gözlenmiştir. Sınıflandırma algoritmalarının eğitim aşamasında kullanılacak verilere literatürde bulunan dört farklı boyut azaltımı algoritması uygulanmış ve her yöntem için elde edilen dört adet dönüşüm matrisi bölüm 3.2.2 ile belirtilen 194 adet veri küpünün sınıflandırılması aşamasında kullanılmıştır.

Çok boyutlu verinin kaç boyuta düşürüleceği ile ilgili bir inceleme de gerçekleştirilmiştir. Temel boyut azaltımı algoritmalarından biri olan PCA kullanılarak çok boyutlu veri 1 – 20 arasındaki tüm tam sayılara sırasıyla boyut olarak düşürülmüş ve elde edilen boyutu düşürülmüş veriler kullanılarak Adaboost sınıflandırma algoritması füze verilerine 1 çıktısını diğer dört sınıftan oluşturulan verinin çıktılarına ise 0 değerini ataması için eğitilmiştir. Birinci AdaBoost modeli bir özelliğe sahip veri ile ikinci AdaBoost modeli 2 özelliğe sahip veri ile ve son AdaBoost modeli de 20 özelliğe sahip veri ile eğitilmiştir. Son aşamada 1 – 20 arası öznetelik için eğitilen 20 adet sınıflandırma modellerinin başarımları oluşturulan test verisi üzerinde incelenmiştir. Şekil 3.3 ile 1 - 20 arasında boyut için füze verisi kullanılarak elde edilen sınıflandırma doğruluğu grafiği verilmiştir.



Şekil 3.3 Farklı sayılarda öznitelikler için füze verilerinin sınıflandırma doğruluğu

Boyut sayısına göre sınıflandırma doğruluğu grafiği çizdirildiğinde 10 öznitelikten sonra doğruluk değerlerinde değişim sabit ilerlediğinden 10 öznitelik kullanmanın yeterli olduğu değerlendirilmiştir. Esasen burada sınıflandırma başarımının dirsek yaptığı 4 değerinin kullanılması da söz konusu olabilir, fakat başarımın daha yüksek olması amacıyla sınıflandırma aşamalarında 10 değeri kullanılmıştır.



Şekil 3.4 Öznitelik çıkarımı akış şeması

3.2.1.3.1 Temel bileşen analizi (PCA)

Hiperspektral görüntü bantları genellikle yüksek oranda ilintilidir, yani benzer özelliklere sahiptirler. Bu nedenle tüm bantların kullanımı bazı uygulamalarda fazlalık olmakla birlikte, işlem yükünü de arttırmaktadır. Temel bileşenler analizi, bu fazlalığı kaldırmak için kullanılan öznitelik uzayı dönüşümüdür (Schowengerdt 2012).

Temel bileşen analizinin ana fikri, birbiriyle ilişkili çok sayıda değişkenden oluşan bir veri setinin boyutsallığını azaltırken, veri setinde mevcut olan varyansı mümkün olduğunca korumaktır (Mishra vd 2017) Bu, birbiriyle ilintisiz ve ilk birkaç değişkenin orijinal değişkenlerde mevcut olan bilgi miktarının çoğunu koruyacak şekilde sıralandığı yeni bir veri kümesine dönüştürülerek yapılır. Yeni veri kümesindeki sıralı değişkenlere temel bileşenler denir. Bu temel bileşenler özvektörler ve öz değişkenler ile belirlenmektedir. Özvektörler ve özdeğerler, kare matrislerle ilişkili vektörler ve sayılardır. Birlikte bir matrisin özayırışmasını sağlarlar.

Her özdeğer, yeni koordinat eksenleri boyunca ilgili temel bileşen görüntüsünün varyansına eşittir ve tüm özdeğerlerin toplamı, orijinal görüntünün tüm bant

varyanslarının toplamına eşit olmalıdır, böylece verilerdeki toplam varyans korunur (Schowengerdt 2012).

Özdeğerler matrisi köşegen olduğundan, temel bileşenler ilintisizdir ve ilk eleman en büyük varyansa ve son eleman en düşük varyansa sahip olacak şekilde azalan varyansa göre sıralanır. Sonuç olarak, toplam görüntü varyansının çoğunun daha az boyut ile ifade edilmesiyle, orijinal K boyutlu verideki mevcut olan korelasyon kaldırılabilir (Schowengerdt 2012).

Temel bileşen koordinat eksenleri, her bir özdeğer (λ_k) için vektör matris denkleminde elde edilen K özvektörleri (e_k) ile tanımlanır.

$$(C - \lambda_k I)e_k = 0 \quad (3.2)$$

burada C ile hiperspektral bantlarının kovaryans matrisi, e_k ile C matrisinin özvektörleri ve λ_k ile özdeğerler ifade edilmiştir. Özvektörler, dönüşüm matrisinin (W_{pc}) satırlarını oluşturur.

$$W_{pc} = \begin{bmatrix} e_{11} & \cdots & e_{1K} \\ \vdots & \ddots & \vdots \\ e_{K1} & \cdots & e_{KK} \end{bmatrix} \quad (3.3)$$

e_{ij} , i. özvektörün j. elemanıdır. Dönüşüm matrisi kullanılarak PCA işlemi denklem (3.4) ile verildiği gibi gerçekleştirilir.

$$Data_{PCA} = W_{pc} * Data_{orijinal} \quad (3.4)$$

PCA sonucu elde edilen veriler, orijinal verilerin yeni eksenlere yansıtılmasından kaynaklanır. Dönüştürülen verilerde, toplam görüntü varyansı optimal şekilde dağıtılır. İlk temel bileşen, orijinal bantların herhangi bir lineer kombinasyonu için mümkün olan maksimum varyansı içerir, ikinci temel bileşen, birinci temel bileşene dik olan herhangi bir eksen için mümkün olan maksimum varyansı içerir ve algoritma böyle devam eder (Schowengerdt 2012). Toplam görüntü varyansı, PCA tarafından korunur.

Özetlemek gerekirse, PCA aşağıdaki adımlar ile gerçekleştirilir (Mishra vd 2017):

1. Veri seti belirlenir.
2. Kovaryans matrix hesaplanır.
3. Kovaryans matrisin özvektörleri ve özdeğerleri hesaplanır.
4. Bileşenler seçilerek dönüşüm matrisi oluşturulur. Boyut azaltımı bu adımda yapılmaktadır. Kovaryans matrisinden özvektörler bulunduğunda, bir sonraki adım bunların özdeğerlerine göre en yüksekten en düşüğe sıralamaktır. Bu işlem sonunda bileşenler önem sırasına göre elde edilir ve dönüşüm matrisi oluşturulur. Önem sırasına göre daha az öneme sahip bileşenler dışarıda bırakılabilir. Böylece nihai veri seti orijinalinden daha az boyuta sahip olur.
5. Yeni veri seti oluşturulur. Oluşturulan yeni veri seti, orijinal veri setindeki bilgi miktarını en çok karşılar ve önemsiz olanları dışarıda bırakır. Böylece işlem sonunda original verinin boyutu azaltılmış olur. Yeni veri setinde, orijinal veri setinde bulunan bilgi miktarının korunması için özvektörler her zaman birbirine diktir.

3.2.1.3.2 Bağımsız bileşenler analizi (ICA)

Bağımsız bileşenler analizi (ICA), bileşenlerin istatistiksel olarak bağımsız veya mümkün olduğunca bağımsız olması için Gauss dağılımına sahip olmayan verilerin doğrusal bir temsilini bulmayı amaçlayan yöntemdir. ICA yöntemi, kokteyl parti denilen bir örnekle anlatılmaktadır (Hyvärinen ve Oja 2000). Bir odada farklı konumlarda iki mikrofon bulunduğu ve iki kişinin de aynı anda konuştuğu düşünülmektedir. Mikrofonlar iki adet zamana bağlı sinyal kaydeder ve bunlar $x_1(t)$ ve $x_2(t)$ ile gösterilir. Bu sinyallere gözlemlenen sinyaller (observed signals) denebilir. Burada x_1 ve x_2 sinyallerin genliklerini ve t ise zaman indeksini göstermektedir. Bu kaydedilen sinyaller, odada bulunan iki konuşmacı tarafından yayılan konuşma sinyallerinin ($s_1(t)$ ve $s_2(t)$) ağırlıklı toplamıdır. Bu sinyaller de kaynak sinyalleri olarak isimlendirilmektedir. Bu durum doğrusal bir denklem olarak ifade edilebilir:

$$x_1(t) = a_{11}s_1 + a_{12}s_2 \quad (3.5)$$

$$x_2(t) = a_{21}s_1 + a_{22}s_2 \quad (3.6)$$

burada, a_{11} , a_{12} , a_{21} ve a_{22} , mikrofonların konuşmacılardan uzaklığına bağlı olan bazı parametrelerdir. Sadece kaydedilen $x_1(t)$ ve $x_2(t)$ sinyallerini kullanarak iki konuşmacıya ait orijinal sinyallerin $s_1(t)$ ve $s_2(t)$ tahmin edilmesi istenmektedir. Buna kokteyl partisi problemi denir (Hyvärinen ve Oja 2000).

Eğer a_{ij} parametreleri bilinseydi, denklem (0.5) ve (0.6) klasik yöntemlerle çözülebilirdi (Hyvärinen ve Oja 2000). Ancak genellikle bu katsayılar bilinmemektedir ve bu durum problemi daha da zorlaştırmaktadır. Bu sorunu çözmeye yönelik bir yaklaşım, a_{ij} parametrelerini tahmin etmek için kaynak sinyallerinin istatistiksel özelliklerinden faydalanılmasıdır. $s_1(t)$ ve $s_2(t)$ sinyallerinin her t anı için istatistiksel olarak bağımsız oldukları varsayılmaktadır (Hyvärinen ve Oja 2000). ICA yöntemi kullanılarak, bu istatistiksel bağımsızlığa dayanarak a katsayıları tahmin edilerek gözlemlenen sinyallerden (x_1 ve x_2), orijinal kaynak sinyalleri (s_1 ve s_2) ayrılabilir (Hyvärinen ve Oja 2000).

ICA'yı matematiksel olarak tanımlamak için gizli değişkenler (latent variables) modeli kullanılmaktadır (Hyvärinen ve Oja 2000). n adet bağımsız bileşenin doğrusal karışımının ($x_1, x_2, \dots, x_n$) ifadesi aşağıda verilmektedir.

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n \quad (3.7)$$

Denklem (3.7), vektör matris gösterimiyle de ifade edilebilmektedir:

$$x = As \quad (3.8)$$


Denklem (3.8) aşağıdaki gibi de ifade edilebilmektedir:

$$x = \sum_{i=1}^n a_i s_i \quad (3.9)$$

Yukarıda verilen istatistiksel model, bağımsız bileşenler analizi olarak isimlendirilmektedir. Hem karışım değişkenleri hem de bağımsız değişkenler sıfır

ortalamaya sahip olmalıdır (Hyvärinen ve Oja 2000). Gözlemlenen x değerleri kokteyl parti problemindeki mikrofona kaydedilen sinyaller olarak düşünülebilirler. Denklem 37’de bağımsız değişkenler, doğrudan gözlemlenemezler, yani gizli değişkenlerdir. Aynı zamanda karışım matrisinin (mixing matrix, A) de bilinmediği varsayılmaktadır. Elde sadece gözlemlenen x değişkenleri bulunmaktadır ve bazı varsayımlar altında hem A hem de s tahmin edilmelidir. ICA’yı kullanmak için aşağıdaki varsayımlar yapılmalıdır (Hyvärinen ve Oja 2000):

1. Bağımsız bileşenler (s), birbirinden istatistiksel olarak bağımsızdır. Temel olarak iki rastgele değişkenden biri diğeri hakkında bir bilgi vermiyorsa, değişkenlerin bağımsız olduğu söylenmektedir. s değişkenleri istatistiksel olarak bağımsızken x değişkenleri istatistiksel olarak bağımsız değildir (Hyvärinen ve Oja 2000). Teknik olarak bağımsızlık, olasılık yoğunlukları ile tanımlanmaktadır. İki rastgele değişkenin, y_1 ve y_2 , olasılık yoğunluk fonksiyonları çarpanlarına ayrılabiliriyorsa bağımsız oldukları söylenebilir, $p(y_1, y_2) = p_1(y_1) \times p_2(y_2)$. İlintisizlik özelliği her zaman sinyallerin bağımsız olduğunu ifade etmez. Ancak, bağımsızlık, sinyallerin ilintisiz olduğunu belirttiğinden, çoğu ICA yöntemi, tahmin prosedürünü her zaman bağımsız bileşenlerin ilintisiz tahminlerini verecek şekilde sınırlandırmaktadır (Hyvärinen ve Oja 2000). Bu, parametre sayısını azaltır ve sorunu basitleştirir.
2. Bağımsız değişkenler, Gauss olmayan dağılıma sahip olmalıdır. Gauss dağılımına sahip değişkenlerin ICA yöntemini nasıl etkilediğini göstermek için, karışım matrisinin ortogonal olduğu ve s_i değişkenlerinin Gauss dağılımına sahip olduğu düşünölsün. O halde x_1 ve x_2 değişkenleri Gauss dağılımına sahip, ilintisiz ve birim varyanslıdır. Bu değişkenleri ortak dağılımları (joint density) Şekil 3.5 ile gösterilmektedir (Hyvärinen ve Oja 2000).



Şekil 3.5 İki bağımsız gauss değişkeninin dağılımı

Şekilden, yoğunluğun tamamen simetrik olduğu ve A karışım matrisine ait sütunların yönleri hakkında herhangi bir bilgi elde edilemediği görülmektedir. Bu nedenle A tahmin edilemez (Hyvärinen ve Oja 2000). Gauss dağılımına sahip değişkenler olduğunda, ICA modeli sadece ortogonal bir dönüşüme kadar tahmin edilebilir. Bu nedenle, A matrisi Gauss bağımsız değişkenleri için tanımlanamaz (Hyvärinen ve Oja 2000).

3. Karışım matrisi kare olmalıdır, ancak bu durum gevşetilebilmektedir.

Karışım (mixing) matrisi A, tahmin edildikten sonra bu matrisin tersi W, hesaplanabilmektedir. Bu işlemler yapıldıktan sonra bağımsız bileşenler aşağıdaki gibi elde edilebilir:

$$s = Wx \quad (3.10)$$

Denklem (3.8) incelendiğinde ICA modelinde aşağıdaki belirsizliklerin olduğu görülmektedir (Hyvärinen ve Oja 2000):

1. Bağımsız bileşenlerin varyansları belirlenememektedir. Bunun nedeni, hem s hem de A bilinmediğinden, s_i bileşenlerinden birindeki herhangi bir skaler çarpan, A matrisinde bu bileşene karşılık gelen sütunun aynı skalere bölünmesiyle iptal edilebilmesidir. Sonuç olarak, bağımsız bileşenlerin büyüklükleri sabitlenebilir. Bunlar, rastgele değişkenler oldukları için her birinin

birim varyansa sahip olduğu varsayılmaktadır, $E\{s_i^2\} = 1$, ve bu nedenle, beyazlatma işlemi veriye uygulanmaktadır.

2. Bağımsız bileşenlerin sırası bilinmemektedir. Bunun nedeni, hem s hem de A bilinmediği için, denklem (3.8)'deki terimlerin sırasının değiştirilebilmesidir. Bu durumda bağımsız bileşenlerden herhangi biri ilk sıraya gelebilir.

3.2.1.3.3 Maksimum gürültü oranı (MNF)

Görüntü kalitesinin en yaygın ölçümlerinden biri sinyal gürültü oranıdır (SNR). PCA yönteminde varyansa göre bileşenler sıralanırken, maksimum gürültü oranı yönteminde SNR değerine göre bileşenler sıralanmaktadır (Green vd. 1988). Bu yöntemde, özvektörler kümesi, SNR değerini maksimize edecek şekilde elde edilmektedir. MNF dönüşümü, görüntü kalitesine göre sıralanmış yeni bileşenler üretir. Maksimum gürültü oranı (MNF), orijinal verilerin doğrusal bir dönüşümünü yapması açısından temel bileşen analizine (PCA) benzemektedir.

L adet banda sahip ve örneğin konumunun x ile ifade edildiği çok değişkenli bir veri setinin (Z) ifadesi aşağıdaki matematiksel denklem aşağıda verilmiştir (Green vd. 1988):

$$Z_i(x), i = 1, \dots, p \quad (3.11)$$

Toplam gürültü ekleme kullanılarak oluşturulan görüntü modeli aşağıdaki gibi ifade edilmektedir (Green vd. 1988):

$$Z(x) = S(x) + N(x) \quad (3.12)$$

$Z^T(x) = \{Z_1(x), \dots, Z_L(x)\}$ ile gürültü eklenmiş sinyal, $S(x)$ ve $N(x)$ ile de $Z(x)$ parametresinin korelasyonsuz sinyal ve gürültü bileşenleri ifade edilmektedir (Green vd. 1988). $Z(x)$ ifadesinin kovaryans matrisi aşağıdaki gibi gösterilmektedir (Green vd. 1988):

$$\text{Cov}\{Z(x)\} = \Sigma = \Sigma_S + \Sigma_N \quad (3.13)$$

Σ_N ve Σ_S terimleri, sırasıyla gürültü N ve sinyalin S kovaryans matrisleridir. Bant i için SNR değeri aşağıdaki gibi hesaplanmaktadır (Greco, Diani, ve Corsini 2006):

$$\text{SNR} = \frac{\text{Var}\{a_i^T Z\}}{\text{Var}\{a_i^T N\}} = \lambda_i \quad (3.14)$$

yukarıdaki ifadede $\text{Var}\{.\}$ ile varyans operatörü, λ_i terimi ile i. dönüşümde elde edilen SNR değeri verilmektedir. MNF yöntemi, SNR değerini maksimize eden doğrusal dönüşümü vermektedir (Greco vd. 2006). MNF işlemiyle orijinal veriye doğrusal dönüşüm uygulanarak, L banda sahip korelasyonsuz veri setinin elde edilmesi aşağıdaki matematiksel ifade ile verilmiştir:

$$Y_i(x) = a_i^T Z(x), i = 1, \dots, L \quad (3.15)$$

MNF dönüşümü matris formatında aşağıdaki gibi gösterilmektedir (Green vd. 1988):

$$Y(x) = A^T Z(x) \quad (3.16)$$

Yukarıdaki ifade de A ile doğrusal dönüşüm katsayıları ifade edilmektedir. Doğrusal dönüşüm katsayıları, aşağıda verilen özdeğer denkleminin çözülmesiyle bulunmaktadır (Gordon 2000):

$$A \Sigma_N A^{-1} = \Lambda A \quad (3.17)$$

Λ_i , a_i özvektörlerine karşılık gelen özdeğerlerin λ_i köşegen matrisidir (Gordon 2000). $Y_i(x)$ 'te bulunan gürültü oranı, λ_i ile verilmektedir. Böylece MNF dönüşümü uygulanmış veriler azalan gürültü oranına göre ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L$) sıralanmaktadır.

Denklem (3.17) kullanılarak doğrusal dönüşüm katsayılarını A hesaplayabilmek için ΣN parametresinin bilinmesi gerekmektedir. Ancak çoğu durumda, bu kovaryans matrisi bilinmez ve tahmin edilmesi gerekir.

Nielsen ve Larsen 1994, $N(x)$ tahmini için dört farklı yöntem sunmaktadır. Tüm yöntemler, uzamsal olarak ilişkilendirilebilen verilere güvenmektedir. $N(x)$ 'i hesaplamak için basit bir yöntem şu şekildedir:

$$N(x) = Z(x) - Z(x + k) \quad (3.18)$$

burada k , adım uzunluğudur ve $S(x) = S(x + k)$ olduğu varsayılmaktadır (Gordon 2000). Bu varsayımın doğru olmadığı ölçüde, $N(x)$ tahmini hatalıdır. Bu gürültü tahmin yöntemi kullanıldığında, MNF dönüşümü min/maks otokorelasyon faktörü dönüşümüne eşdeğerdir (Green vd. 1988).

Kullanılan görüntülerdeki nesnelerin spektral öznitelikleri ve sayıları sabit tutularak, sadece uzamsal konumları değiştirildiğinde, MNF yöntemi farklı sonuçlar verebilmektedir (Liu vd. 2009). PCA dönüşümünde bu durum meydana gelmemektedir. PCA dönüşümü piksel düzeyinde uygulandığından, piksellerin uzamsal düzeni nasıl değişirse değişsin, öznitelik çıkarım sonucu sabit kalmaktadır. MNF'nin piksellerin uzamsal değişimine göre farklı sonuç verme nedeni, piksellerin uzamsal düzenine ilişkin bilgiler, genellikle hiperspektral görüntülerin gürültü kovaryans matrisinin (NMF) tahmin edilmesinde kullanılmasıdır (Liu vd. 2009). Gürültü tahmin yöntemlerinin çoğu uzamsal alanda çalışmaktadır.

Bu çalışmada MNF dönüşümü hiperspektral veriye aşağıdaki adımlar izlenerek uygulanmıştır:

1. Σ_N ifadesinin tahmin edilmesi: Denklem (3.18) aşağıdaki gibi tekrar yazılabilir (Hundley 2013).

$$dZ(i, :) = Z(i, :) - Z(i + 1, :) \quad (3.19)$$

dZ matrisinin i . satırı, Z matrisinin i ve $i+1$ satırları arasındaki farktır. Bu ifadeden, $\text{Cov}(dZ) \cong \text{Cov}(N)$ çıkarımı yapılabilir (Hundley 2013).

2. Σ_N , kullanılarak, orthonormalize öz değer vektörü E ve öz değerlerin köşegen matrisi Λ_n hesaplanır, $E^T \Sigma_n E = \Lambda_n$ (Roger 1994).
3. Orijinal verinin beyazlatılması: beyazlatma işlemi, rastgele değişkenleri, ortogonalleştirmek için yapılan bir dönüşümdür (Kessy, Lewin, ve Strimmer 2018). Sıfır ortalamaya sahip bir x vektörümüz olsun. Eğer x 'te bulunan veriler korelosyunlu ise, x 'in kovaryans matrisi, köşegen olmayacaktır (Picard 2018). Verileri ilintisiz hale getirip, köşegen kovaryans matrise sahip olmalarını sağlamak için bir dönüşüm yapılması gerekmektedir. Bu dönüşüm öz değer problemi çözülerek bulunmaktadır.

$$\Sigma_x \phi = \phi \Lambda_x \quad (3.20)$$

Λ_x , öz değerleri bulunduran köşegen bir matristir. Böylece, ϕ matrisi x vektörünün kovaryans matrisini köşegenleştirmektedir. Φ matrisinin sütunları kovaryans matrisinin öz vektörleridir. Denklem (3.20) aşağıdaki gibi de ifade edilmektedir:

$$\phi^T \Sigma_x \phi = \Lambda_x \quad (3.21)$$

Λ_x matrisinde yer alan öz değerler, aynı veya farklı olabilir. Eğer matristeki tüm değerler aynı olursa, buna verinin beyazlatılması denmektedir (Picard 2018). Her özdeğer, ilişkili özvektörünün uzunluğunu belirlediğinden, kovaryans, veriler beyazlatılmadığında bir elipse ve veriler beyazlatıldığında bir küreye karşılık gelmektedir (Picard 2018). Beyazlatma işlemi aşağıdaki gibi yapılmaktadır:

$$\Lambda^{-1/2} \Lambda \Lambda^{-1/2} = I \quad (3.22)$$

Bu ifade denklem (3.21)'de yerine yazılırsa:

$$\Lambda^{-1/2} \Phi^T \Sigma_x \Phi \Lambda^{-1/2} = I \quad (3.23)$$

Böylece, beyazlatılmış veriler elde edilir:

$$w = \Lambda^{-1/2} y = \Lambda^{-1/2} \Phi^T x \quad (3.24)$$

Denklem (3.24) ile, w 'nin kovaryansı hem köşegen hem de tekdüze (uniform) olmaktadır:

$$E(ww^T) = E\left(\Lambda^{-1/2} \Phi^T x x^T \Phi \Lambda^{-1/2}\right) = I \quad (3.25)$$

Z ile ifade edilen hiperspektral verisine beyazlatma işleminin uygulandığı aşağıdaki gibidir (Picard 2018):

$$\tilde{Z} = Z E \Lambda_n^{-1/2} \quad (3.26)$$


4. Beyazlatılmış verinin kovaryansının özvektör G matrisi hesaplanır (Roger 1994).
5. MNF dönüşümü gerçekleştirilir (Picard 2018):

$$Y = Z(E \Lambda_n^{-1/2} G) \quad (3.27)$$

3.2.1.3.4 Sinir ağları (NN)

Derin öğrenme (deep learning) teknikleri, çok derin sinir ağlarıyla çeşitli öznitelikleri çıkarmak için hiyerarşik bir öğrenme çerçevesi kullanmaktadır (Kumar vd. 2020). Tipik olarak üç katmandan daha fazla sayıda katman bulunduran sinir ağları, derin ağlar olarak kabul edilmektedir (Kumar vd. 2020). Derin modeller, öznitelikleri aşamalı

olarak öğrenmektedir. Otomatik kodlayıcı (autoencoder), derin öznitelikleri hiyerarşik bir şekilde öğrenmek için temel yaklaşımlardan biridir (Kumar vd. 2020). Şekil 3.6 ile gösterildiği gibi otomatik kodlayıcı bir giriş katmanı (input layer), bir saklı katman (hidden layer) ve yeniden yapılandırma katmanı (reconstruction layer) olarak da bilinen bir çıkış katmanından (output layer) oluşmaktadır (Kumar vd. 2020). Hem girdi hem de yeniden yapılandırma katmanları aynı sayıda N birimden oluşur. Saklı katman, h biriminden oluşur ve diğer iki katmandan daha küçüktür ($h < N$ veya $h \ll N$).



Şekil 3.6 Otomatik kodlayıcı mimarisi (Kumar vd. 2020)

Her katman çifti arasında, doğrusal olmayan bir aktivasyon fonksiyonu bulunur (Kumar vd. 2020). İşlem sırasında, giriş katmanının içeriği ($x \in R^N$), saklı katmandaki gizli bir gösterime eşlenir,


$$v = g(Wx + \beta) \quad (3.28)$$

burada W ile giriş katmanından saklı katmana geçişte kullanılan ağırlık matrisi, β ile saklı katmanın bias vektörü (bias vector) ve $g(\cdot)$ ile aktivasyon fonksiyonu ifade

edilmiştir. Gizli gösterim (latent representation) daha sonra ters eşleme ile orijinal verinin yaklaşık olarak yeniden oluşturulması ($\hat{x} \in R^N$) için kullanılır,


$$\hat{x} = g(\theta v + \gamma) \quad (3.29)$$

burada θ ile saklı katmandan çıkış katmanına geçişte kullanılan ağırlık matrisi, γ ile çıkış katmanının bias vektörü (bias vector) ifade edilmiştir. Eğitim aşamasının amacı, x ve $\hat{x}$ arasındaki yeniden yapılandırma hatasını ($J(x, \hat{x})$) en aza indirmektir. $J(x, \hat{x})$, genellikle kare hata maliyetidir ancak başka birçok farklı yolla da hesaplanabilir (Kumar vd. 2020). Gizli gösterim, orijinal girdinin sıkıştırılmış biçimidir ($h \ll N$). Yeniden oluşturma hatası bir eşik dâhilindeyse, gizli gösterim boyutu azaltılmış bir dizi öznetelik olarak kullanılabilir (Kumar vd. 2020). Hatayı en aza indirmek için Şekil 3.7 ile gösterildiği gibi bir dizi otomatik kodlayıcı istiflenir. Bir otomatik kodlayıcıdaki saklı katman, bir sonrakinin girdisini oluşturur. Bu düzenleme, aşamalı olarak derin öznetelikler oluşturabilen yığın otomatik kodlayıcı (stacked autoencoder, SAE) olarak bilinmektedir (Kumar vd. 2020). Yeniden yapılandırma hatası eşik değeri içindeyse, saklı katmanların içeriği istenen öznetelikleri temsil etmektedir.



Şekil 3.7 Yığın Otomatik Kodlayıcı Mimarisi (Kumar vd. 2020)

Bu çok katmanlı ağıdaki parametreler, geri yayılım (back propagation) algoritması ile ayarlanmaktadır (Kumar vd. 2020). Piksel bazlı spektral öznitelikler için, piksel vektörü Şekil 3.8 ile gösterildiği gibi SAE'ye beslenir. Bu işlem sonucunda belirtilen sayıda öznitelik SAE katmanlarında elde edilir.



Şekil 3.8 SAE Kullanılarak Spektral Öznitelik Çıkarma (Kumar vd. 2020)

Çalışmanın bu aşamasında sinir ağları boyut azaltımı amacıyla kullanılmıştır. NN'nin boyut azaltımı amacıyla kullanılması için hem girdi katmanına hem de çıktı katmanına aynı veri seti verilmiştir. Girdi ve çıktı katmanlarının arasına ise 3 adet saklı katman eklenmiştir. Birinci saklı katmanda 20 adet düğüm kullanılmıştır. İkinci gizli katmanda 10 adet gizli katman kullanılmıştır. Üçüncü katmanda ise birinci katmanda kullanılan düğüm sayısı kadar (20) düğüm kullanılmıştır.

İlgili NN mimarisi tanımlandıktan sonra hem girdi katmanına hem de çıktı katmanına aynı veri seti verilerek modelin eğitimi gerçekleştirilmiştir. Bu işlemin yapılmasının amacı, girdi katmanından gelen verileri önce 10 boyuta düşürecek (ikinci saklı katmanın çıktıları), ardından 10 boyuta düşürülmüş veriden tekrar orijinal veriyi üretebilecek bir yapı oluşturmaktadır. Başka bir ifade ile, 10 boyuta düşürülmüş veri seti eğer tekrar kendisini üretebiliyor ise, ilgili 10 boyutlu verinin orijinal verinin boyutu düşürülmüş

bir versiyonu olarak kullanılabileceğini göstermektedir. Bu anlamda, eğitilmiş NN modelinin ikinci gizli katmanının çıktısı orijinal verinin boyutu düşürülmüş versiyonu olarak kullanılmıştır.

3.2.1.4 Kırmızı/Mavi uç (Red/Blue spike) oranı

Öznitelik çıkarımı için akış şeması Şekil 3.4 ile gösterilmiştir. Şekil 3.3 ile 10 öznitelik çıkarımına karar verildikten sonra 11. birinci öznitelik olarak Kırmızı/Mavi uç (red/blue spike) oranı eklenmiştir. (Gagnon vd. 2015; Kim vd. 2020; Renuka ve Reddy 2013) çalışmalarında kırmızı ve mavi bantların kullanımının çeşitli platformların ve füzelerin tespitinde faydalı olduğunu söylemişlerdir.

Literatürde belirtilen geçirgenliğin az olduğu CO₂ bandının (4.2 μ m) her iki tarafında var olan dar emisyon bantları (mavi uç 4.18 μ m, kırmızı uç 4.38 μ m) öznitelik olarak sürece eklenmiştir. İki banda ait verilerin oranları da normalize edilmiş sınıflandırma için gerekli olan eğitim ve test verisine dahil edilmiştir.

3.2.1.5 Sınıflandırma algoritmalarının eğitilmesi

Şekil 3.2 ile gösterilen sürecin son aşaması, sınıflandırma algoritmalarının eğitilmesi safhalarıdır. Bu noktaya kadar veri üzerinde ön işlemler gerçekleştirilmiş ve verinin, performansı etkilemeyecek şekilde boyutunun azaltılması üzerinde çalışmalar yapılmıştır. Bu çalışmaların sonucunda veri artık sınıflandırma algoritmasına verilmeye hazırdır.

Son aşamada eğitim amacıyla elde edilen veri seti; içerisinde 5 farklı sınıfa ait verileri içermektedir. Veri setindeki örneklerin temsil ettiği uzayda, farklı sınıflara ait örneklerin farklı bölgelerde konumlandığı düşünülmektedir. Dolayısıyla veriler ilgili öznitelik uzayının farklı bölgelerinde farklı dağılımlar göstermektedir. Sınıflandırma algoritmaları, verilen eğitim kümesinden bu dağılım davranışını öğrenmeyi amaçlar. Eğitim işlemi bittikten sonra ise, eğitilmiş modele sınıfın belirli olmadığı test verileri girdi olarak verildiğinde model ilgili test örneklerinin hangi sınıfa dâhil olduğunu tespit


etmeye çalışmaktadır. Sınıflandırma algoritmalarının denenmesi amacıyla bu çalışma kapsamında iki farklı sınıflandırma algoritmasının performansı denenmiştir. Takip eden alt ayrımlarda, kullanılan algoritmalar ile ilgili özet bilgiler verilmiştir.

3.2.1.5.1 Destek vektör makinaları (SVM) algoritması

Destek Vektör Makinaları (SVM), sınırlı sayıda eğitim örneği kullanarak yüksek boyutlu verileri işleme yeteneklerinden dolayı genellikle hiperspektral verilerin sınıflandırılması için kullanılmaktadır. Amaç, iki sınıfın eğitim örneklerini ayırt edebilen çok boyutlu bir öznitelik alanı içinde optimal bir doğrusal ayırıcı hiperdüzlem (sınıf sınırı) tanımlamaktır (Ghamisi vd. 2017).

En iyi hiperdüzlem, her iki sınıftan da maksimum marjı bırakandır. SVM, hiperdüzlem ve en yakın eğitim örnekleri arasındaki marjları maksimize etmeye çalışır. Başka bir deyişle, sınıflandırıcının eğitim aşamasında, hiperdüzlem vektörünü konumlandırabilmek için sadece sınıf sınırına yakın örnekler ihtiyacı duymaktadır. Bu nedenle, hiperdüzleme en yakın örnekler destek vektörleri denmektedir. Daha da önemlisi, hiper düzlemin öznitelik alanına yerleştirilmesinde yalnızca en yakın eğitim örnekleri etkili olduğundan, sınırlı sayıda eğitim örneği mevcut olsa bile SVM girdi verilerini verimli bir şekilde sınıflandırabilir (Ghamisi vd. 2017).

Şekil 3.9 ile gösterilen iki sınıflı durumda, ayrılacak iki sınıf mavi daireler veya yeşil üçgenler olarak gösterilmiştir (Mather ve Koch 2011).



Şekil 3.9 Destek Vektörü Kavramının Gösterilmesi (Mather ve Koch 2011)

Kenar boşluğu (marj), iki açık mavi paralel çizgi arasındaki mesafedir. İki sınıfın en yakın üyeleri arasındaki maksimum mesafeyi veren kenar boşluklarının (margins) bir konumu vardır. Şekil 3.9 ile iki mavi örnek ve iki yeşil örnek, öznitelik uzayında birbirinden en uzak olan en yakın veri noktası çiftleridir ve bunlar sarı ile gösterilmiştir. Bunlara destek vektörleri denir. En az iki destek vektörü olmalıdır, ancak ikiden fazla da olabilir. Kenar boşluğunun ortasından aşağı doğru uzanan kırmızı çizgi, maksimum kenar boşluğu hiperdüzlemidir. Bir hiperdüzlem, üçten fazla boyutta tanımlanmış bir düzlemi ifade etmektedir. Herhangi bir yeni nokta, maksimum kenar hiperdüzlemine başvurularak tanımlanabilir. Bir örnek yukarıda ve sağda yer alıyor ise yeşil sınıfın bir üyesi olarak ifade edilir. Ancak, maksimum kenar hiperdüzleminden daha düşük ve sol tarafta yer alıyor ise mavi sınıfın bir üyesi olarak belirtilir. Burada belirtilen örnek, sadece destek vektörlerinin gerekli olduğunu göstermektedir. Eğitim verilerinin geri kalanına bakılmaksızın, bir örnek sınıflara atanabilmektedir. Bu nedenle, aynı destek vektörlerinin oluşturulması koşuluyla eğitim verileri değiştirilse bile SVM sınıflandırıcısı sabit kalmaktadır (Mather ve Koch 2011).

Eğitim veri kümesinde bulunan iki sınıfın her birinin üyelerinin doğrusal olarak ayrılamayacağı durumlar vardır. Bu veriler sınıflar arası ayrılabilirliği artırmak için daha yüksek boyutlu bir uzaya aktarılır. Eşleme işlemi kernel adı verilen fonksiyonla

yapılır, dolayısıyla SVM kernel tabanlı bir yöntemdir. Çözülecek probleme göre, homojen ve homojen olmayan polinomlar, radyal tabanlı fonksiyon, Gauss radyal tabanlı fonksiyon ve sigmoid kernellerinden biri tercih edilmelidir (Mather ve Koch 2011).

Eğitim verisi toplamının zaman alıcı, zahmetli ve maliyetli olduğu düşünüldüğünde, SVM yönteminin az sayıda eğitim verisine ihtiyaç duyması onu tercih edilebilir yapmaktadır. Kernel fonksiyonlarının kullanımı, işlem maliyeti ve yükünden dolayı dezavantaj gibi görülse de lineer olmayan verilerin ayrıştırılmasında sağladıkları başarı onları öne çıkarmaktadır (Mather ve Koch 2011).

3.2.1.5.2 AdaBoost algoritması

Boosting, hatası büyük olabilen, ancak yine de rastgele tahminden daha iyi sonuç veren, birçok zayıf sınıflandırıcıyı birleştirerek eğitim kümesindeki hatası küçük olan bir güçlü öğrenici üretmektedir (Freund ve Schapire 1996). Boosting algoritmalarının arkasındaki ilke, önce eğitim veri kümesi kullanılarak bir model oluşturulması, ardından ilk modelde bulunan hataları düzeltmek için ikinci bir model oluşturulmasıdır (Anonymous 2021). Bu işlem, hatalar en aza indirilinceye veya veri kümesi doğru tahmin edilene kadar devam eder.


Aşağıda belirtilen iki özellikten herhangi birine sahip olan öğrenme problemlerinde Boosting yönteminin kullanılabileceği düşünülmektedir. Birçok gerçek dünya problemi için geçerli olan ilk özellik, gözlemlenen örneklerin değişen derecelerde zorluğa sahip olmasıdır. Bu tür problemler için, Boosting algoritması daha zor örneklerle odaklanan dağılımlar üretme eğilimindedir. Böylece, zayıf öğrenicileri, örnek uzayın bu daha zor örneklerinde iyi performans göstermeye zorlamaktadır. İkinci özellik, öğrenme algoritmasının eğitim örneklerindeki değişikliklere duyarlı olması ve böylece farklı eğitim setleri için önemli ölçüde farklı zayıf öğrenicilerin üretilmesidir. Boosting, önceden oluşturulmuş zayıf öğreniciler tarafından yapılan hataların bir fonksiyonu olarak eğitim örnekleri üzerindeki dağılımını değiştirerek sınıflandırıcıyı daha başarılı bir hale getirmeye çalışmaktadır (Freund ve Schapire 1996).

Boosting'in başka bir etkisi, varyansı azaltmasıdır. Tümü aynı eğitim setinden seçilen farklı örneklerden eğitilen birçok zayıf öğrenici kullanılarak ağırlıklı çoğunluk almak, birleşik sınıflandırıcının varyansını azaltma etkisine sahiptir. Bu nedenle, boosting, zayıf öğrenicilere göre daha düşük varyansa sahip güçlü bir sınıflandırıcı üretme eğilimindedir. Bununla birlikte, Boosting yöntemi, öğrenme algoritmasının bias değerini de azaltabilir (Freund ve Schapire 1996).

Adaptive Boosting olarak da adlandırılan AdaBoost, Makine Öğrenmesinde Ensemble (topluluk) Yöntemi olarak kullanılan bir tekniktir. Adaboost algoritması, bir model oluşturarak, tüm veri noktalarına eşit ağırlıklar vermektedir. Daha sonra yanlış sınıflandırılmış noktalara daha yüksek ağırlıklar atanmaktadır. Böylece bir sonraki modelde daha yüksek ağırlıklara sahip tüm noktalara daha fazla önem verilmektedir. Düşük bir hata alınana kadar veya tüm örnekler doğru sınıflandırılana kadar bu işlem devam etmektedir. AdaBoost, zayıf sınıflandırıcıların hatalarından ders çıkarmak ve onları güçlü sınıflandırıcılara dönüştürmek için yinelemeli bir yaklaşım kullanmaktadır. Tek bir sınıflandırıcı, bir örneğin sınıfını doğru olarak tahmin edemeyebilir. Ancak birden fazla zayıf sınıflandırıcı kullanılarak, yanlış sınıflandırılmış örnekler aşamalı olarak öğrenilerek, güçlü bir model oluşturulabilir (Anonymous 2021).

Zayıf sınıflandırıcı, rastgele bir tahminden daha iyi performans gösteren, ancak örnekleri tahmin etmede düşük performans gösteren bir sınıflandırıcıdır (Anonymous 2021). Bir durumun değerlendirilmesinde %50'nin üzerinde doğruluk elde edebilirler, buna rağmen birçok veri noktası da yanlış sınıflandırmış olabilir.

AdaBoost tek seviyeli karar ağaçlarını kullanmaktadır. Bu ağaçlara Karar Kütükleri (decision stamp) de denmektedir. Şekil 3.10 ile karar kütüğü yapısı gösterilmektedir (Anonymous 2021).



Şekil 3.10 Karar Kütüğü Yapısı (Anonymous 2021)

Karar kütükleri (decision stamps), bir düğüm ve iki yaprak bulundurmaktadır (Anonymous 2021). Bu karar kütükleri, zayıf öğrencileri ifade etmektedir ve Boosting teknikleri tarafından kullanılmaktadır. Kütükler tek başına karar vermek için iyi bir yol değildir. Bir karar ağacı, hedef değeri tahmin etmek için tüm özniteliklerden alınan kararları birleştirmektedir (Anonymous 2021). Ancak tek bir kütük, karar vermek için yalnızca bir öznitelik kullanmaktadır. AdaBoost'ta karar kütüklerinin sırası çok önemlidir. İlk kütüğün hatası, diğer kütüklerin nasıl eğitileceğini etkilemektedir. AdaBoost işlemi aşağıdaki adımlar ile ifade edilmektedir (Anonymous 2021):

Adım 1: Ağırlık katsayıları atanmış eğitim verisi kullanılarak zayıf öğrenciler, karar kütükleri, oluşturulur. Burada her örneğin ağırlıkları doğru sınıflandırmanın önemini göstermektedir.

n adet örneğe sahip veri kümesi, aşağıdaki gibi ifade edilmektedir (Anonymous 2021):

$$x_i \in \mathbb{R}^n, y_i \in \{-1, 1\} \quad (3.30)$$

burada y ile ikili sınıflandırmada birinci veya ikinci sınıfı ifade eden -1 veya 1 değerine sahip hedef değişkenler gösterilmiştir. Başlangıçta, ilk kütük için tüm örneklere eşit ağırlık verilmektedir:

$$w = \frac{1}{N} \varepsilon [0,1] \quad (3.31)$$

Adım 2: Öznitelik sayısı ile aynı sayıda karar kütüğü oluşturulur. Algoritma oluşturulan modellerden sadece birini seçer. Temel öğrenici seçilirken, iki özellikten biri karar kütüklerini kendi içinde karşılaştırmak için kullanılmaktadır. Bu özellikler, Gini ve Entropi değerleridir. Yaprakların altındaki sayılar doğru ve yanlış sınıflandırılmış örnekleri temsil etmektedir. Bunlar kullanılarak Gini veya Entropy indeksi, tüm kütükler için hesaplanır. En az Gini veya Entropi değerine sahip kütük, ilk temel öğrenici olarak seçilir.


Adım 3: Toplam hata, hatalı sınıflandırılmış toplam örnek sayısının örnek uzunluğuna oranıdır. Seçilen kütük için toplam hata hesaplanmaktadır.

Adım 4: Karar kütüğünün performansı aşağıdaki formüle göre hesaplanır:

$$a_t = \frac{1}{2} \ln \frac{(1 - \text{ToplamHata})}{\text{ToplamHata}} \quad (3.32)$$

Alfa, ilgili kütüğün son sınıflandırmada ne kadar etkisi olacağını ifade etmektedir. Alfaya, “amount of say”, “importance” veya “influence” da denmektedir (Freund ve Schapire 1996). Yukarıdaki formülde toplam hata değeri yerine konularak hesaplama gerçekleştirilir. Burada hesaplanan değer kullanılarak örnekler için ağırlık katsayıları güncellenmektedir. Eğer bu işlem gerçekleştirilmezse, aynı ağırlık katsayıları uygulanacak ve çıktı ilk model ile aynı olacaktır. Yanlış sınıflandırılan örneklerin ağırlık katsayısı arttırılırken, doğru sınıflandırılan örneklerin ağırlık katsayısı azaltılmalıdır. Böylece diğer modele geçişte yanlış sınıflandırılan örneklerin daha fazla tekrarlanması sağlanır.

0 ile 1 arasında değişen toplam hata değerlerine göre Alfa için bir grafik Şekil 3.11 ile gösterilmektedir (Anonymous 2021).



Şekil 3.11 Hata Oranına göre Alfa Değeri Grafiği (Anonymouse 2021)

Bir karar kütüğü, iyi sonuç verdiğinde veya herhangi bir yanlış sınıflandırma örneğine sahip olmadığında, bunun düşük hata oranıyla ve nispeten büyük, pozitif alfa değeriyle sonuçlandığına dikkat edilmelidir.

Kütük örneklerin yarısını doğru ve yarısını yanlış sınıflandırdığında, hata oranı ~ 0.5 , rastgele tahminden daha iyi değil, alfa değeri sıfır olmaktadır.

Kütük, yanlış sınıflandırılmış sonuçlar verdiğinde ise alfa, büyük negatif bir değer olacaktır.

Adım-5: Karar kütüğü için toplam hata hesaplandıktan sonra, her veri noktası için $1/N$ olarak atanan ağırlık katsayılarının güncellenmesi gerekmektedir. Bu güncelleme aşağıdaki formülle yapılmaktadır:

$$w_{i+1} = w_i * e^{+a} \quad (3.33)$$

Alfa için pozitif veya negatif olması şunları ifade etmektedir:

1. Alfa'nın işareti negatif ise örnek doğru şekilde sınıflandırılmıştır. Bu durumda, zayıf sınıflandırıcı zaten iyi performans gösterdiğinden örneğe atanan ağırlık katsayıları düşürülmektedir.

2. Gerçek etiket ile sınıflandırılan etiket farklı ise alfanın işareti pozitifdir. Bu durumda, yanlış sınıflandırmanın bir sonraki karar kütüğünde tekrarlanmaması için örneğin ağırlık katsayısı artırılmalıdır. Bu durum kütüklerin öncekilere bağımlı olduğunu göstermektedir.

Tüm örnekler için ağırlık katsayıları güncellenir. Ağırlıkların toplamı bire eşit olmalıdır. Ağırlıklarının toplamının bir olmaması durumunda, güncellenen her ağırlık değeri, güncellenen ağırlık değerlerinin toplamına bölünmelidir.

Adım-6: Son olarak yeni bir veri seti, güncellenen ağırlık katsayıları kullanılarak oluşturulmalıdır. Yeni veri setindeki eleman sayısı, önceki veri seti ile aynı olmalıdır. Yeni veri setinde yanlış sınıflandırılan örneklerin sıklığı, doğru sınıflandırılanlardan fazla olacaktır. Bunun nedeni yanlış sınıflandırılan örneklere daha yüksek ağırlık katsayılarının atanmasıdır. Bu yeni veri kümesi kullanılarak, ikinci karar kütüğü oluşturulur ve aynı işlemler adım-1'den itibaren tekrarlanır.

Nihai kararı vermek için, test veri seti algoritma tarafından oluşturulan tüm kütüklerden geçirilir. Her kütük test verisi için bir çıktı oluşturur. Elde edilen çıktılarından çoğunluğu oluşturan, nihai çıktı olarak ifade edilir. Nihai sınıflandırıcı aşağıdaki formül ile ifade edilmektedir (Freund ve Schapire 1996):

$$H(x) = \text{sign}\left(\sum_{t=1}^T a_t h_t(x)\right) \quad (3.34)$$

burada $H(x)$, zayıf sınıflandırıcıların birleşimidir. Son sınıflandırıcı $H(x)$, zayıf öğrencilerin ağırlıklı oyudur. Yani belirli bir x örneği için, zayıf öğrencilerin ağırlıklarının toplamını maksimize eden y etiketini üretmektedir (Freund ve Schapire 1996).

3.2.2 Sınıflandırma adımlarının sonuçları

3.2.1 bölümünde ham hiperspektral verisi kullanılarak, görüntüler içerisinde bulunan 5 ana sınıfı (füze, gökyüzü, yeryüzü, bulut, egzoz dumanı) birbirinden ayırmak için izlenen adımlar detaylandırılmıştır. Bu süreçte yapılan son işlem, uygun formatlara getirilmiş veriler kullanılarak sınıflandırılma algoritmalarının eğitilmesi olmuştur. Dolayısıyla son aşamada artık elde eğitilmiş sınıflandırma modelleri bulunmaktadır. Bu noktada yapılması gereken işlem ise, eğitim aşamasında kullanılmamış veri setleri kullanılarak sınıflandırma modellerinin denenmesidir. Bu bölümde ilgili değerlendirmelere yönelik sonuçlara yer verilmiştir. Başarımların değerlendirilmesi amacıyla kullanılan işlem adımları Şekil 3.12 ile gösterilmiştir.



Şekil 3.12 Performans değerlendirme akış şeması

Başarımların değerlendirilmesi sürecinde girdi verisi olarak, hiperspektral verinin tümünün kullanılabileceği değerlendirilmektedir. Girdi verisi öncelikle, boyut azaltımı bloğuna girmektedir. Bu bloğa girdi olarak gelen hiperspektral verilere boyut azaltımı işlemi yapılmaktadır. Verinin izdüşümünün alınacağı uzay vektörlerinden oluşan dönüşüm matrisleri eğitim safhasında belirlenmiştir. Dolayısıyla ilgili dönüşüm matrislerinin boyut azaltımı bloğuna girdi olarak verilmesi gerekmektedir. Bu aşamada,

hiperspektral veriler ilgili dönüşüm matrisleri kullanılarak boyut azaltımı işlemine tabi tutulmaktadır. Akışın son adımında ise, boyut azaltımı uygulanmış verilerin eğitilmiş sınıflandırma modelleri kullanılarak sınıflandırılması gerçekleştirilmektedir. Takip eden alt ayrımlarda farklı sınıflandırma algoritmalarının sonuçlarına yer verilmiştir.

3.2.2.1 Destek vektör makinaları algoritmasının sonuçları

Bu bölümde, dört farklı boyut azaltımı yöntemi kullanılarak elde edilen veri setleri kullanılarak eğitilen SVM modellerinin başarımları üzerinde durulacaktır. Başarım kriteri, test verisindeki örneklerin dahil oldukları sınıfları doğru bir şekilde tahmin edebilme üzerinden değerlendirilecektir. SVM algoritması kullanılırken, veriler doğrusal ayrılmayan veri türünde olduğundan kernel fonksiyonu kullanılarak veriler yüksek boyutlara dönüştürülmüştür.


Sınıflandırma başarımının incelendiği bu aşamada test edilecek veri setlerinin her biri beş sınıf için ayrı ayrı oluşturulan SVM modellerine girdi olarak verilmiştir. Bu SVM modellerinin her biri ikili (binary) sınıflandırma yapmaktadır. Başka bir ifadeyle, örneğin füze için eğitilmiş SVM modeli füze ve diğerleri (gökyüzü, yeryüzü, bulut, egzoz dumanı) şeklinde bir sınıflandırma yaparken, yeryüzü için eğitilmiş SVM modeli yeryüzü ve diğerleri (gökyüzü, füze, bulut, egzoz dumanı) şeklinde bir sınıflandırma yapmaktadır. Bunun sonucunda her test örneği için beş farklı modelden gelen beş farklı sınıf etiketi oluşmuştur. Şekil 3.13 ile tüm SVM modelleri sonucunda oluşan sınıf etiketi gösterilmiştir.

	1	2	3	4	5
	Bulut	Yeryüzü	Füze	Duman	Gökyüzü
1	0	0	1	0	0
2	0	0	1	0	0
3	0	0	1	0	0
4	0	0	1	0	0
5	0	0	0	0	1
6	0	0	1	0	0
7	0	0	1	0	0
8	0	0	1	0	0
9	0	0	1	0	1
10	0	0	1	0	0
11	0	0	1	0	0
12	0	0	1	0	0
13	0	0	1	0	0
14	0	0	1	0	0
15	0	1	1	0	0
16	0	0	1	0	0
17	0	0	1	0	0
18	0	1	1	0	0
19	0	0	1	0	0
20	0	0	1	0	0

Şekil 3.13 Sınıf etiketleri


SVM algoritması veri örneğinin hangi sınıfa ait olduğunu bildirmesinin yanında, sınıfları birbirinden ayıran hiper-düzleme olan uzaklığına göre bir güvenilirlik değeri de vermektedir. İlgili örnek optimize edilmiş hiper-düzleme ne kadar uzak ise, verilen kararın o derecede güvenilir olduğu bilinmektedir. Bu sebeple bir test örneği için, örneğin hem füze için eğitilmiş SVM modeli hem de bulut için eğitilmiş SVM modeli 1 kararını verirse, başka bir ifadeyle bir SVM modeli ilgili test örneği için füze kararı, diğeri ise bulut kararı verirse, bunlardan güvenilirlik değeri en yüksek olanın kararı geçerli kabul edilmiştir. Bu şekilde, iki sınıfı ayırma yeteneğine sahip olan SVM modellerini birleştirmek suretiyle birden fazla sınıfın sınıflandırılması işlemi çoklu (multi) SVM sınıflandırma algoritması olarak isimlendirilmiştir.

Sınıflandırma çalışmasında ilk olarak 3.2.1.2 bölümünde açıklanan yöntem ile toplanan veri seti kullanılarak Karışıklık Matrisi ile başarımlar ve hata oranları ortaya koyulmuştur. Bu analiz için, eğitim safhasında ikiye ayrılan veri setinin ikinci bölümü kullanılmıştır. Eğitim aşamasında kullanılan veri seti, tüm veri setinin %80’lik bir kısmını oluşturmaktadır. Başarımların incelendiği test aşamasında ise tüm veri setinin %20’si kullanılmıştır. Boyut azaltımı metodunda Temel Bileşenler Analizi (PCA) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımlar yüzdeleri Şekil 3.14 ile verilmiştir.




Şekil 3.14 PCA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri


Yeryüzü		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	26206 44.9%
0	1	2305 4.0%
1	0	2954 5.1%
1	1	26855 46.0%
		89.9% 10.1%
		92.1% 7.9%
		91.0% 9.0%




Füze		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	1058 50.0%
0	1	67 3.2%
1	0	0 0.0%
1	1	991 46.8%
		100% 0.0%
		93.7% 6.3%
		96.8% 3.2%



Egzoz Dumanı		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	2416 46.9%
0	1	123 2.4%
1	0	159 3.1%
1	1	2452 47.6%
		93.8% 6.2%
		95.2% 4.8%
		94.5% 5.5%



Şekil 3.14 PCA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)



Şekil 3.14 PCA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)


Çizelge 3.1 ile PCA işlemi sonrası SVM için ROC eğrilerinin AUC değerleri verilmiştir.

Çizelge 3.1 PCA ve SVM Sonucunda Elde Edilen AUC Bilgileri


Veri	AUC Bilgisi
Bulut	0.9797
Yeryüzü	0.9683
Füze	0.9968
Egzoz Dumanı	0.9881
Gökyüzü	0.9627

Boyut azaltımı metodunda Sinir Ağları (NN) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımlar yüzdelere Şekil 3.15 ile verilmiştir.


		Bulut		
Çıktı Sınıfı	0	24654 44.1%	2874 5.1%	89.6% 10.4%
1	3276 5.9%	25056 44.9%	88.4% 11.6%	
		88.3% 11.7%	89.7% 10.3%	89.0% 11.0%
		Hedef Sınıfı		




		Yeryüzü		
Çıktı Sınıfı	0	24623 42.2%	4587 7.9%	84.3% 15.7%
1	4537 7.8%	24573 42.1%	84.4% 15.6%	
		84.4% 15.6%	84.3% 15.7%	84.4% 15.6%
		Hedef Sınıfı		



		Füze		
Çıktı Sınıfı	0	1057 50.0%	108 5.1%	90.7% 9.3%
1	1 0.0%	950 44.9%	99.9% 0.1%	
		99.9% 0.1%	89.8% 10.2%	94.8% 5.2%
		Hedef Sınıfı		



Şekil 3.15 NN ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri




Şekil 3.15 NN ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)

Çizelge 3.2 ile NN işlemi sonrası SVM için ROC eğrilerinin AUC değerleri verilmiştir.


Çizelge 3.2 NN ve SVM Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.9501
Yeryüzü	0.9145
Füze	0.9840
Egzoz Dumanı	0.9488
Gökyüzü	0.9139

Boyut azaltımı metodunda Bağımsız Bileşenler Analizi (ICA) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımların yüzdeleri Şekil 3.16 ile verilmiştir.



Şekil 3.16 ICA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri



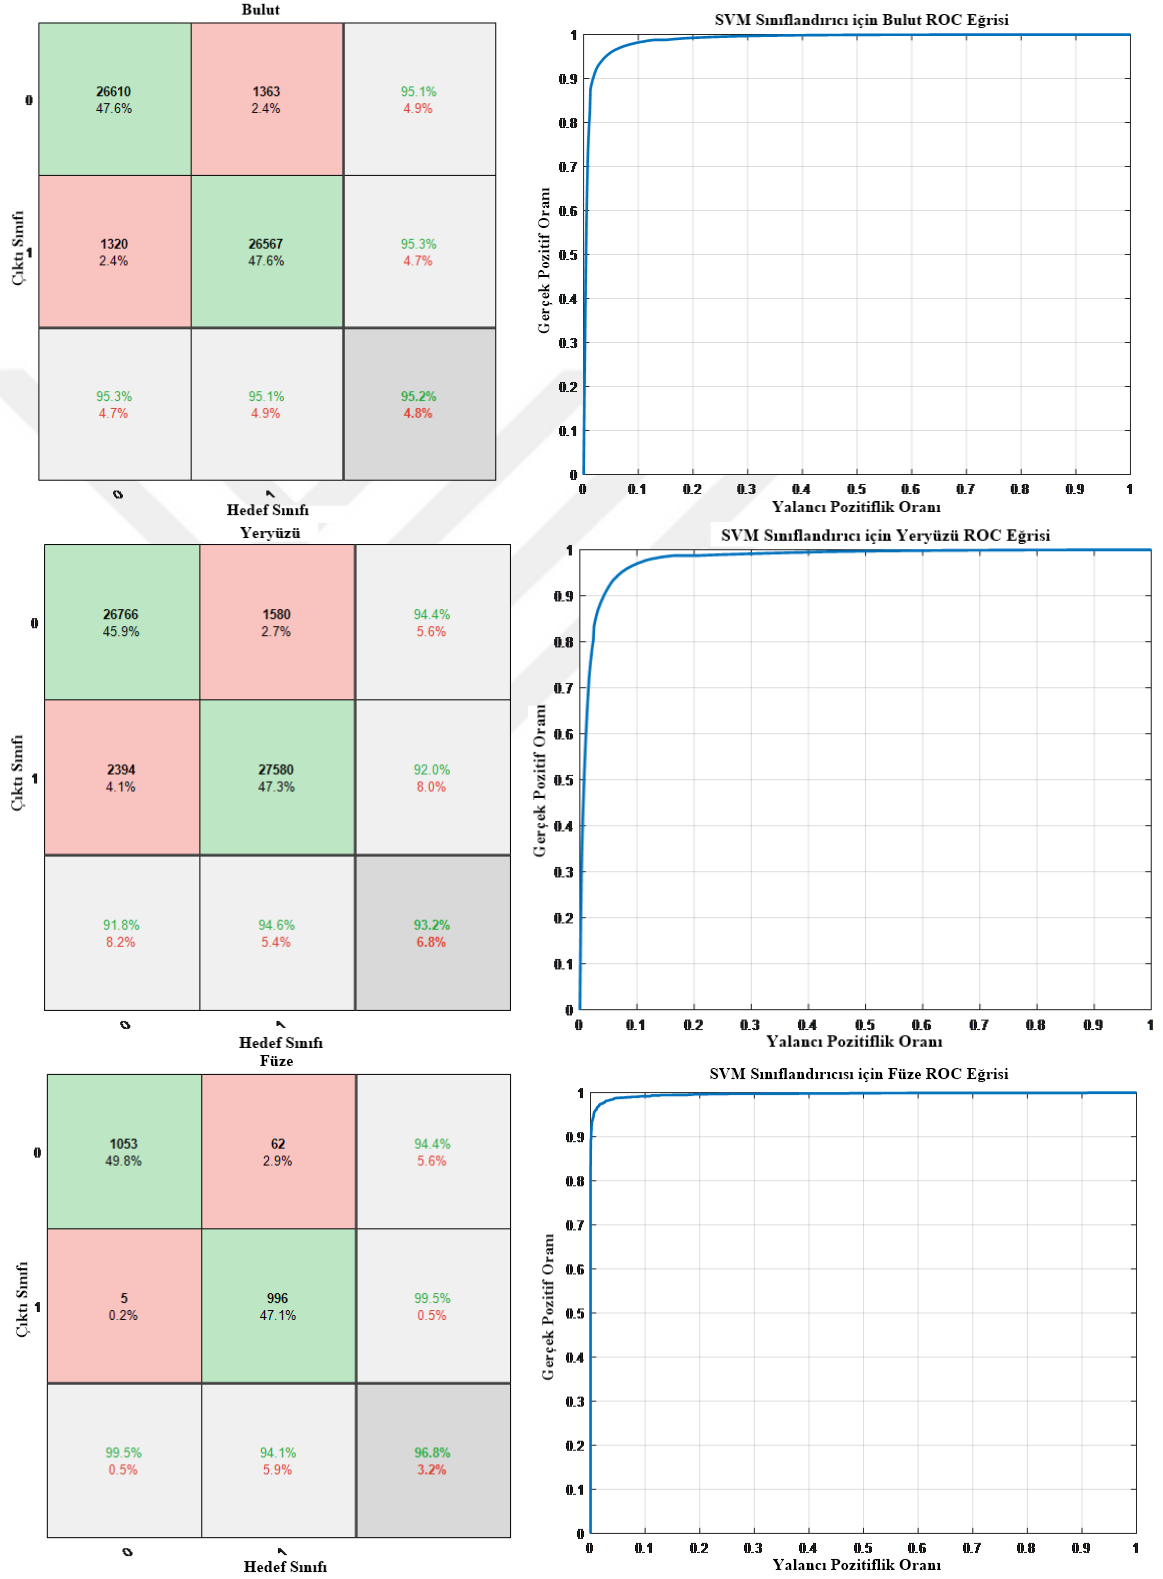
Şekil 3.16 ICA ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)


Çizelge 3.3 ile ICA işlemi sonrası SVM için ROC eğrilerinin AUC değerleri verilmiştir.

Çizelge 3.3 ICA ve SVM Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.8645
Yeryüzü	0.8287
Füze	0.9752
Egzoz Dumanı	0.9603
Gökyüzü	0.8389

Boyut azaltımı metodunda Maksimum Gürültü Oranı (MNF) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımlar Şekil 3.17 ile verilmiştir.





Şekil 3.17 MNF ve SVM Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri

Çizelge 3.4 ile MNF işlemi sonrası SVM için ROC eğrilerinin AUC değerleri verilmiştir.

Çizelge 3.4 MNF ve SVM Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.9887
Yeryüzü	0.9801
Füze	0.9965
Egzoz Dumanı	0.9917
Gökyüzü	0.9748

Çizelge 3.5 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre SVM sınıflandırıcısı sonucu elde edilen sınıflandırma doğrulukları verilmiştir.

Çizelge 3.5 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	92.6	95.2	76.9	89.0
Yeryüzü	91.0	93.2	73.4	84.4
Füze	96.8	96.8	92.7	94.8
Egzoz Dumanı	94.5	94.1	83.8	87.4
Gökyüzü	90.1	92.5	75.9	83.7

Çizelge 3.6 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre SVM sınıflandırıcısı sonucu elde edilen kesinlik (precision) değerleri verilmiştir.

Çizelge 3.6 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	93.2	95.3	80.3	88.4
Yeryüzü	90.1	92.0	72.7	84.4
Füze	100	99.5	98.9	99.9
Egzoz Dumanı	93.9	94.2	86.8	84.9
Gökyüzü	90.0	93.4	74.5	83.0

Çizelge 3.7 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre SVM sınıflandırıcısı sonucu elde edilen duyarlılık (recall) değerleri verilmiştir.

Çizelge 3.7 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	91.9	95.1	70.5	89.7
Yeryüzü	92.1	94.6	75.0	84.3
Füze	93.7	94.1	86.3	89.8
Egzoz Dumanı	95.2	93.9	79.7	91.0
Gökyüzü	90.2	91.4	78.8	84.8

Çizelge 3.8 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre SVM sınıflandırıcısı sonucu elde edilen AUC değerleri verilmiştir.

Çizelge 3.8 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen AUC Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	0.9797	0.9887	0.8645	0.9501
Yeryüzü	0.9683	0.9801	0.8287	0.9145
Füze	0.9968	0.9965	0.9752	0.9840
Egzoz Dumanı	0.9881	0.9917	0.9603	0.9488
Gökyüzü	0.9627	0.9748	0.8389	0.9139

Şekil 3.18, Şekil 3.19, Şekil 3.20 ve Şekil 3.21 ile beş sınıf için elde edilen hata matrisleri dört farklı boyut azaltımı yöntemine göre SVM sınıflandırma sonuçları verilmiştir.

5 Sınıf için Hata Matrisi

1	190 9.0%	4 0.2%	12 0.6%	2 0.1%	29 1.4%	80.2% 19.8%
2	8 0.4%	200 9.5%	56 2.6%	3 0.1%	49 2.3%	63.3% 36.7%
3	0 0.0%	0 0.0%	975 46.1%	0 0.0%	0 0.0%	100% 0.0%
4	3 0.1%	9 0.4%	10 0.5%	11 0.5%	5 0.2%	28.9% 71.1%
5	12 0.6%	21 1.0%	5 0.2%	1 0.0%	511 24.1%	92.9% 7.1%
	89.2% 10.8%	85.5% 14.5%	92.2% 7.8%	64.7% 35.3%	86.0% 14.0%	89.2% 10.8%
	1	2	3	4	5	
	Hedef Sınıfları					

Çıktı Sınıfları


Şekil 3.18 PCA ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

5 Sınıf için Hata Matrisi											
Çıktı Sınıfları	1	213 10.1%	0 0.0%	12 0.6%	1 0.0%	21 1.0%	86.2% 13.8%				
	2	4 0.2%	224 10.6%	63 3.0%	0 0.0%	34 1.6%	68.9% 31.1%				
	3	0 0.0%	0 0.0%	967 45.7%	0 0.0%	0 0.0%	100% 0.0%				
	4	7 0.3%	3 0.1%	9 0.4%	22 1.0%	2 0.1%	51.2% 48.8%				
	5	3 0.1%	8 0.4%	7 0.3%	1 0.0%	515 24.3%	96.4% 3.6%				
	Hedef Sınıfları										
1	2	3	4	5		93.8% 6.2%	95.3% 4.7%	91.4% 8.6%	91.7% 8.3%	90.0% 10.0%	91.7% 8.3%

Şekil 3.19 MNF ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

5 Sınıf için Hata Matrisi							
Çıktı Sınıfları	1	191 9.0%	6 0.3%	33 1.6%	5 0.2%	27 1.3%	72.9% 27.1%
	2	15 0.7%	175 8.3%	59 2.8%	3 0.1%	74 3.5%	53.7% 46.3%
	3	0 0.0%	1 0.0%	931 44.0%	0 0.0%	0 0.0%	99.9% 0.1%
	4	22 1.0%	12 0.6%	9 0.4%	15 0.7%	18 0.9%	19.7% 80.3%
	5	15 0.7%	36 1.7%	26 1.2%	2 0.1%	441 20.8%	84.8% 15.2%
		78.6% 21.4%	76.1% 23.9%	88.0% 12.0%	60.0% 40.0%	78.8% 21.3%	82.8% 17.2%
Hedef Sınıfları							
1	2	3	4	5			

Şekil 3.20 NN ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi



Şekil 3.21 ICA ve SVM Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

Çizelge 3.9 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre SVM sınıflandırıcısı sonucu elde edilen sınıflandırma doğrulukları verilmiştir.

Çizelge 3.9 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları

Yöntem Veri	PCA	MNF	NN	ICA
5 Sınıf	89.2	91.7	82.8	73.0

Çizelge 3.10 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre SVM sınıflandırıcısı sonucu elde edilen kesinlik değerleri verilmiştir.

Çizelge 3.10 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri

Yöntem Veri	PCA	MNF	NN	ICA
Bulut	80.2	86.2	72.9	37.9
Yeryüzü	63.3	68.9	53.7	46.4
Füze	100	100	99.9	99.9
Egzoz Dumanı	28.9	51.2	19.7	20.0
Gökyüzü	92.9	96.4	84.8	71.6

Çizelge 3.11 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre SVM sınıflandırıcısı sonucu elde edilen duyarlılık değerleri verilmiştir.

Çizelge 3.11 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve SVM Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri

Yöntem Veri	PCA	MNF	NN	ICA
Bulut	89.2	93.8	78.6	53.3
Yeryüzü	85.5	95.3	76.1	61.0
Füze	92.2	91.4	88.0	83.0
Egzoz Dumanı	64.7	91.7	60.0	64.7
Gökyüzü	86.0	90.0	78.8	67.7

Çizelge 3.9, Çizelge 3.10 ve Çizelge 3.11 ile beş sınıfa çoklu SVM sınıflandırma algoritması uygulanmasıyla elde edilen sonuçlar incelenmiştir. Buna göre dört boyut

azaltımı yöntemi içinden MNF yönteminin en iyi sonucu verdiği, PCA yönteminin ikinci en iyi sonucu verdiği ve ICA yönteminin ise en kötü sonucu verdiği bulunmuştur. NN yönteminin üçüncü en iyi yöntem olduğu değerlendirilmiştir.

Sınıf verilerinin başarımlar yüzdeleri 3.2.1.3 bölümünde detaylandırılan dört farklı boyut azaltımı yönteminden elde edilen farklı veri setlerinin hepsi için incelenmiştir. Yüzdelere kabul edilebilir düzeyde olduğundan ikili (binary) ve çoklu (multi) SVM sınıflandırma algoritması ile çalışmaya devam edilmiştir.


Sınıflandırma algoritmasında, veri sayısının artırılmasının yanı sıra hem veri seti hem de HS görüntülerin ışıma değerleri normalize edilerek kullanılan değerlerin belirli sınırlar arasında kalması sağlanmıştır. Normalize edilen veri seti öznetelik çıkarımı algoritmalarına girdi olarak verilmiştir. Bahsi geçen iyileştirmelere ek olarak geçirgenliğin az olduğu CO₂ bandının (4.2 µm) her iki tarafında var olan dar emisyon bantları (mavi uç 4.18 µm, kırmızı uç 4.38 µm) da algoritmaya dahil edilmiştir. İki banda ait verilerin oranları da normalize edilmiş sınıflandırma için gerekli olan eğitim ve test verisine dâhil edilmiştir. Tüm bu düzenlemeler sonucunda oluşturulan veri matrisleri karar algoritmasına girdi olarak verilmiş, seçilen HS görüntüleri renklendirilmiştir.

Renklendirme işlemi;


- Füze verisi: kırmızı
- Gökyüzü verisi: koyu mavi
- Yeryüzü verisi: yeşil
- Bulut verisi: beyaz
- Egzoz Dumanı verisi: gri

olacak şekilde belirlenmiştir.


Renklendirme işlemi uygulanan HS görüntülerinin farklı algoritma sonuçları Şekil 3.22, Şekil 3.23, Şekil 3.24 ve Şekil 3.25 ile verilmiştir.




Şekil 3.22 PCA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler




Şekil 3.22 PCA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)




Şekil 3.23 MNF ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler




Şekil 3.23 MNF ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)




Şekil 3.24 NN ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler



Şekil 3.24 NN ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)



Şekil 3.25 ICA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler



Şekil 3.25 ICA ve SVM Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)

Yukarıda anlatılan boyut azaltımı ve sınıflandırma işlemleri hiperspektral verilerin tüm bantlarına uygulanmıştır.

Çizelge 3.5 incelendiğinde dört farklı boyut azaltımı tekniği için SVM sonucu elde edilen hata matrislerinin 5 farklı sınıfın herbirini diğerlerinden ne kadar iyi ayırdığının

oranları verilmiştir. Çizelge 3.6 ve Çizelge 3.7 ile sınıflandırıcı modellerinin kesinlik ve duyarlılık değerleri belirtilmiştir. Çizelge 3.5 incelendiğinde dört yöntem içinden PCA ve MNF'nin her sınıf için yüzde %90 ve üzerinde başarımlar sağladığı görülürken, ICA yönteminin ise en kötü sonuçları verdiği görülmüştür. Dört boyut azaltımı tekniğinin de SVM ile sınıflandırılması sonucunda füze verisinin diğer sınıflardan yüksek doğruluk oranıyla ayrıldığı görülmektedir. Çizelge 3.6 ve Çizelge 3.7 incelendiğinde yine en iyi sonuçları PCA ve MNF yöntemlerinin verdiği, en kötü sonucu ise ICA yönteminin verdiği bulunmuştur. NN yöntemi ise dört farklı boyut azaltımı yöntemi arasında üçüncü en iyi yöntem olmuştur. Çizelge 3.8 ise AUC sonuçlarını göstermektedir. AUC, ROC eğrisinin altında kalan alan demektir ve eğrinin altında kalan alan ne kadar fazlaysa sınıflandırıcının başarısı o kadar fazla demektir. AUC'nin ideal değeri 1'dir. SVM için AUC sonuçları incelendiğinde PCA ve MNF yöntemleri en başarılı iki yöntem olurken, ICA ise yine en kötü sonuçları vermiştir. Şekil 3.22, Şekil 3.23, Şekil 3.24 ve Şekil 3.25 ile SVM sonuçları görsel olarak incelendiğinde, dört boyut azaltımı yönteminin de füzeyi arka plandan ayırt edebildiği ancak ICA yönteminin füze dışındaki sınıfları sahnede ayırt edemediği bulunmuştur. Diğer yöntemlerin renklendirme sonuçlarının gerçek hiperspektral görüntüye benzer görüntüler verdiği görülmüştür. SVM sınıflandırıcısı kullanıldığında dört boyut azaltımı yöntemi değerlendirildiğinde PCA ve MNF'nin en iyi yöntemler olduğu, ICA'nın en kötü sonuçları verdiği ve NN'nin üçüncü en iyi yöntem olduğu bulunmuştur. Görsel sonuçlar değerlendirildiğinde ise SVM sınıflandırıcısı kullanıldığında dört boyut azaltımı yönteminin de füzeyi arkaplandan ayırabildiği tespit edilmiştir.

3.2.2.2 AdaBoost algoritmasının sonuçları

Bu bölümde, dört farklı boyut azaltımı yöntemi kullanılarak elde edilen veri setleri kullanılarak eğitilen AdaBoost modellerinin başarımları üzerinde durulacaktır. Başarım kriteri, test verisindeki örneklerin dahil oldukları sınıfları doğru bir şekilde tahmin edebilme üzerinden değerlendirilecektir.

Sınıflandırma başarımının incelendiği bu aşamada test edilecek veri setlerinin her biri beş sınıf için ayrı ayrı oluşturulan AdaBoost modellerine girdi olarak verilmiştir. Bu

AdaBoost modellerinin her biri ikili (binary) sınıflandırma yapmaktadır. Başka bir ifadeyle, örneğin füze için eğitilmiş AdaBoost modeli füze ve diğerleri (gökyüzü, yeryüzü, bulut, egzoz dumanı) şeklinde bir sınıflandırma yaparken, yeryüzü için eğitilmiş AdaBoost modeli yeryüzü ve diğerleri (gökyüzü, füze, bulut, egzoz dumanı) şeklinde bir sınıflandırma yapmaktadır. Bunun sonucunda her test örneği için beş farklı modelden gelen 5 farklı sınıf etiketi oluşmuştur. Tüm AdaBoost modelleri sonucunda oluşan sınıf etiketleri de Şekil 3.13 ile gösterilebilir. AdaBoost algoritması, sınıflandırması yapılan çerçevedeki piksel örneğinin hangi sınıfa ait olduğunu bildirmesinin yanında, örneklerin hangi sınıfa ne olasılıkla ait olduğunu belirten skor değerini de vermektedir. Şekil 3.26 ile skor matrisinin bir kısmı örnek olarak gösterilmiştir.


81920x5

	1	2	3	4	5
1	-9.8689	8.8540	-13.9119	-5.0726	-5.5183
2	-2.9109	4.5479	-9.8273	-1.1133	-2.9258
3	-8.4204	8.5806	4.1312	-2.9793	-2.7186
4	-8.0624	8.1217	-12.2524	-4.8948	-3.6211
5	-9.4227	8.1649	-12.9745	-5.5893	-4.8019
6	-10.3951	9.1943	-13.9636	-5.4375	-4.6749
7	-11.8080	9.3222	-10.7517	-5.2452	-5.6516
8	-9.9896	9.7573	-13.3445	-5.4877	-5.2938
9	-1.8364	2.7519	-5.6551	-1.6789	-1.5691
10	-3.7453	6.2628	-8.0714	-2.3472	-2.2659
11	-10.7061	8.8397	-10.7918	-5.7893	-5.4089
12	-8.8056	8.9865	-8.0836	-5.4855	-4.8067
13	-3.6348	4.8740	-13.8471	-5.1561	-2.3857
14	-4.3121	5.1171	-10.7330	-1.7203	-2.1539
15	-5.7705	6.2186	-9.8855	-4.0114	-3.2312
16	-6.8881	7.6155	-6.3826	8.4964	-3.2714
17	-1.4972	4.3553	-3.5073	1.3221	-1.5106
18	-1.9293	5.7364	-1.7131	-0.0890	-3.0986
19	-1.8407	3.2123	-2.7731	-1.4228	-0.5262
20	-3.1074	4.4433	-10.7830	-1.6071	-2.9495
21	-2.5455	4.2491	-9.3819	-4.3709	-2.5940

Şekil 3.26 5 Sınıf için Skor Matris Örneği


Bir test örneği için, model sadece tek sınıf için 1 çıktısı vermişse örnek o sınıfa atanır. Ancak, örneğin hem füze için eğitilmiş AdaBoost modeli hem de bulut için eğitilmiş AdaBoost modeli 1 kararını verirse, başka bir ifadeyle bir AdaBoost modeli ilgili test örneği için füze kararı, diğeri ise bulut kararı verirse, bunlardan skor değeri en yüksek olanın kararı geçerli kabul edilmiştir. Eğer test örneği için hiçbir model 1 çıktısı vermemişse skor değeri en yüksek olan sınıfa ait olduğu düşünülmüştür. Bu yöntemle, iki sınıfı ayırma yeteneğine sahip olan AdaBoost modelleri birleştirilerek birden fazla sınıfın çoklu olarak sınıflandırılması gerçekleştirilmiştir.

Sınıflandırma çalışmasında ilk olarak 3.2.1.2 bölümünde açıklanan yöntemler ile toplanan veri seti kullanılarak Hata Matrisi ile başarımlar ve hata oranları ortaya koyulmuştur. Bu analiz için, eğitim safhasında ikiye ayrılan veri setinin ikinci bölümü kullanılmıştır. Eğitim aşamasında kullanılan veri seti, tüm veri setinin %80'lik bir kısmını oluşturmaktadır. Başarımların incelendiği test aşamasında ise tüm veri setinin %20'si kullanılmıştır. Boyut azaltımı metodunda Temel Bileşenler Analizi (PCA) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımlar yüzdeleri Şekil 3.27 ile verilmiştir.




Şekil 3.27 PCA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri


Yeryüzü		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	26202 44.9%
0	1	2560 4.4%
1	0	2958 5.1%
1	1	26600 45.6%
2	0	89.9% 10.1%
2	1	91.2% 8.8%
2	2	90.5% 9.5%




Füze		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	1051 49.7%
0	1	14 0.7%
1	0	7 0.3%
1	1	1044 49.3%
2	0	99.3% 0.7%
2	1	98.7% 1.3%
2	2	99.0% 1.0%



Egzoz Dumanı		
Çıktı Sınıfı	Hedef Sınıfı	
0	0	2380 46.2%
0	1	130 2.5%
1	0	195 3.8%
1	1	2445 47.5%
2	0	92.4% 7.6%
2	1	95.0% 5.0%
2	2	93.7% 6.3%



Şekil 3.27 PCA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)



Şekil 3.27 PCA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)


Çizelge 3.12 ile PCA işlemi sonrası AdaBoost için ROC eğrilerinin AUC değerleri verilmiştir.

Çizelge 3.12 PCA ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri


Veri	AUC Bilgisi
Bulut	0.9731
Yeryüzü	0.9664
Füze	0.9997
Egzoz Dumanı	0.9810
Gökyüzü	0.9624

Boyut azaltımı metodunda Sinir Ağları (NN) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımlar yüzdelere Şekil 3.28 ile verilmiştir.


		Bulut		
Çıktı Sınıfı	0	24473 43.8%	3066 5.5%	88.9% 11.1%
	1	3457 6.2%	24864 44.5%	87.8% 12.2%
		87.6% 12.4%	89.0% 11.0%	88.3% 11.7%
		0	1	
		Hedef Sınıfı		




		Hedef Sınıfı		
Çıktı Sınıfı	0	24179 41.5%	4852 8.3%	83.3% 16.7%
	1	4981 8.5%	24308 41.7%	83.0% 17.0%
		82.9% 17.1%	83.4% 16.6%	83.1% 16.9%
		0	1	
		Yeryüzü		



		Füze		
Çıktı Sınıfı	0	1038 49.1%	24 1.1%	97.7% 2.3%
	1	20 0.9%	1034 48.9%	98.1% 1.9%
		98.1% 1.9%	97.7% 2.3%	97.9% 2.1%
		0	1	
		Hedef Sınıfı		



Şekil 3.28 NN ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri




Şekil 3.28 NN ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)

Çizelge 3.13 ile NN işlemi sonrası AdaBoost için ROC eğrilerinin AUC değerleri verilmiştir.


Çizelge 3.13 NN ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.9540
Yeryüzü	0.9071
Füze	0.9963
Egzoz Dumanı	0.9368
Gökyüzü	0.9135

Boyut azaltımı metodunda Bağımsız Bileşenler Analizi (ICA) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımların yüzdeleri Şekil 3.29 ile verilmiştir.



Şekil 3.29 ICA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri



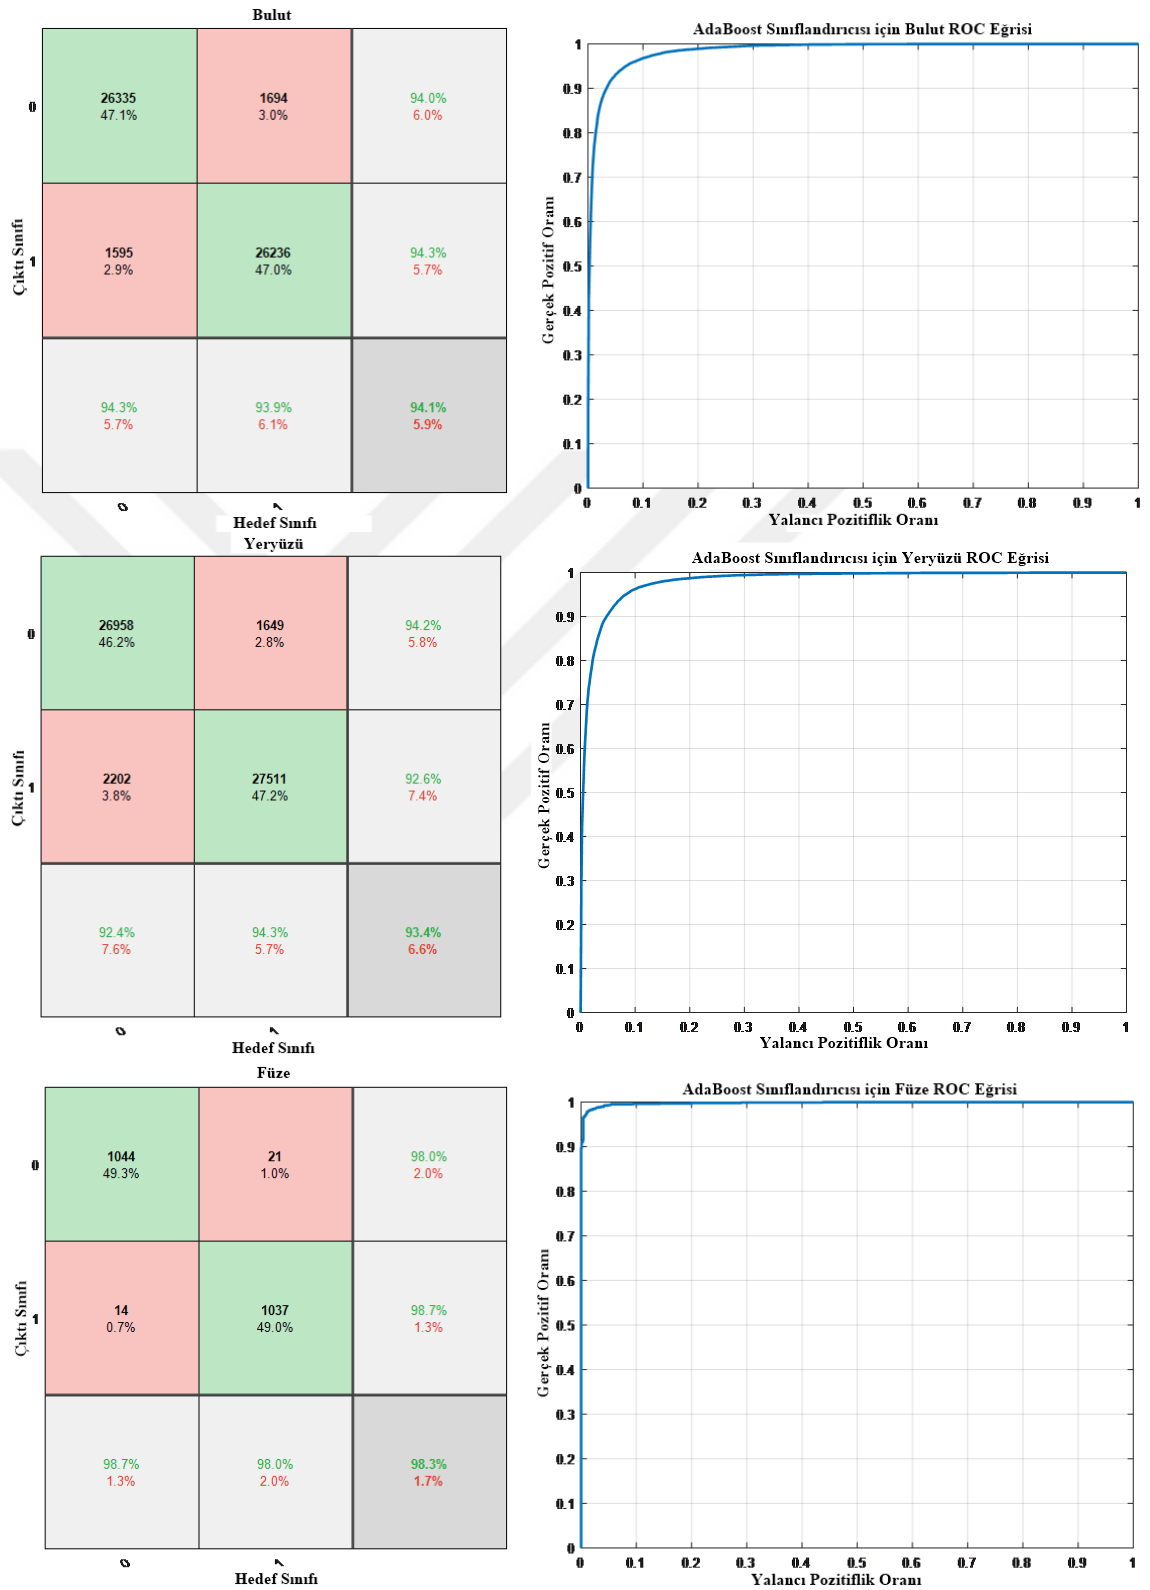
Şekil 3.29 ICA ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)

Çizelge 3.14 ile ICA işlemi sonrası AdaBoost için ROC eğrilerinin AUC değerleri verilmiştir.


Çizelge 3.14 ICA ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.8350
Yeryüzü	0.8074
Füze	0.9836
Egzoz Dumanı	0.8974
Gökyüzü	0.8306

Boyut azaltımı metodunda Maksimum Gürültü Oranı (MNF) kullanılarak yapılan sınıflandırma sonucunda elde edilen başarımların yüzdeleri Şekil 3.30 ile verilmiştir.



Şekil 3.30 MNF ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri



Şekil 3.30 MNF ve AdaBoost Sonucunda Elde Edilen Hata Matrisi ve ROC Eğrisi Grafikleri (devam)

Çizelge 3.15 ile MNF işlemi sonrası AdaBoost için ROC eğrilerinin AUC değerleri verilmiştir.

Çizelge 3.15 MNF ve AdaBoost Sonucunda Elde Edilen AUC Bilgileri

Veri	AUC Bilgisi
Bulut	0.9856
Yeryüzü	0.9808
Füze	0.9981
Egzoz Dumanı	0.9797
Gökyüzü	0.9783

Çizelge 3.16 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre AdaBoost sınıflandırıcısı sonucu elde edilen sınıflandırma doğrulukları verilmiştir.

Çizelge 3.16 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	90.8	94.1	75.6	88.3
Yeryüzü	90.5	93.4	73.2	83.1
Füze	99.0	98.3	95.0	97.9
Egzoz Dumanı	93.7	93.8	81.4	86.8
Gökyüzü	89.6	92.5	75.2	83.2

Çizelge 3.17 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre AdaBoost sınıflandırıcısı sonucu elde edilen kesinlik (precision) değerleri verilmiştir.

Çizelge 3.17 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	90.7	94.3	78.3	87.8
Yeryüzü	90.0	92.6	72.7	83.0
Füze	99.3	98.7	96.5	98.1
Egzoz Dumanı	92.6	93.4	82.3	86.0
Gökyüzü	89.8	92.7	74.1	83.0

Çizelge 3.18 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre AdaBoost sınıflandırıcısı sonucu elde edilen duyarlılık (recall) değerleri verilmiştir.

Çizelge 3.18 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	90.9	93.9	70.8	89.0
Yeryüzü	91.2	94.3	74.3	83.4
Füze	98.7	98.0	93.5	97.7
Egzoz Dumanı	95.0	94.3	80.1	87.9
Gökyüzü	89.4	92.2	77.3	83.4

Çizelge 3.19 ile dört farklı boyut azaltımı yöntemi için her sınıfa göre AdaBoost sınıflandırıcısı sonucu elde edilen AUC değerleri verilmiştir.

Çizelge 3.19 Her Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen AUC Değerleri

Yöntem Veri	PCA	MNF	ICA	NN
Bulut	0.9731	0.9856	0.8350	0.9540
Yeryüzü	0.9664	0.9808	0.8074	0.9071
Füze	0.9997	0.9981	0.9836	0.9963
Egzoz Dumanı	0.9810	0.9797	0.8974	0.9368
Gökyüzü	0.9624	0.9783	0.8306	0.9135

Şekil 3.31, Şekil 3.32, Şekil 3.33 ve Şekil 3.34 ile beş sınıf için elde edilen hata matrisleri dört farklı boyut azaltımı yöntemine göre AdaBoost sınıflandırma sonuçları verilmiştir.

5 Sınıf için Hata Matrisi							
Çıktı Sınıfları	1	201 9.5%	8 0.4%	8 0.4%	1 0.0%	21 1.0%	84.1% 15.9%
	2	15 0.7%	199 9.4%	2 0.1%	0 0.0%	45 2.1%	76.2% 23.8%
	3	0 0.0%	4 0.2%	1039 49.1%	1 0.0%	0 0.0%	99.5% 0.5%
	4	4 0.2%	20 0.9%	9 0.4%	13 0.6%	6 0.3%	25.0% 75.0%
	5	12 0.6%	10 0.5%	0 0.0%	0 0.0%	498 23.5%	95.8% 4.2%
	86.6% 13.4%	82.6% 17.4%	98.2% 1.8%	86.7% 13.3%	87.4% 12.6%	92.2% 7.8%	
		Hedef Sınıfları					
		1	2	3	4	5	

Şekil 3.31 PCA ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

5 Sınıf için Hata Matrisi							
Çıktı Sınıfları	1	222 10.5%	2 0.1%	1 0.0%	1 0.0%	18 0.9%	91.0% 9.0%
	2	14 0.7%	217 10.3%	8 0.4%	0 0.0%	31 1.5%	80.4% 19.6%
	3	1 0.0%	1 0.0%	1002 47.4%	0 0.0%	2 0.1%	99.6% 0.4%
	4	7 0.3%	4 0.2%	33 1.6%	13 0.6%	5 0.2%	21.0% 79.0%
	5	16 0.8%	14 0.7%	14 0.7%	1 0.0%	489 23.1%	91.6% 8.4%
	85.4% 14.6%	91.2% 8.8%	94.7% 5.3%	86.7% 13.3%	89.7% 10.3%	91.8% 8.2%	
		Hedef Sınıfları					
		1	2	3	4	5	

Şekil 3.32 MNF ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

5 Sınıf için Hata Matrisi

Çıktı Sınıfları	1	154 7.3%	7 0.3%	6 0.3%	5 0.2%	37 1.7%	73.7% 26.3%
	2	16 0.8%	143 6.8%	14 0.7%	0 0.0%	74 3.5%	57.9% 42.1%
	3	2 0.1%	3 0.1%	1029 48.6%	0 0.0%	1 0.0%	99.4% 0.6%
	4	48 2.3%	9 0.4%	6 0.3%	20 0.9%	28 1.3%	18.0% 82.0%
	5	19 0.9%	33 1.6%	3 0.1%	1 0.0%	458 21.6%	89.1% 10.9%
		64.4% 35.6%	73.3% 26.7%	97.3% 2.7%	76.9% 23.1%	76.6% 23.4%	85.3% 14.7%
		Hedef Sınıfları					
		1	2	3	4	5	

Şekil 3.33 NN ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

5 Sınıf için Hata Matrisi

Çıktı Sınıfları	1	111 5.2%	25 1.2%	52 2.5%	1 0.0%	65 3.1%	43.7% 56.3%
	2	36 1.7%	132 6.2%	12 0.6%	3 0.1%	106 5.0%	45.7% 54.3%
	3	9 0.4%	4 0.2%	949 44.8%	0 0.0%	3 0.1%	98.3% 1.7%
	4	27 1.3%	17 0.8%	28 1.3%	13 0.6%	29 1.4%	11.4% 88.6%
	5	43 2.0%	43 2.0%	17 0.8%	2 0.1%	389 18.4%	78.7% 21.3%
		49.1% 50.9%	59.7% 40.3%	89.7% 10.3%	68.4% 31.6%	65.7% 34.3%	75.3% 24.7%
		Hedef Sınıfları					
		1	2	3	4	5	

Şekil 3.34 ICA ve AdaBoost Sonucunda 5 Sınıf için Elde Edilen Hata Matrisi

Çizelge 3.20 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre AdaBoost sınıflandırıcısı sonucu elde edilen sınıflandırma doğrulukları verilmiştir.

Çizelge 3.20 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Sınıflandırma Doğrulukları

Yöntem Veri	PCA	MNF	NN	ICA
5 Sınıf	92.2	91.8	85.3	75.3

Çizelge 3.21 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre AdaBoost sınıflandırıcısı sonucu elde edilen kesinlik değerleri verilmiştir.

Çizelge 3.21 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Kesinlik Değerleri

Yöntem Veri	PCA	MNF	NN	ICA
Bulut	80.2	86.2	72.9	37.9
Yeryüzü	63.3	68.9	53.7	46.4
Füze	100	100	99.9	99.9
Egzoz Dumanı	28.9	51.2	19.7	20.0
Gökyüzü	92.9	96.4	84.8	71.6

Çizelge 3.22 ile beş sınıf için dört farklı boyut azaltımı yöntemine göre AdaBoost sınıflandırıcısı sonucu elde edilen duyarlılık değerleri verilmiştir.

Çizelge 3.22 Beş Sınıf için Dört Farklı Boyut Azaltımı Yöntemi ve AdaBoost Sınıflandırıcısı Uygulanarak Elde Edilen Duyarlılık Değerleri

Yöntem Veri	PCA	MNF	NN	ICA
Bulut	89.2	93.8	78.6	53.3
Yeryüzü	85.5	95.3	76.1	61.0
Füze	92.2	91.4	88.0	83.0
Egzoz Dumanı	64.7	91.7	60.0	64.7
Gökyüzü	86.0	90.0	78.8	67.7

Çizelge 3.20, Çizelge 3.21 ve Çizelge 3.22 ile beş sınıfa çoklu AdaBoost sınıflandırma algoritması uygulanmasıyla elde edilen sonuçlar incelenmiştir. Buna göre dört boyut azaltımı yöntemi içinden PCA ve MNF yöntemlerinin en iyi sonuçları verdiği ve ICA yönteminin ise en kötü sonucu verdiği bulunmuştur. NN yönteminin üçüncü en iyi yöntem olduğu değerlendirilmiştir.


Sınıf verilerinin başarımların yüzdeleri 3.2.1.3 bölümünde detaylandırılan dört farklı boyut azaltımı yönteminden elde edilen farklı veri setlerinin hepsi için incelenmiştir. Her yöntem ve sınıf için başarımların yüzdeleri ~%90 ve daha fazla olduğundan bu bölümde belirtilen yöntemin kullanılmasına karar verilmiştir.

Sınıflandırma algoritmasında, veri sayısının artırılmasının yanı sıra hem referans veri seti hem de HS görüntülerin ışıma değerleri normalize edilerek kullanılan değerlerin belirli sınırlar arasında kalması sağlanmıştır. Normalize edilen veri seti öznelik çıkarımı algoritmalarına girdi olarak verilmiştir. Bahsi geçen iyileştirmelere ek olarak geçirgenliğin az olduğu CO₂ bandının (4.2 μ m) her iki tarafında var olan dar emisyon bantları (mavi uç 4.18 μ m, kırmızı uç 4.38 μ m) da algoritmaya dahil edilmiştir. İki banda ait verilerin oranları da normalize edilmiş sınıflandırma için gerekli olan eğitim ve test verisine dâhil edilmiştir. Tüm bu düzenlemeler sonucunda oluşturulan veri matrisleri karar algoritmasına girdi olarak verilmiş, seçilen HS görüntüleri test edilerek Şekil 0.35 ile gösterildiği gibi renklendirilmiştir. Şekil 3.35 ile PCA ve AdaBoost sonucunda elde edilen sınıflandırma sonuçları gösterilmiştir. Renklendirme işlemi;


- Füze verisi: kırmızı
- Gökyüzü verisi: koyu mavi
- Yeryüzü verisi: yeşil
- Bulut verisi: beyaz
- Egzoz Dumanı verisi: gri

olacak şekilde belirlenmiştir.


Renklendirme işlemi uygulanan HS görüntülerinin farklı algoritma sonuçları Şekil 3.35, Şekil 3.36, Şekil 3.37 ve Şekil 3.38 ile verilmiştir




Şekil 3.35 PCA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler




Şekil 3.35 PCA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)




Şekil 3.36 MNF ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler




Şekil 3.36 MNF ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)




Şekil 3.37 ICA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler



Şekil 3.37 ICA ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)



Şekil 3.38 NN ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler



Şekil 3.38 NN ve AdaBoost Kullanılarak Sınıflandırılan Farklı Zamanlarda Alınmış Hiperspektral Görüntüler (devam)

Yukarıda anlatılan boyut azaltımı ve sınıflandırma işlemleri hiperspektral verilerin tüm bantlarına uygulanmıştır.

Çizelge 3.16 incelendiğinde dört farklı boyut azaltımı tekniği için AdaBoost sonucu elde edilen hata matrislerinin 5 farklı sınıfın herbirini diğerlerinden ne kadar iyi ayırdığının oranları verilmiştir. Çizelge 3.17 ve Çizelge 3.18 ile sınıflandırıcı modellerinin kesinlik ve duyarlılık değerleri belirtilmiştir. Çizelge 3.16 incelendiğinde dört yöntem içinden PCA ve MNF'nin her sınıf için yüzde ~%90 ve üzerinde başarımlar sağladığı görülürken, ICA yönteminin ise en kötü sonuçları verdiği görülmüştür. Dört boyut azaltımı tekniğinin de AdaBoost ile sınıflandırılması sonucunda füze verisinin diğer sınıflardan yüksek doğruluk oranıyla ayrıldığı görülmektedir. Çizelge 3.17 ve Çizelge 3.18 incelendiğinde yine en iyi sonuçları PCA ve MNF yöntemlerinin verdiği, en kötü sonucu ise ICA yönteminin verdiği bulunmuştur. NN yöntemi ise dört farklı boyut azaltımı yöntemi arasında üçüncü en iyi yöntem olmuştur. Çizelge 3.19 ile AUC sonuçları verilmiştir. AdaBoost için AUC sonuçları incelendiğinde PCA ve MNF yöntemleri en başarılı iki yöntem olurken, ICA ise yine en kötü sonuçları vermiştir. Şekil 3.35, Şekil 3.36, Şekil 3.37 ve Şekil 3.38 ile AdaBoost sonuçları görsel olarak incelendiğinde, dört boyut azaltımı yönteminin de füzeyi arka plandan ayırt edebildiği ancak ICA yönteminin füze dışındaki sınıfları sahnede ayırt edemediği görülmüştür. Diğer yöntemlerin renklendirme sonuçlarının gerçek hiperspektral görüntüye benzer görüntüler verdiği görülmüştür. AdaBoost sınıflandırıcısı kullanıldığında dört boyut azaltımı yöntemi değerlendirildiğinde PCA ve MNF'nin en iyi yöntemler olduğu, ICA'nın en kötü sonuçları verdiği ve NN'nin üçüncü en iyi yöntem olduğu bulunmuştur. Görsel sonuçlar değerlendirildiğinde ise AdaBoost sınıflandırıcısı kullanıldığında dört boyut azaltımı yönteminin de füzeyi arkaplandan ayırabildiği tespit edilmiştir.

4. TARTIŞMA VE SONUÇ

Hava taşıtları KÖ ışıma yapmaktadır. Hava taşıtının yaptığı ışıma miktarı sıcaklığına ve salıcılık değeriine bağıdır. Karadan havaya atılan füzelerde hava platformunun KÖ emisyonuna kilit atan arayıcı bulunmaktadır ve bu arayıcı füzeye güdüm bilgisi sağlamaktadır. KÖ güdümlü füzeler önceleri hava platformunun sadece yüksek ışıma yapan motor ve egzoz çevresi gibi bölgelerine kilit atabilirken, günümüzde detektör teknolojisinin gelişmesiyle platformun çeşitli bölgelerine de KÖ güdümlü füze atılabilmektedir. Yani önceden KÖ füzeler tek yönden platforma atılabılırken günümüzde her yönden atılabilmektedir.

Hava platformunu KÖ güdümlü füzelerden korumak amacıyla çeşitli yöntemler geliştirilmiştir. Birinci nesil KÖ füzeler yüksek ısı kaynağına kilitlendiğinden, platformdan fırlatıldığında yüksek sıcaklık veren ısı fişekleri atılarak kandırılabilmekteydi. Ancak füze teknolojisi geliştikçe sadece belirli bantlardaki ısı kaynaklarını takip eden veya belirli bir ışıma profilini takip eden detektörler geliştirilmiştir. Bu detektörler sadece yüksek sıcaklık yayan ısı fişeklerine aldanmamaktadır. Sadece yüksek ışıma yayan ısı fişeklerinin yeterli olmaması ile hava platformunun hareketini ve ışımasını taklit edebilen ısı fişekleri ve modüleli sinyal yayarak füzenin güdümünü bozan IRCM sistemleri geliştirilmiştir. Günümüzde görüntülemeli KÖ arayıcıların geliştirilmesiyle, platform hareketini ve ışımasını taklit edebilen ısı fişekleri ve IRCM sistemleri de etkinliğini yitirmiştir. Görüntülemeli KÖ arayıcılara karşı DIRCM gibi sistemler kullanılmaktadır. Yukarıda bahsedildiği gibi KÖ füze ve karşı tedbir teknolojileri birbirine paralel olarak gelişmektedir. Bu nedenle hangi tehdide hangi karşı tedbirin uygulanacağı önem arz etmektedir. Ancak KÖ füzelere etkili bir şekilde karşı tedbir uygulayabilmek için öncesinde tehdidin tespit edilmesi gerekmektedir.

Hava platformunun, KÖ güdümlü füzeleri tespit edebilmesi için çeşitli sistemler geliştirilmiştir. Füze ikaz sistemleri kullanılarak füzenin daha ateşlendiği anda platforma ulaşmadan tespit edilmesi amaçlanmaktadır. FİS içerisinde çeşitli görüntü işleme

algoritmaları kullanılarak füzenin tespit edilmesi amaçlanmaktadır. Bu algoritmalar füzenin hızı, ışıma miktarı, hareketi gibi farklı özniteliklerini kullanarak tehdidi tespit etmektedir.

Bu tez çalışmasında hiperspektral sahnede bulunan bulut, yeryüzü, füze, füze egzoz dumanı ve gökyüzü sınıflarına ait verilerin sınıflandırılması amaçlanmıştır. Bu kapsamda farklı günlerde farklı konumlardan alınan 41 banda sahip 194 adet hiperspektral görüntü incelenmiştir. Hiperspektral görüntüler iki boyutlu matris olarak 81920×41 ve üç boyutlu veriküpü olarak $256 \times 320 \times 41$ boyutlarıyla ifade edilmektedir. Hiperspektral görüntülerin hepsi alt alta eklenerek $(194 \times 81920) \times 41$ boyutlu matris elde edilmiş ve bu matristen 41 bant için maksimum ve minimum değerleri barındıran 1×41 boyutlu iki adet vektör bulunmuştur. Bulunan değerler kullanılarak hiperspektral veriler normalize edilmiş ve ışıma değerleri 0 – 1 aralığına getirilmiştir. Böylece farklı günlerde alınan veriler belirli bir skalaya ölçeklendirilmiştir. Normalizasyon işleminden sonra eğitim aşamasında kullanmak amacıyla 194 adet görüntüden 5 sınıfa ait örnekler toplanarak referans veri seti oluşturulmuştur. Referans veri setine PCA, MNF, NN ve ICA boyut azaltımı yöntemleri ayrı ayrı uygulanmış ve her yöntem için dönüşüm matrisi kaydedilmiştir. Boyut azaltımı işlemi sonucunda 10 özelliğe sahip dört farklı veri seti elde edilmiştir. 10 boyuta indirilen verilere 11. öznitelik olarak Kırmızı/Mavi uç oranı eklenmiştir. Boyutu azaltılmış veriler kullanılarak her sınıf için SVM ve AdaBoost sınıflandırıcıları eğitilmiştir. Eğitim aşamasında veriler %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Böylece test verisi kullanılarak sınıflandırıcıların performansı değerlendirilmiştir. SVM sınıflandırıcısının performans değerlendirmesi PCA için Şekil 3.14 ve Çizelge 3.1 ile NN için Şekil 3.15 ve Çizelge 3.2 ile ICA için Şekil 3.16 ve Çizelge 3.3 ile MNF için Şekil 3.17 ve Çizelge 3.4 ile verilmiştir. SVM sınıflandırıcısının beş sınıf için değerlendirmesi Şekil 3.18, Şekil 3.19, Şekil 3.20, Şekil 3.21, Çizelge 3.9, Çizelge 3.10 ve Çizelge 3.11 ile verilmiştir. AdaBoost sınıflandırıcısının performans değerlendirmesi PCA için Şekil 3.27 ve Çizelge 3.12 ile NN için Şekil 3.28 ve Çizelge 3.13 ile ICA için Şekil 3.29 ve Çizelge 3.14 ile MNF için Şekil 3.30 ve Çizelge 3.15 ile verilmiştir. AdaBoost sınıflandırıcısının beş sınıf için değerlendirmesi Şekil 3.31, Şekil 3.32, Şekil

3.33, Şekil 3.34, Çizelge 3.20, Çizelge 3.21 ve Çizelge 3.22 ile verilmiştir. Şekil3.2 ile eğitim aşaması blok şemalar halinde verilmiştir.

Eğitim aşamasından sonra 194 adet hiperspektral görüntüdeki nesnelerin sınıflandırılması amaçlanmıştır. Bunun için daha önce kaydedilen dönüşüm matrisleri kullanılarak hiperspektral veri küpleri 10 boyuta düşürülmüştür ve her pikselin Kırmızı/Mavi uç oranı 11. öznitelik olarak eklenmiştir. 11 boyutlu 194 adet hiperspektral görüntü daha önce eğitilen SVM ve AdaBoost sınıflandırıcılarına verilmiş ve işlem sonucunda her bir piksele 5 sınıftan birine ait etiket atanmıştır. Atanan bu etiketlere göre sınıflandırılan pikseller renklendirilmiştir. Renklendirme sonucunda elde edilen görüntüler hiperspektral görüntünün 41 dalgaboyu kullanılarak elde edilen radyometrik görüntü ile birlikte verilmiştir. Radyometrik görüntü ve renklendirme sonucu elde edilen görüntülerin benzer olduğu görülmüştür. SVM sınıflandırması sonucu elde edilen renklendirilmiş görüntüler PCA için Şekil 3.22 ile MNF için Şekil 3.23 ile ICA için Şekil 3.24 ile NN için Şekil 3.25 ile verilmiştir. AdaBoost sınıflandırması sonucu elde edilen renklendirilmiş görüntüler PCA için Şekil 3.35 ile MNF için Şekil 3.36 ile ICA için Şekil 3.37 ile NN için Şekil 3.38 ile verilmiştir. Şekil 3.12 ile eğitim aşamasından sonraki işlemler blok şemalar halinde verilmiştir. Buna göre dört boyut azaltımı yöntemi için hem SVM hem de AdaBoost sınıflandırıcıları kullanılarak füzelerin doğru şekilde sınıflandırıldığı görülmüştür. PCA ve MNF yöntemlerinin 5 farklı sınıfı başarılı bir şekilde sınıflandırabildiği görülmüş ICA yönteminin ise füzeyi doğru şekilde sınıflandırmasına rağmen arkaplan sınıflandırmasında hatalı sonuçlar verdiği görülmüştür.

Çizelge 3.6, Çizelge 3.7 ve Çizelge 3.8 ile SVM sınıflandırıcısı için dört farklı boyut azaltımı yönteminin doğruluk, kesinlik ve duyarlılık değerleri verilmiştir. Bu çizelgeler incelendiğinde SVM için en iyi sonuçları PCA ve MNF'nin, en kötü sonucu ise ICA'nın verdiği bulunmuştur. Çizelge 3.16, Çizelge 3.17 ve Çizelge 3.18 ile AdaBoost sınıflandırıcısı için dört farklı boyut azaltımı yönteminin doğruluk, kesinlik ve duyarlılık değerleri verilmiştir. Bu çizelgeler incelendiğinde AdaBoost için en iyi sonuçları PCA ve MNF'nin, en kötü sonucu ise ICA'nın verdiği bulunmuştur. NN yöntemi her iki sınıflandırıcı için en iyi üçüncü sonucu vermiştir.

Çizelge 3.9, Çizelge 3.10 ve Çizelge 3.11 ile beş sınıfa dört farklı boyut azaltımı yöntemi ve SVM sınıflandırıcısı uygulanması sonucu elde edilen doğruluk, kesinlik ve duyarlılık değerleri verilmiştir. Bu çizelgeler incelendiğinde SVM için en iyi sonuçları PCA ve MNF'nin, en kötü sonucu ise ICA'nın verdiği bulunmuştur. Çizelge 3.20, Çizelge 3.21 ve Çizelge 3.22 ile beş sınıfa dört farklı boyut azaltımı yöntemi ve AdaBoost sınıflandırıcısı uygulanması sonucu elde edilen doğruluk, kesinlik ve duyarlılık değerleri verilmiştir. NN yöntemi her iki sınıflandırıcı için en iyi üçüncü sonucu vermiştir.

Sonuçlar değerlendirildiğinde PCA ve MNF yöntemlerinin en başarılı sonuçları verdiği bulunmuştur. Bu iki yöntemden sonra NN yönteminin geldiği ve en kötü sonuçları ICA yönteminin verdiği bulunmuştur.

Çizelge 4.1, Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4 ile beş farklı sınıfa göre AdaBoost ve SVM sınıflandırıcıları kullanılarak elde edilen doğruluk, kesinlik, duyarlılık ve AUC değerleri dört farklı boyut azaltımı yöntemi için verilmiştir. AdaBoost ve SVM yöntemleri incelendiğinde benzer sonuçlar verdiği bulunmuştur. Çizelge 4.1, Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4 incelendiğinde füzeyi diğer sınıflardan ayırmada AdaBoost sınıflandırıcısının daha başarılı olduğu, füze dışındaki sınıfların birbirinden ayrılmasında ise SVM sınıflandırıcısının daha başarılı olduğu bulunmuştur.

Çizelge 4.1 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Doğruluk Değerleri

Doğruluk Değerleri	Bulut		Yeryüzü		Füze		Egzoz Dumanı		Gökyüzü	
	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM
PCA	90.8	92.6	90.5	91.0	99.0	96.8	93.7	94.5	89.6	90.1
MNF	94.1	95.2	93.4	93.2	98.3	96.8	93.8	94.1	92.5	92.5
ICA	75.6	76.6	73.2	72.7	95.0	92.7	81.4	83.8	75.2	75.9
NN	88.3	89.0	83.1	84.4	97.9	94.8	86.8	87.4	83.2	83.7

Çizelge 4.2 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Kesinlik Değerleri

Kesinlik Değerleri	Bulut		Yeryüzü		Füze		Egzoz Dumanı		Gökyüzü	
	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM
PCA	90.7	93.2	90.0	90.1	99.3	100	92.6	93.9	89.8	90
MNF	94.3	95.3	92.6	92.0	98.7	99.5	93.4	94.2	92.7	93.4
ICA	78.3	80.3	72.7	72.7	96.5	98.9	82.3	86.8	74.1	74.5
NN	87.8	88.4	83.0	84.4	98.1	99.9	86.0	84.9	83.0	83.0

Çizelge 4.3 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen Duyarlılık Değerleri


Duyarlılık Değerleri	Bulut		Yeryüzü		Füze		Egzoz Dumanı		Gökyüzü	
	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM
PCA	90.9	91.9	91.2	92.1	98.7	93.7	95.0	95.2	89.4	90.2
MNF	93.9	95.1	94.3	94.6	98.0	94.1	94.3	93.9	92.2	91.4
ICA	70.8	70.5	74.3	75.0	93.5	86.3	80.1	79.7	77.3	78.8
NN	89.0	89.7	83.4	84.3	97.7	89.8	87.9	91.0	83.4	84.8

Çizelge 4.4 AdaBoost ve SVM Sınıflandırma Sonuçları Elde Edilen AUC Değerleri

AUC Değerleri	Bulut		Yeryüzü		Füze		Egzoz Dumanı		Gökyüzü	
	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM	AdaBoost	SVM
PCA	0.9731	0.9797	0.9664	0.9683	0.9997	0.9968	0.9810	0.9881	0.9624	0.9627
MNF	0.9856	0.9887	0.9808	0.9801	0.9981	0.9965	0.9797	0.9917	0.9783	0.9748
ICA	0.8350	0.8645	0.8074	0.8287	0.9836	0.9752	0.8974	0.9603	0.8306	0.8389
NN	0.9540	0.9501	0.9071	0.9145	0.9963	0.9840	0.9368	0.9488	0.9135	0.9139


Çalışmada hiperspektral verilere boyut azaltımı yöntemi uygulanarak 41 öznitelik 10 özniteliğe düşürülmüş ve ek olarak Kırmızı/Mavi uç oranı 11. öznitelik olarak eklenmiştir. Ön işlem yapılan verilerin bir kısmı kullanılarak SVM ve AdaBoost sınıflandırıcıları eğitilmiş ve geriye kalan veriler ile sınıflandırıcıların başarımı test edilmiştir. Sonrasında ise eğitilen sınıflandırıcılar kullanılarak 194 adet hiperspektral görüntü sınıflandırılarak, her sınıfa göre renklendirme işlemi gerçekleştirilmiştir. Sınıflandırma doğruluğu hata matrisi, AUC, ROC ve görsel olarak değerlendirilmiştir.

Görüntülere bant bastıran çentik (notch) süzgeç ve bilateral süzgeç uygulanmıştır. Gauss cnotch kullanılarak oluşturulan süzgecin görüntülere uygulanmasıyla elde edilen sınıflandırma sonuçları Şekil 4.1 ile verilmiştir. Sonuçlardan filtre uygulanması sonucu görüntülerde bozulmalar meydana geldiği görülmektedir.




Şekil 4.1 Gauss cnotch Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları

Gauss cnotch ve bilateral filtrelerin görüntülere uygulanmasıyla elde edilen sınıflandırma sonuçları Şekil 4.2 ile verilmiştir. Sonuçlardan cnotch filtre uygulanması ile bazı görüntülerde bozulmalar meydana geldiği görülmektedir.




Şekil 4.2 Gauss cnotch ve Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları

recnotch filtrenin görüntülere uygulanmasıyla elde edilen sınıflandırma sonuçları Şekil 4.3 ile verilmiştir. Sonuçlardan recnotch filtre uygulanması ile bazı görüntülerde bozulmalar meydana geldiği görülmektedir.




Şekil 4.3 renotch Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları

renotch ve bilateral filtrelerin görüntülere uygulanmasıyla elde edilen sınıflandırma sonuçları Şekil 4.4 ile verilmiştir. Sonuçlardan cnotch filtre uygulanması ile bazı görüntülerde bozulmalar meydana geldiği görülmektedir.



Şekil 4.4 renotch ve Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları

bilateral filtrenin görüntülere uygulanmasıyla elde edilen sınıflandırma sonuçları Şekil 4.5 ile verilmiştir. Sonuçlardan bilateral filtre uygulanması ile bazı görüntülerde periyodik gürültünün kaldırılamadığı ancak görüntülerde az miktarda bulanıklaşma meydana geldiği görülmektedir.



Şekil 4.5 Bilateral Filtre Kullanılarak AdaBoost ile Elde Edilen Sınıflandırma Sonuçları

Görüntülere notch ve bilateral filtreler gürültüleri kaldırmak amacıyla uygulanmıştır. Şekil 4.1-4.5 ile hem filtre uygulanmış görüntüler hem de bu görüntülerin sınıflandırma sonucu elde edilen renklendirilmiş halleri verilmiştir. Filtrelenmiş görüntüler incelendiğinde görüntülerin bazı bölümlerinde uzama, negatif piksel değerleri bulunması, bazı bölgelerde fazla yumuşama vb. gibi bozulmaların meydana geldiği görülmüştür. Bu bozulmaların sonucunda da renklendirilmiş görüntülerden sınıflandırma doğruluklarının azaldığı bulunmuştur.

SVM ve AdaBoost sonuçlarının dört boyut azaltımı tekniği içinde sayısal ve görsel olarak benzer sonuçlar verdiği elde edilmiştir. SVM ve AdaBoost ile elde edilen sınıflandırma sonuçlarından dört boyut azaltımı tekniğinden en iyi sonuçları PCA ve MNF yöntemlerinin verdiği bulunmuştur. Bu yöntemlerden sonra NN yöntemi iyi sonuçlar vermiştir. ICA yöntemi ise en kötü sonuçları vermiştir.

Literatür incelendiğinde hiperspektral görüntüler kullanılarak çeşitli işlemlerin yapılabildiği görülmektedir. Ancak bu çalışmalar arasında güdümlü füze tespiti için yapılmış çok fazla çalışma bulunmamaktadır. Bu çalışma kapsamında özellikle güdümlü füzelerin hiperspektral veriler kullanılarak tespiti üzerine yoğunlaşmıştır. Çalışmada, hiperspektral görüntüler içerisindeki spektral öznitelikler dikkate alınarak sahnedeki varlıkların eğitilmiş sınıflandırılması yapılmıştır. Bu çalışma kapsamında hiperspektral görüntülerdeki yeryüzü, gökyüzü, bulutlar, güdümlü füze ve güdümlü füzenin ardında bıraktığı duman birbirinden ayrılmaya çalışılmıştır. Literatürde farklı zamanlarda alınan spektral görüntüler üzerinde daha çok değişiklik tespiti algoritmaları çalışılmıştır. Bu çalışmada ise farklı zamanlarda alınan hiperspektral görüntülere boyut azaltımı algoritmaları uygulanmış ve sonrasında sınıflandırma işlemi gerçekleştirilmiştir. Bu açıdan da hiperspektral görüntülerin kullanımına farklı bir bakış sunulmuştur. Daha önce, kurumsal bazda hiperspektral verilerin bu anlamda incelenmesi üzerine herhangi bir çalışma yapılmaması ve açık literatürde füze-sahte hedef ayrımının hiperspektral video kayıtları kullanılarak incelenmesi üzerine yeterli çalışma/kaynak bulunmaması sebebiyle veriye çok farklı açılardan bakma ihtiyacı duyulmuştur. Bu bakış açılarından doğan incelemeler umut verici sonuçlar vermiştir.

5. GELECEKTE YAPILABİLECEK ÇALIŞMALAR

Bu çalışmada kullanılan hiperspektral görüntüler içerisinde 3 farklı füzeye ait füze ve füze egzoz dumanı ışıma bilgileri bulunmaktadır. Sonraki çalışmalarda bu füzelere ait egzoz ve egzoz dumanı bilgileri kullanılarak füzelerin kendi içlerinde sınıflandırılmasına dair çalışmalar gerçekleştirilebilir. Böylece füze tehdidine karşı platform korumak amacıyla daha etkin karşı tedbirler uygulanabilir.

5 farklı sınıfa ait ışıma bilgileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Veriye ait 41 dalga boyu bu işlemlerde kullanılmıştır. Sonraki çalışmalarda bu 5 sınıfın birbirinden en iyi ayrıldığı dalgaboyları tespit edilerek, sadece en iyi dalga boyları kullanımıyla sınıflandırma sonuçlarının değerlendirilmesi amaçlanmaktadır. En iyi dalga boyu tespiti işleminin özellikle füze ve füze egzoz dumanı tespitinde süreci hızlandıracağı ve başarılı sonuçlar vereceği değerlendirilmektedir.

Hiperspektral görüntüler, belirli bir sıcaklığın üzerinde kızılötesi bantta ışıma yapan nesneler hakkında görüntüleme yapabildikleri bant aralığında spektral iz bilgisi vermektedir. Füzeler ateşlendikleri andan itibaren kızılötesi bantta bir ışıma yapmaktadır. Bu anlamda füzeler kızılötesi bir kaynak olarak düşünülebilir. Özellikle taşınabilir hava savunma sistemi olarak isimlendirilen karadan havaya füze sistemleri helikopter gibi hava taşıtları için büyük bir tehdit oluşturmaktadır. Bu tür tehditlerden platformu korumak için füze ikaz sistemleri kullanılarak füze tespiti yapıp ardından ısı fişegi atımı, karıştırıcı sinyal uygulama vb. gibi farklı karşı tedbirler kullanılarak tehdidin aldatılması amaçlanır. Füze ikaz sisteminin doğru bir uyarı verebilmesi için füzeyi arka plandan ayrılabilmesi gerekmektedir. Bu amaçla füze ikaz sisteminin algılama yaptığı bant aralığının veya aralıklarının bu ayrımı yapabilecek bant aralıkları olması gerekmektedir. Bu sayede füzelerin tespit olasılığı artacak ve uygulanacak karşı tedbir ile füzenin etkisiz hale getirilmesi sağlanabilecektir. Bu tez kapsamında farklı tür füzeleri barındıran hiperspektral görüntüler kullanılarak görüntülerde yer alan gökyüzü, bulut, yeryüzü, füze ve füze egzoz dumanı verilerinin sınıflandırılması yapılmıştır. Bu sayede füze ikaz sistemlerinin füze tespit doğruluğu ve etkinliğini artıracak bilgilerin elde edilerek ilerleyen süreçte bu tür sistemlerin veri kütüphanesinde girdi olarak kullanılması hedeflenmektedir.

KAYNAKLAR

- Anonymous. 2021. Web Sitesi: <https://www.analyticsvidhya.com/blog/2021/09/adaboost-algorithm-a-complete-guide-for-beginners/> Erişim Tarihi: 15.11.2021
- Anonymous. 2021. Web Sitesi: <https://blog.paperspace.com/adaboost-optimizer/> Erişim Tarihi: 15.11.2021
- Anonymous. 2021. Web Sitesi: <https://www.mygreatlearning.com/blog/adaboost-algorithm/> Erişim Tarihi: 15.11.2021
- Anonymous. 2021. Web Sitesi: <https://en.wikipedia.org/> Erişim Tarihi: 13.09.2021
- Audebert, N., Saux, Bertrand L., Lefevre, Sebastian, 2019. " Deep Learning for Classification of Hyperspectral Data: A Comparative Review ". IEEE Geoscience and Remote Sensing Magazine, Volume: 7, Issue: 2, June 2019, 159 - 173, DOI: 10.1109/MGRS.2019.2912563
- Bajcsy, Peter, ve Peter Groves. 2004. "Methodology for hyperspectral band selection". Photogrammetric Engineering and Remote Sensing 70(7):793–802. doi: 10.14358/PERS.70.7.793.
- Boggavarapu, L. N. P., ve Mprabukumar Prabukumar. 2017. "Survey on classification methods for hyper spectral remote sensing imagery". Proceedings of the 2017 International Conference on Intelligent Computing and Control Systems, ICI CCS 2017 2018-Janua:538–42. doi: 10.1109/ICCONS.2017.8250520.
- Boreman, Glenn D. 1998. Basic Electro-Optics for Electrical Engineers. Washington: SPIE.
- Freund, Yoav, ve Schapire, Robert E., 1996. " Experiments with a New Boosting Algorithm ". ICML'96: Proceedings of the Thirteenth International Conference on International Conference on Machine Learning, 148–156
- Gagnon, Marc Andre, Jean Philippe Gagnon, Pierre Tremblay, Simon Savary, Vincent Farley, Eric Guyot, Philippe Lagueux, ve Martin Chamberland. 2015. "Standoff midwave infrared hyperspectral imaging of ship plumes". Workshop on Hyperspectral Image and Signal Processing, Evolution in Remote Sensing 2015-June:2–5. doi: 10.1109/WHISPERS.2015.8075384.
- Ghamisi, Pedram, Javier Plaza, Yushi Chen, Jun Li, ve Antonio J. Plaza. 2017. "Advanced Spectral Classifiers for Hyperspectral Images: A review". IEEE Geoscience and Remote Sensing Magazine 5(1):8–32. doi: 10.1109/MGRS.2016.2616418.
- Ghamisi, Pedram, Naoto Yokoya, Jun Li, Wenzhi Liao, Sicong Liu, Javier Plaza, Behnood Rasti, ve Antonio Plaza. 2017. "Advances in Hyperspectral Image and Signal Processing: A Comprehensive Overview of the State of the Art". IEEE Geoscience and Remote Sensing Magazine 5(4):37–78. doi: 10.1109/MGRS.2017.2762087.

- Gordon, Christopher. 2000. "A generalization of the maximum noise fraction transform". *IEEE Transactions on Geoscience and Remote Sensing* 38(1 II):608–10. doi: 10.1109/36.823955.
- Greco, M., M. Diani, ve G. Corsini. 2006. "Analysis of the classification accuracy of a new MNF based feature extraction algorithm". *Image and Signal Processing for Remote Sensing XII* 6365(September 2006):63650V. doi: 10.1117/12.689961.
- Green, Andrew A., Mark Berman, Paul Switzer, ve Maurice D. Craig. 1988. "A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal". *IEEE Transactions on Geoscience and Remote Sensing* 26(1):65–74. doi: 10.1109/36.3001.
- Han, Jinhui, Yin Yu, Kun Liang, ve Honghui Zhang. 2018. "Infrared small-target detection under complex background based on subblock-level ratio-difference joint local contrast measure". *Optical Engineering* 57(10):1. doi: 10.1117/1.oe.57.10.103105.
- Huang, Da, ve Shucai Huang. 2018. "Dim and Small Target Detection Based on Characteristic Spectrum". *Journal of the Indian Society of Remote Sensing* 46(11):1915–23. doi: 10.1007/s12524-018-0856-1.
- Hundley, Douglas R. 2013. "A Solution Procedure For Blind Signal Separation Using The Maximum Noise Fraction Approach Algorithms And Examples". (January 2002).
- Hyvärinen, A., ve E. Oja. 2000. "Independent component analysis: Algorithms and applications". *Neural Networks* 13(4–5):411–30. doi: 10.1016/S0893-6080(00)00026-5.
- Ji, Luyan, Lei Wang, ve Xiurui Geng. 2019. "An automatic bad band pre-removal method for hyperspectral imagery". *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 12(12):4985–94. doi: 10.1109/JSTARS.2019.2944930.
- Kang, Xudong, Shutao Li, ve Jon Atli Benediktsson. 2014. "Feature extraction of hyperspectral images with image fusion and recursive filtering". *IEEE Transactions on Geoscience and Remote Sensing* 52(6):3742–52. doi: 10.1109/TGRS.2013.2275613.
- Kang, Xudong, Student Member, Shutao Li, ve Jón Atli Benediktsson. 2013. "Spectral – Spatial Hyperspectral Image Classification With Edge-Preserving Filtering". (MII):1–12.
- Kang, Xudong, Xuanlin Xiang, Shutao Li, ve Jon Atli Benediktsson. 2017. "PCA-Based Edge-Preserving Features for Hyperspectral Image Classification". *IEEE Transactions on Geoscience and Remote Sensing* 55(12):7140–51. doi: 10.1109/TGRS.2017.2743102.
- Kawaguchi, Shuji, ve Ryuei Nishii. 2007. "Hyperspectral image classification by bootstrap AdaBoost with random decision stumps". *IEEE Transactions on Geoscience and Remote Sensing* 45(11):3845–51. doi: 10.1109/TGRS.2007.903708.

- Kessy, Agnan, Alex Lewin, ve Korbinian Strimmer. 2018. "Optimal Whitening and Decorrelation". *American Statistician* 72(4):309–14. doi: 10.1080/00031305.2016.1277159.
- Kim, Sungho, Jungsub Shin, Joonmo Ahn, ve Sunho Kim. 2020. "Extremely robust remote-target detection based on carbon dioxide-double spikes in midwave spectral imaging". *Sensors (Switzerland)* 20(10). doi: 10.3390/s20102896.
- Kumar, Brajesh, Onkar Dikshit, Ashwani Gupta, ve Manoj Kumar Singh. 2020. "Feature extraction for hyperspectral image classification: a review". *International Journal of Remote Sensing* 41(16):6248–87. doi: 10.1080/01431161.2020.1736732.
- Liu, Xiang, Bing Zhang, Lian Ru Gao, ve Dong Mei Chen. 2009. "A maximum noise fraction transform with improved noise estimation for hyperspectral images". *Science in China, Series F: Information Sciences* 52(9):1578–87. doi: 10.1007/s11432-009-0156-z.
- Mather, Paul M., ve Koch, Magaly. 2011. "Computer Processing of Remotely-Sensed Images An Introduction". John Wiley & Sons, DOI:10.1002/9780470666517
- Mishra, Sidharth P., Sarkar, Uttam, Taraphder, Subhash, Datta, Sanjay, Swain, Devi P., Saikhom, Reshma, Panda, Sasmita, ve Laishram, Menalsh. 2017. "Multivariate Statistical Data Analysis - Principal Component Analysis (PCA)". *International Journal of Livestock Research*, Vol 7(5), 60-78, DOI-<http://dx.doi.org/10.5455/ijlr.20170415115235>
- Neele, Filip. 2005. "Two-color infrared missile warning sensors". *Airborne Intelligence, Surveillance, Reconnaissance (ISR) Systems and Applications II* 5787(May 2005):134–45. doi: 10.1117/12.603391.
- Neele, Filip P., ve Ric M. Schleijsen. 2003. "Electro-optical missile plume detection". *Targets and Backgrounds IX: Characterization and Representation* 5075(September 2003):270. doi: 10.1117/12.487510.
- Nielsen, Allan Aasbjerg, ve Rasmus Larsen. 1994. "Restoration of GERIS Data Using the Maximum Noise Fraction Transform". *International Airborne Sensing Conference an Exhibition (September 1994)*:11–15.
- Pastor, Alvaro. 2020. "Infrared guidance systems . A review of two man-portable defense applications ." Preprint.
- Pathak, Diganta Kumar, Sanjib Kumar Kalita, ve Dhruba Kumar Bhattacharya. 2020. "Classification of Hyperspectral Image using Ensemble Learning methods:A comparative study". 2020 IEEE 17th India Council International Conference, INDICON 2020 (December). doi: 10.1109/INDICON49873.2020.9342213.
- Picard, Rosalind W. 2018. "Topic: Decorrelating and then Whitening data". *Class Notes* (1):2–3.
- Rao, G. A., ve S. P. Mahulikar. 2005. "Effect of atmospheric transmission and radiance on aircraft infrared signatures". *Journal of Aircraft* 42(4):1046–54. doi: 10.2514/1.7515.

- Renuka, D. V., ve K. Maheswara Reddy. 2013. "Infrared background and missiles signature survey". *Defence Science Journal* 63(6):611–15. doi: 10.14429/dsj.63.5762.
- Richardson, Mark A. 2007. "The anatomy of the MANPAD". *Technologies for Optical Countermeasures IV* 6738(October 2007):67380H. doi: 10.1117/12.746609.
- Rodarmel, Craig, ve Jie Shan. 2002. "Principal component analysis for hyperspectral image classification". *Surveying and Land Information Science* 62(2):115–22.
- Roger, R. E. 1994. "A Faster Way to Compute the Noise-Adjusted Principal Components Transform Matrix". *IEEE Transactions on Geoscience and Remote Sensing* 32(6):1194–96. doi: 10.1109/36.338369.
- Schowengerdt, Robert A. 2012. *Remote sensing: Models and methods for image processing: Second edition*.
- Sotoca, José Martínez, Filiberto Pla, ve José Salvador Sánchez. 2007. "Band selection in multispectral images by minimization of dependent information". *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews* 37(2):258–67. doi: 10.1109/TSMCC.2006.876055.
- Sun, Weiwei, ve Qian Du. 2019. "Hyperspectral band selection: A review". *IEEE Geoscience and Remote Sensing Magazine* 7(2):118–39. doi: 10.1109/MGRS.2019.2911100.
- Vaddi, Radhesyam, ve Mprabukumar Prabukumar. 2017. "Comparative study of feature extraction techniques for hyperspectral remote sensing image classification A survey". *International Conference on Intelligent Computing and Control Systems* 543–48.
- Yao, Da-wei, Wei Hao, Xiao-jun Yang, ve Yan Tian. 2011. "Research on UV detector technology and application in MAWS". *International Symposium on Photoelectronic Detection and Imaging 2011: Advances in Imaging Detectors and Applications* 8194(August 2011):819436. doi: 10.1117/12.901021.