

UZUN DALGA KIZILÖTESİ HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ

TARGET DETECTION FROM LONG-WAVE INFRARED HYPERSPETRAL IMAGES

SEFA KÜÇÜK

Yrd. Doç. Dr. Seniha Esen Yüksel
Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliği'nin
Elektrik ve Elektronik Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

2015

SEFA KÜÇÜK'ün hazırladığı **Uzun Dalga Kızılötesi Hiperspektral Görüntülerde Hedef Tespiti** adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK - ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Aydın Alatan

Başkan

Yrd. Doç. Dr. Seniha Esen Yüksel

Danışman

Prof. Dr. A. Salim Kayhan

Üye

Yrd. Doç. Dr. Yakup Sabri Özkazanç

Üye

Yrd. Doç. Dr. Berkan Dülek

Üye

Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Fatma SEVİN DÜZ

Fen Bilimleri Enstitüsü Müdürü

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

10 / 07 / 2015

Sefa KÜÇÜK

ÖZET

UZUN DALGA KIZILÖTESİ HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ

SEFA KÜÇÜK

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Yrd. Doç. Dr. Seniha Esen Yüksel

Temmuz 2015, 102 sayfa

Bu tez kapsamında, hiperspektral görüntülerde hedef bulmaya yönelik anomali tespiti ve uç eleman analizi konuları üzerine çalışmalar yapılmıştır. Anomali tespitinde amaç, veri hakkında herhangi bir önsel bilgi olmaksızın veri içerisinde çevresine göre farklılık gösteren noktaları tespit etmektir. Hiperspektral görüntü analizinde sıklıkla kullanılan Reed-Xiaoli (RX) algoritması, veride arka planı çok değişkenli bir Gauss dağılımı ile modeller ve bir test pikselinin bu modelden ne kadar uzaklaştığını hesap eder. Çalışmada, RX tabanlı altı anomali bulucu: Global RX, Yerel RX, RXD-UTD, Çift Pencere RX, Alt Uzay RX ve Çekirdek RX uzun dalga kızılötesi (long-wave infrared - LWIR) hiperspektral verileri üzerinde uygulanmıştır. Anomali bulucuların başarımlarını etkileyen işlem yükü, gürültüye dayanım, parametre seçimi, pencere boyut etkisi gibi değişkenler kapsamlı bir şekilde incelenmiş, algoritma performansları ROC (Receiver Operating Characteristic) eğrileri kullanılarak karşılaştırılmıştır. Karşılaştırılan modelleme tabanlı altı anomali bulucu içerisinde, DWRX algoritmasının fazla işlem yükü gerektirmediği; az sayıda yanlış alarm üreterek hedef noktaları yüksek başarımla tespit ettiği görülmüştür.

Arka plan modellemeye dayalı anomali bulucuların yanısıra, toprak yüzeyindeki farklılıkları tespit etmeye yarayan öznitelik tabanlı Reststrahlen oran tespit algoritması uzun dalga kızılötesi veriler üzerinde test edilmiştir.

Anomali tespiti sonrası oluşan yanlış alarmları azaltabilmek için, uç eleman analiz yöntemleri kullanılarak yanlış alarmlara sebebiyet veren uç elemanların bulunması hedeflenmiştir. Uç eleman analizi için ICE (Iterated Constrained Endmembers), SPICE (Sparsity Promoting Iterated Constrained Endmember) ve KİDDO (Kısıtlı İkinci Dereceden Denklemlerle Optimizasyon) algoritmaları kullanılmıştır. Basit eşikleme yöntemleriyle, anomali bulucuların ve uç eleman analiz algoritmalarının hedef tespitinde birbirlerine olan katkıları incelenmiş, yanlış alarmlar azaltılmaya çalışılmıştır. Tüm algoritmalar hem yapay hem de gerçek LWIR hiperspektral veriler üzerinde test edilmiştir.

Anahtar Kelimeler: Anomali Tespiti, Hiperspektral Analiz, Uzun Dalga Kızılötesi, Uç Eleman Analizi

ABSTRACT

TARGET DETECTION FROM LONG-WAVE INFRARED HYPERSPECTRAL IMAGES

SEFA KÜÇÜK

**Master of Science, Department of
Electrical and Electronics Engineering**

Supervisor: Yrd. Doç. Dr. Seniha Esen Yüksel

July 2015, 102 pages

In this thesis, target detection from hyperspectral images has been investigated using anomaly detection and endmember extraction. The aim of anomaly detection is to detect the deviations from the normal background behavior without any prior information about the data. In hyperspectral image analysis, Reed-Xiaoli (RX) algorithm is a commonly used anomaly detector. It first models the background as a multidimensional Gaussian distribution and then computes how much a test vector deviates from the background model. In this thesis, six different RX-based anomaly detectors, namely the global RX, local RX, dual window RX, subspace RX, kernel RX and the global RX combined with a uniform target detector have been tested on long-wave infrared (LWIR) hyperspectral images. Several factors such as parameter selection, resilience to noise, computational complexity, effect of window size have been examined and the detection performances have been compared based on ROC (Receiver Operating Characteristic) curves. When we consider that it is not time-consuming and generates less false alarms, DWRX is an outstanding detector among six model-based anomaly detectors.

Apart from the background model based anomaly detectors, a feature-based anomaly detector, specifically Reststrahlen ratio detector has been employed to detect anomalies on the earth surface.

In order to reduce the false alarms, three different endmember extraction algorithms,

namely ICE (Iterated Constrained Endmembers), SPICE (Sparsity Promoting Iterated Constrained Endmember) and SPICEE (Sparse and Physically Correct Endmembers) have been used. The effect of basic thresholding methods on the performance of anomaly detection and endmember extraction algorithms are examined. All proposed methods have been tested on both synthetic and real LWIR hyperspectral data.

Keywords: Anomaly Detection, Hyperspectral Analysis, Long-Wave Infrared, Endmember Extraction

TEŐEKKÜR

Çalıőmalarım ve araőtırmalarım boyunca bana sunduđu sayısız fırsattan, sađladıđı deđerli fikir ve yardımlarından öte, göstermiő olduđu sabır ve anlayıőından dolayı tez da-nıőmanım Yrd. Doç. Dr. Seniha Esen Yüksel'e,

Bilgi ve deneyimlerini paylaőan deđerli jüri üyelerine,

Kazandırdıkları farklı bakıő açıları, destek ve yardımları için tüm araőtırma görevlisi arkadaşlarıma ve özellikle Kemal Gürkan Toker'e

Sevgi ve destekleriyle bana güç veren, beni daima destekleyen canım aileme,

Çalıőmalarım boyunca gösterdiđi hoőgörü ve sabıryla desteđini bir an olsun eksik et-meyen eőim Nagihan'a,

Tez kapsamında kullanılan hiperspektral görüntüler için HAVELSAN A. Ő.' ne ve özel-likle sayın Dr. Mustafa Yaman'a,

2228-A burs programı kapsamında desteklerinden dolayı Türkiye Bilimsel ve Teknolojik Araőtırma Kurumu'na teőekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGELER	viii
ŞEKİLLER	ix
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Tezin Amacı	5
1.2. Tezin Akışı	6
2. HİPERSPEKTRAL VERİLERDE ÖN İŞLEME	8
2.1. Doğrusal olmayan Yönbağımlı Filtreleme	8
2.2. Deneysel Sonuçlar	10
3. HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ	15
3.1. Modelleme Tabanlı Anomali Tespit Algoritmaları	15
3.1.1. Global Reed-Xiaoli Algoritması	16
3.1.2. Yerel Reed-Xiaoli Algoritması	17
3.1.3. Reed-Xiaoli ve Uniform Hedef Bulucu	17
3.1.4. Çift Pencere Reed-Xiaoli Algoritması	18
3.1.5. Alt Uzay Reed-Xiaoli Algoritması	19
3.1.6. Çekirdek Reed-Xiaoli Algoritması	20
3.2. Anomali Tespit Algoritmalarının Yapay Veri Seti Üzerinde Uygulanması ...	23
3.3. Reststrahlen Oran Tespit Algoritması	31
3.4. Uç Eleman Analiz Yöntemleri	31
3.4.1. ICE	32

3.4.2. SPICE	35
3.4.3. KİDDO	36
3.5. Uç Eleman Analiz Yöntemlerinin Yapay Veri Seti Üzerinde Uygulanması ..	37
4. GERÇEK VERİLER ÜZERİNDE DENEYSEL ÇALIŞMALAR	44
4.1. Sahne 1	44
4.1.1. Anomali Bulucuların Sahne 1 Üzerinde Uygulanması	45
4.2. Sahne 2	50
4.2.1. Anomali Bulucuların Sahne 2 Üzerinde Uygulanması	50
4.3. Sahne 3	53
4.3.1. Reststrahlen Oran Tespit Algoritmasının Sahne 3 Üzerinde Uygulanması	53
4.3.2. Anomali Bulucuların Sahne 3 Üzerinde Uygulanması	55
5. SONUÇLAR	65
KAYNAKLAR	67
EKLER	71
ÖZGEÇMİŞ	85

ÇİZELGELER

	<u>Sayfa</u>
Çizelge 3.1. Anomali tespit algoritmaları	22
Çizelge 3.2. Anomali bulucuların yapay veri seti üzerinde harcadığı süreler	24
Çizelge 3.3. ASTER sisteminin teknik özellikleri	38
Çizelge 3.4. SPICE ve KÍDDO algoritma çıktılarının karşılaştırılması [38]	40
Çizelge 4.1. Telops Hyper-Cam-LW kamerasının teknik özellikleri	44
Çizelge 4.2. Anomali bulucuların sahne 1 verisi üzerinde harcadığı süreler	46

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1.1. Hiperspektral veri küpü ve piksel spektrası [7]	2
Şekil 1.2. Genel akış diyagramı	7
Şekil 2.1. Dört komşuluklu piksel yapısının iki boyutta gösterimi	9
Şekil 2.2. Bir test pikseli için 26 komşulu üç boyutlu ağ yapısı	11
Şekil 2.3. Hiperspektral verinin (a) radyans görüntüsü, (b) yineleme sayısı 1 için yöntem çıktısı, (c) yineleme sayısı 3 için yöntem çıktısı, (d) yineleme sayısı 5 için yöntem çıktısı	12
Şekil 2.4. Yineleme sayısına bağlı spektral değişimleri incelemek için hiperspektral veri küpü üzerinden alınan bir test pikseli (mavi nokta) ...	13
Şekil 2.5. Hiperspektral veri üzerinden alınan bir test pikseli için farklı yineleme sayısına bağlı spektral değişimler	13
Şekil 2.6. Hiperspektral veri üzerinden alınan bir test pikseli için ortalama filtre çıktısı ile yineleme sayısı 1 iken yönbağımlı yayılım yöntem çıktısından elde edilen spektral değişimler	14
Şekil 3.1. Test pikselini çevreleyen eş merkezli pencereler	18
Şekil 3.2. Üretilen yapay veri setlerinde (a) birinci sahne, (b) ikinci sahne	23
Şekil 3.3. Birinci yapay veri seti üzerinde anomali tespit sonuçları	26
Şekil 3.4. İkinci yapay veri seti üzerinde anomali tespit sonuçları	27
Şekil 3.5. İkinci yapay veri seti üzerinde DWRX - LRX anomali bulucuların karşılaştırılması. LRX-7-9 etiketi, LRX anomali bulucu için iç pencere boyutu 7x7, dış pencere boyutu 9x9 olarak kullanıldığını göstermektedir.	28
Şekil 3.6. İkinci yapay veri seti üzerinde KRX - SSRX anomali bulucuların karşılaştırılması. KRX-7-21 etiketi, KRX anomali bulucu için iç pencere boyutu 7x7, dış pencere boyutu 21x21 olarak kullanıldığını göstermektedir.	29

Şekil 3.7. GRX ve RXD-UTD anomali tespit sonuçlarının karşılaştırılması (a) 1. yapay veri seti, (b) 2. yapay veri seti, (c) 1. yapay veri seti üzerinde GRX çıktısı, (d) 2. yapay veri seti üzerinde GRX çıktısı, (e) 1. yapay veri seti üzerinde RXD-UTD çıktısı, (f) 2. yapay veri seti üzerinde RXD-UTD çıktısı	30
Şekil 3.8. Üç uç eleman ve olası katışım noktaları [38]	32
Şekil 3.9. Bütün verileri kapsayan iki farklı simpleks [38]	34
Şekil 3.10. Seçilen beş farklı materyale ait spektral imzalar [38]	39
Şekil 3.11. Dirichlet dağılımı kullanılarak üretilen veriler [38]	39
Şekil 3.12. Örnek SPICE algoritma çıktısı [38]	42
Şekil 3.13. Örnek KİDDO algoritma çıktısı [38]	42
Şekil 4.1. Sahne 1 hiperspektral verisinin (a) iki boyutlu görüntüsü, (b) temel doğrusu	45
Şekil 4.2. Sahne 1 hiperspektral verisi üzerinde anomali tespit sonuçları (a) sahne 1'in iki boyutlu görüntüsü, (b) GRX çıktısı, (c) RXD-UTD çıktısı ..	47
Şekil 4.3. Sahne 1 hiperspektral verisi üzerinde anomali tespit sonuçları (a) LRX çıktısı, (b) DWRX çıktısı, (c) SSRX çıktısı	48
Şekil 4.4. Sahne 1 hiperspektral verisi üzerinde anomali bulucuların hedefleri bulma başarımları	49
Şekil 4.5. Sahne 2 hiperspektral verisinin iki boyutlu görüntüsü	50
Şekil 4.6. Sahne 2 hiperspektral verisi üzerinde (a) GRX çıktısı, (b) GRX çıktısının eşiklenmiş hali	51
Şekil 4.7. Sahne 2 hiperspektral verisi üzerinde (a) RXD-UTD çıktısı, (b) RXD-UTD çıktısının eşiklenmiş hali	52
Şekil 4.8. Sahne 2 hiperspektral verisi üzerinde (a) LRX çıktısı, (b) LRX çıktısının eşiklenmiş hali	54
Şekil 4.9. Sahne 2 hiperspektral verisi üzerinde (a) DWRX çıktısı, (b) DWRX çıktısının eşiklenmiş hali	55
Şekil 4.10. Sahne 2 hiperspektral verisi üzerinde (a) SSRX çıktısı, (b) SSRX çıktısının eşiklenmiş hali	56

Şekil 4.11. Sahne 2 hiperspektral verisi üzerinde anomali bulucuların hedefleri bulma başarımları	57
Şekil 4.12. Sahne 3 hiperspektral verisinin (a) iki boyutlu görüntüsü, (b) renkli görüntüsü	59
Şekil 4.13. Sahne 3 hiperspektral verisinin (a) radyans görüntüsü, (b) Reststrahlen oran tespit algoritma çıktısı	60
Şekil 4.14. Sahne 3 radyan verisinin salıcılık normalizasyonu sonrası elde edilen (a) salıcılık görüntüsü, (b) sıcaklık haritası	61
Şekil 4.15. İki öznelik uzayında sahne 3 hiperspektral verisi üzerinde hedef noktaların gösterimi	62
Şekil 4.16. İki öznelik uzayında sahne 3 hiperspektral verisi üzerinde yanlış alarmların gösterimi	62
Şekil 4.17. Sahne 3 hiperspektral verisinin (a) temel doğrusu (b) hedef noktaların sınıflandırılması	63
Şekil 4.18. KİDDO algoritma çıktılarından seçilen bolluk haritası	64
Şekil 4.19. Sahne 3 hiperspektral verisi için bolluk haritası kullanılarak yanlış alarmların elenmesi	64

SİMGELER VE KISALTMALAR

Simgeler

d	Spektral bant sayısı
e_j	j . spektral bandın uç eleman değeri
E	Uç eleman matrisi
k	Çekirdek fonksiyonu
M	Uç eleman sayısı
N	Piksel sayısı
p_{ik}	k . uç elemanın i . pikselde bulunma oranı
P	Katılım oran matrisi
S	Reststrahlen oran özneliği
\hat{K}_b	Gram matrisi
V	Düzenleştirme terimi
μ	Ödünleşim değişkeni
$\hat{\mu}_b$	Arka plan ortalama vektörü
$\hat{\mu}_{b\phi}$	Çekirdek uzayında arka plan ortalaması
$\hat{\Sigma}_{b\phi}$	Çekirdek uzayında arka plan ortak değişinti matrisi
$\hat{\Sigma}_b$	Arka plan ortak değişinti matrisi

Kisaltmalar

DWRX	Dual Window Reed-Xiaoli	Çift Pencereli Reed-Xiaoli
FN	False Negative	Yanlış Negatif
FP	False Positive	Yanlış Pozitif
GRX	Global Reed-Xiaoli	Global Reed-Xiaoli
HP	Airborne Platform	Hava Platformu
ICE	Iterated Constrained Endmember	Yinelemeli Kısıtlı Uç Eleman
KRX	Kernel Reed-Xiaoli	Çekirdek Reed-Xiaoli

LRX	Local Reed-Xiaoli	Yerel Reed-Xiaoli
LWIR	Long-Wave Infrared	Uzun-Dalga Kızılötesi
MNF	Minimum Noise Fraction	Minimum Gürültü Kesri
MWIR	Mid-Wave Infrared	Orta-Dalga Kızılötesi
RGB	Red Green Blue	Kırmızı Yeşil Mavi
ROC	Receiver Operating Characteristic	Alıcı İşlem Karakteristikleri
RSS	Residual Sum of Squares	Artık Kareler Toplamı
RX	Reed-Xiaoli	Reed-Xiaoli
SPT	Sparsity Promoting Term	Seyreklik Teşvik Edici Terim
SSRX	Subspace Reed-Xiaoli	Alt Uzay Reed-Xiaoli
SWIR	Short-Wave Infrared	Kısa-Dalga Kızılötesi
SYP	Ground-Based Platform	Sabit Yer Platformu
TBA	Principal Component Analysis	Temel Bileşen Analiz
TIR	Thermal Infrared	Termal Kızılötesi
TN	True Negative	Doğru Negatif
TP	True Positive	Doğru Pozitif
UA	Remote Sensing	Uzaktan Algılama
UP	Space Platform	Uydu Platformu
UTD	Uniform Target Detector	Uniform Hedef Bulucu
VNIR	Visible & Near Infrared	Görünür & Yakın Kızılötesi

1. GİRİŞ


İnsanođlu var olduđu günden itibaren içinde bulunduđu dünyayı keşfetme merakıyla yaşamış, edindiđi bilgileri gözlemleri ile birleřtirerek çevresini anlamaya ve yorumlamaya çalışmıřtır. Uzaktan algılama (UA) adı verilen, nesnelere direkt temas etmeden yapılan ölçümlerle nesnelere hakkında bilgi toplamaya yarayan, toplanan bilgilerle nesnelere yorumlanmasına ve analizine olanak sađlayan teknoloji sayesinde, insanođlu bu merakını giderme imkanı bulmuřtur. Ulařılması zor alanların görüntülenmesine ve nesnelere gözle görülemeyen özelliklerinin tespit edilmesine olanak sađlayan uzaktan algılama teknolojisi; yeryüzü deformasyonunun izlenmesi, orman türlerinin belirlenmesi ve haritalanması, tarım ürünlerinin gelişiminin izlenmesi, bitki türlerinin sınıflandırılması, toprak ve kayaç türlerinin ayırt edilmesi, deniz kirliliğinin incelenmesi, arama ve kurtarma faaliyetleri gibi onlarca farklı uygulamada kullanılmaktadır.

Uzaktan algılanan görüntüler, çözünürlüklerine göre farklı amaçlarda kullanılmaktadır. Genel olarak bir UA görüntüsü uzamsal, spektral, radyometrik ve zamansal olmak üzere dört temel çözünürlüğe sahiptir [1, 2]:

- **Uzamsal çözünürlük**, algılayıcı tarafından algılanan bir pikselin temsil ettiđi geometrik alan olarak tanımlanır.
- **Spektral çözünürlük**, algılayıcının elektromanyetik spektrumda kaydedebildiđi belirli dalga boyu aralıđıdır.
- **Radyometrik çözünürlük**, elektromanyetik enerji miktarında sahip olunan hassasiyet olarak tanımlanır.
- **Zamansal çözünürlük**, algılayıcının bir alandan hangi sıklıkla veri topladıđının ölçüsüdür.

Uzaktan algılamada, yüzey materyallerinden yansıyan veya yayılan enerjinin ölçümü esas alınır. Son yıllarda uzaktan algılama alanında yaygın olarak kullanılan hiperspektral görüntüleme sistemleri, dar ve bitişik yüzlerce dalga boyu bandında ölçüm almaktadır. Hiperspektral görüntüler materyallerden yansıyan veya yayılan enerjinin dalga

boylarına göre deęişimini ölçen cihazlarla elde edilir [3, 4]. Elde edilen görüntüler, hiperküp adı verilen uzunluk ve genişlięi uzamsal bilgiyi, derinlięi ise spektral bilgiyi temsil eden üç boyutlu bir veri küpü olarak toplanmaktadır [5]. Hiperspektral veri küpü her bir görüntü elemanı için dalga boyuna baęlı olacak şekilde sürekli bir spektrum bilgisi sunmaktadır. Materyallerin her bir dalga boyunda sahip olduęu spektral bilgi, spektral imza adı verilen materyallerin tanımlanması ve sınıflandırılmasını saęlayan örüntüler oluşturur. Şekil 1.1’de örnek bir hiperspektral veri küpü ve bir piksele ait spektral imza gösterilmektedir. Materyallere özgü spektral imzalar, hiperspektral görüntüleme yardımıyla yapılan uzaktan algılama uygulamalarında tanıma, tespit ve sınıflandırma işlemlerine olanak saęlamaktadır [6].



Şekil 1.1. Hiperspektral veri küpü ve piksel spektrası [7]

Hiperspektral görüntü işleme, dünya genelinde olduęu gibi ülkemizde de araştırmacı sayısının her geçen gün arttıęı, uygulama alanı oldukça yaygın olan bir araştırma dalıdır. Hiperspektral görüntü algılayıcıları genel olarak dört dalga boyu aralığında görüntü toplamak için tasarlanmıştır. Tasarlandığı dalga boyu aralıkları aşıęıdaki şekilde sıralanabilir:

- **Görünür ve Yakın Kızılötesi Bant (Visible & Near Infrared - VNIR)**

0.4 - 1 μm aralığını kapsayan bant aralığında VNIR görüntüler çevre, gıda, şehir planlama ve tarım gibi birçok alanda kullanılmaktadır [8].

- **Kısa Dalga Kızılötesi Bant (Short-Wave Infrared - SWIR)**

1 - 2.5 μm bant aralığını kapsayan SWIR görüntüler geri dönüşüm, arkeoloji, ilaç sanayi, nemlilik kontrolü, maden ve yeryüzü kaynaklarının aranması, tarım ve ziraat gibi birçok alanda kullanılmaktadır [9].

- **Orta Dalga Kızılötesi Bant (Mid-Wave Infrared - MWIR)**

3 - 5 μm bant aralığını kapsayan MWIR görüntüler jeolojide petrol, gaz, jeotermal araştırmaları ve savunma sanayisinde hedef tespiti gibi birçok alanda kullanılmaktadır [10].

- **Uzun Dalga Kızılötesi Bant (Long-Wave Infrared - LWIR)**

8 - 12 μm bant aralığını kapsayan LWIR görüntüler deniz yüzeyi sıcaklık dağılımı, kamufraj ve gaz tespiti, gömülü mayın tespiti, volkanik araştırma çalışmaları ve mineral haritalama gibi birçok alanda kullanılmaktadır [11].

Hiperspektral görüntüleyicilere ulaşan enerji değerleri çoğu zaman, fiziksel anlamı olmayan kalibre edilmemiş ayrık numaralarla (digital number) ifade edilir. Elde edilen veriler üzerinde yapılacak ilk işlem, kalibre edilmemiş verinin görüntüleyicilere ait kazanç (gain) ve sapma (bias) değerlerini kullanarak radyansa dönüştürülmesidir [12]. Radyans, belirli bir doğrultuda belirli bir açıyla ölçümü yapılan, birim alandan geçen veya yansıyan ışın miktarıdır [13]. Özellikle spektral imza tabanlı uygulamalar için radyans değerleri, atmosferik etkilerin düzeltilmesi sonucu yansıma (reflectance) değerlerine dönüştürülür. Yansıma, bir cisimden yansıyan enerjinin o cisime gelen toplam enerjiye oranıdır [12].

Hiperspektral görüntüleyiciler içerisinde VNIR ve SWIR bantta çalışan algılayıcılar için güneş ışığı baskın radyasyon kaynağıdır [14]. VNIR ve SWIR bantta çalışan algılayıcılar gün ışığında görüntü sağlarlar. Dolayısıyla bu bant aralıklarında elde edilen görüntüler için yansıma değerleri kullanılır. LWIR bölgede çalışan algılayıcılar için termal yayılma (thermal emission) baskınken, güneş radyasyonu (solar radiation) ihmal edilebilir seviyededir. Termal hiperspektral görüntüleyici olarak da bilinen LWIR hiperspektral görün-

tüleyiciler sayesinde hem gece hem de gündüz görüntü alınabilmektedir. Bu özelliği ile termal hiperspektral görüntüleyiciler uzaktan algılama alanında birçok yeniliğe olanak sağlamaktadır. Cisimlerin farklı ısınma özelliklerinden yararlanılarak elde edilen LWIR görüntüler üzerinden, cisimlerin sıcaklıklarını ve salıcılık (emissivity) spektralarını çıkarmak mümkündür [15]. LWIR bir veriküpü içerisinde bir piksele ait salıcılık değeri, piksel sıcaklığında piksele ait radyans değerinin kara cismin radyansına oranıdır ve aşağıdaki şekilde hesaplanabilir [16, 17, 18]:

$$\epsilon_i = \frac{L_i}{L_{BB}} \quad (1.1)$$

burada L_i , i . pikselin radyans değeri, L_{BB} ise kara cismin radyansdır ve Eşitlik 1.2'de verilen Planck kuralı ile hesaplanır:

$$L_{BB} = \frac{C_1}{\lambda^5 \pi \left[\exp\left(\frac{C_2}{\lambda T}\right) - 1 \right]} \quad (1.2)$$

burada T sıcaklık, λ dalga boyu, C_1 ve C_2 radyasyon sabitleridir. Her bir piksel noktasında salıcılık değeri aşağıda verilen sırayla hesaplanır:

- İlk olarak, Eşitlik 1.1'de yer alan ifadede her dalga boyu için salıcılık değeri $\epsilon = 0.95$ kabul edilir ve bilinen piksel radyans değeri ile L_{BB} değeri elde edilir. Hesaplanan L_{BB} değeri üzerinden Eşitlik 1.2'de verilen kurala göre her bir dalga boyu için T sıcaklık değerleri hesaplanır.
- Bütün dalga boylarında hesap edilen sıcaklık değerleri içerisinde en yüksek sıcaklık değeri o piksele ait sıcaklık değeri olarak belirlenir.
- Bulunan en yüksek sıcaklık değerine göre Eşitlik 1.2 kullanılarak tekrar L_{BB} hesaplanır. Hesaplanan değer Eşitlik 1.1'e yerleştirilerek piksele ait ϵ salıcılık değeri belirlenir.

Hiperspektral görüntülerle UA teknikleri, kullanılan platforma göre üç şekilde incelenmektedir [13, 19]:

- **Sabit Yer Platformları (SYP)**, ayrıntı gerektiren uygulamalarda kullanılır. Alınan görüntülerde uzamsal çözünürlük oldukça yüksektir ancak görüntülenen alan dar-dır.
- **Hava Platformlarında (HP)**, hava araçlarına monte edilen algılayıcılar kullanılmaktadır. Uzamsal çözünürlük hava araçlarının uçurulduğu yüksekliğe göre de-ğişmektedir. Genellikle yerel ölçekli araştırma uygulamalarında kullanılmaktadır.
- **Uydu Platformlarında (UP)**, uzay platformlarına monte edilen algılayıcılar kul-lanılmaktadır. Görüntülenen alan genişlemesine rağmen görüntülerdeki uzamsal çözünürlük azalmaktadır.

Genellikle UP ile elde edilen hiperspektral görüntülerde uzamsal çözünürlüğün düşük olması, görüntülerde katışım pikseli (mixed pixel) oluşumuna sebebiyet verir [6, 20]. Katışım pikseli birden fazla materyalin tek bir piksel içerisinde bulunduğu durumu ifade eder. Tek bir materyalin enerji değerinden oluşan piksel saf piksel (pure pixel) olarak adlandırılmaktadır [21]. Katışım pikselleri uzamsal çözünürlüğün düşük olduğu durumlarda oluştuğundan, görüntüdeki piksel değerleri birden fazla materyalin katışımı halinde bulunabilir. Bu tür durumlarda görüntü içerisindeki piksellerin analizi için uç eleman çıkarımı, spektral katışım analizi gibi yaklaşımlar kullanılmaktadır.

1.1 Tezin Amacı

Bu tezde, uzun dalga kızılötesi hiperspektral görüntülerde toprak yüzeyinde bulunan hedeflerin tespit edilmesi amaçlanmıştır. Hedef tespiti için veri içerisinde bulunan ve olası hedef noktalarını işaret eden anomalilerin bulunmasını sağlayan anomali tespit yöntemleri kullanılmıştır. Anomali tespiti sonrası elenemeyen, toprak yüzeyindeki bitki örtüsü gibi materyallerden kaynaklanan yanlış alarmların azaltılması için uç eleman analiz yöntemleri kullanılmıştır.

Tez kapsamında, anomali tespitine yönelik arka plan modelleme tabanlı; Global RX, Yerel RX, RXD-UTD, Çift Pencereli RX, Alt Uzay RX ve Çekirdek RX anomali bulucuları ile öznitelik tabanlı Reststrahlen oran tespit algoritması yapay ve gerçek hiperspektral veriler üzerinde incelenmiş, anomali bulan yöntemlerin performansını etkileyen değişkenler

detaylı bir şekilde araştırılmıştır. Benzer şekilde hiperspektral verilerde uç eleman analizi sağlayan SPICE ve KİDDO algoritmaları yapay veriler üzerinde incelenmiş, anomali tespiti sonrası oluşan yanlış alarmları azaltmak için çalışmalar yapılmıştır. Uç eleman analiz yöntemlerini uygulamak için ASTER spektral kütüphanesinde [22] bulunan materyallere ait spektral imzalar kullanılarak yapay bir veri seti oluşturulmuştur. Anomali tespit yöntemleri ise hem yapay hem de gerçek LWIR hiperspektral veri setleri üzerinde uygulanmıştır.

1.2 Tezin Akışı


Tezin geri kalan kısmı şu şekilde özetlenebilir:

İkinci bölümde, hiperspektral görüntülerin analizinden önce veriler üzerinde uygulanan bazı ön işleme yöntemlerine değinilmiş, tez kapsamında verilerdeki gürültüyü gidermek için kullanılan doğrusal olmayan yönbağımlı yayılma yöntemi anlatılmıştır.

Üçüncü bölümde, hiperspektral görüntülerde hedef tespiti sağlayan anomali tespit yöntemleri ve uç eleman analiz algoritmaları anlatılmıştır. İlk olarak, veride arka planı modelleyerek verideki anomalileri bulmaya çalışan altı anomali tespit yöntemi; Global RX, Yerel RX, RXD-UTD, Çift Pencere RX, Alt Uzay RX ve Çekirdek RX açıklanmıştır. Üretilen yapay veri setleri üzerinde, yöntemlerin performansları incelenmiş, yöntemlerin performanslarını etkileyen değişkenler detaylı bir şekilde araştırılmıştır. Sonrasında, üç uç eleman analiz yöntemi ICE, SPICE, KİDDO anlatılmış; benzer şekilde, yapay veri seti üzerinde uç eleman analiz algoritmaları koşturulmuştur. Ayrıca bu bölümde LWIR bantta çalışan, toprak yüzeyindeki farklılıkları bulmayı amaçlayan öznelik tabanlı Reststrahlen oran tespit algoritması açıklanmıştır.

Dördüncü bölümde, üç farklı sahnenin bir LWIR hiperspektral görüntüleyici ile görüntülenmesi sonucu elde edilen gerçek hiperspektral veri setleri tanıtılmıştır. Üçüncü bölümde anlatılan hedef tespit yöntemleri gerçek veri setlerine uygulanmış, elde edilen sonuçlar karşılaştırmalı olarak yorumlanmıştır. Bu bölümde yapılan işlemler genel hatlarıyla Şekil 1.2'de yer alan akış diyagramı ile gösterilmiştir.

Son bölümde, çalışma boyunca elde edilen sonuçlarla ilgili çıkarımlara yer verilmiştir.



Şekil 1.2. Genel akış diyagramı

2. HİPERSPEKTRAL VERİLERDE ÖN İŞLEME

Hiperspektral görüntülerin analizinden önce verilere uygulanan düzeltme ve düzenleme işlemleri ön işleme (preprocessing) olarak adlandırılır. Atmosferik ve geometrik düzeltme (atmospheric & geometric correction), bant ayıklama, boyut azaltma, gürültü modelleme ve gürültü azaltma gibi ön işleme yöntemleri veri üzerinde yapılacak analize göre şekillenmektedir.

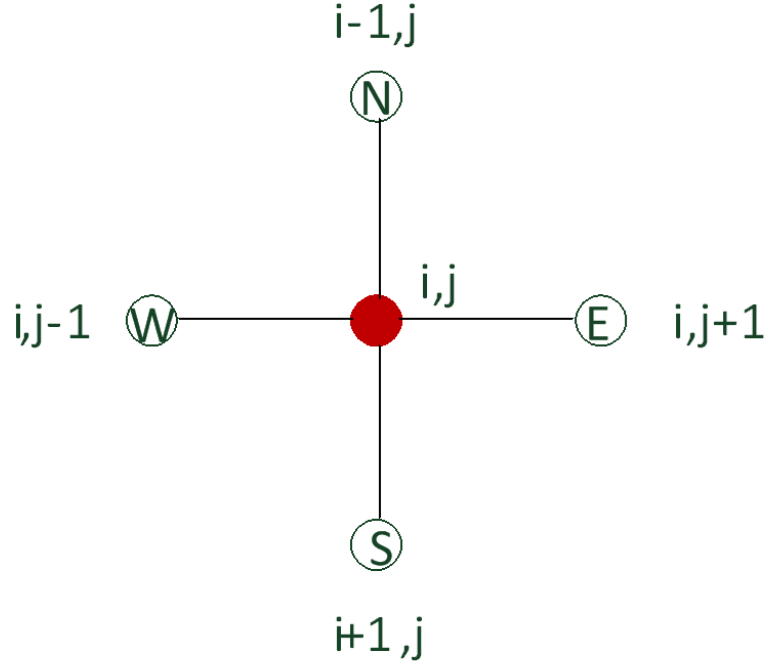
Tez kapsamında kullanılan uzun dalga kızılötesi görüntülerde gürültü varlığı görülmüştür. Literatürde, hiperspektral görüntülerde gürültü azaltma yöntemi olarak Temel Bileşen Analiz - TBA ve Minimum Gürültü Kesri - MNF yaygın olarak kullanılmaktadır [15]. TBA, hiperspektral verilerde değişimin baskın olduğu bantları bulan, geriye kalan bantların gürültü olduğu varsayımda bulunan boyut azaltma yöntemidir [23].

TBA yöntemi, hiperspektral görüntülerdeki gürültüyü azaltırken verinin bütününde baskın olan değişimi incelemektedir. Ancak bu durum, veri içerisinde arka plan tarafından bastırılmış yerel bölgelerde konumlanan hedef noktaları için sorun teşkil etmektedir. Bu durum göz önünde bulundurularak, tez kapsamında yerel bazda kenar bilgisini inceleyerek piksel spektralarında iyileştirme sağlayan *doğrusal olmayan yönbağımlı yayılma yöntemi* gürültü azaltma yöntemi olarak kullanılmıştır. Yönbağımlı yayılma yöntemi, temelde gri-seviye görüntüler için geliştirilmiş bir gürültü azaltma yöntemidir. Yöntem geliştirilerek çok bantlı (multi-spectral) görüntülere de uygulanmış ve başarılı sonuçlar elde edilmiştir [24]. Yönbağımlı yayılma yönteminin çok bantlı görüntülerde uygulanmasının en büyük getirisi, verilerde kenar bilgisi korunacak şekilde hem uzamsal hem de spektral komşulukların incelenmesidir.

2.1 Doğrusal olmayan Yönbağımlı Filtreleme

Yönbağımlı yayılma yöntemi olarak da adlandırılan yöntem [25], doğrusal olmayan yayılma modelini kullanmaktadır. Yayılma denklemlerini yinelemeli olarak çözmek için geliştirilen yöntem, görüntüde nispeten homojen olan bölgeleri düzgünleştirirken kenarları bozmamayı amaçlamaktadır. Şekil 2.1'de gösterildiği gibi doğrusal olmayan yönbağımlı filtreleme yöntemi, görüntüde her bir pikselin komşuluğundaki dört piksel ile uzamsal ilişkisini incelemektedir. Eşitlik 2.1'de, yöntemin örnek bir görüntüye uygulanması için

gereken matematiksel ifade verilmiştir:



Şekil 2.1. Dört komşuluklu piksel yapısının iki boyutta gösterimi

$$\mathbf{X}_{i,j}^{t+1} = \mathbf{X}_{i,j}^t + \lambda [c_N \cdot \nabla_N \mathbf{X} + c_S \cdot \nabla_S \mathbf{X} + c_E \cdot \nabla_E \mathbf{X} + c_W \cdot \nabla_W \mathbf{X}]_{i,j}^t \quad (2.1)$$

Eşitlik 2.1 yineleme sayısına bağlı bir yayılma denklemdir. Eşitlikte $\mathbf{X}(i, j)$, yöntemin uygulandığı örnek bir görüntüde i, j noktasındaki parlaklık değeri, t yineleme sayısı ve λ yumuşatma sabitidir. N, S, E, W bir pikselin kuzey (north), güney (south), doğu (east) ve batı (west) komşuluklarını gösteren alt indekslerdir. ∇ sembolü ise test pikselinin komşu pikseller ile belirtilen yöndeki farkını göstermektedir:

$$\begin{aligned} \nabla_N \mathbf{X}_{i,j} &\equiv \mathbf{X}_{i-1,j} - \mathbf{X}_{i,j} \\ \nabla_S \mathbf{X}_{i,j} &\equiv \mathbf{X}_{i+1,j} - \mathbf{X}_{i,j} \\ \nabla_E \mathbf{X}_{i,j} &\equiv \mathbf{X}_{i,j+1} - \mathbf{X}_{i,j} \\ \nabla_W \mathbf{X}_{i,j} &\equiv \mathbf{X}_{i,j-1} - \mathbf{X}_{i,j} \end{aligned} \quad (2.2)$$

Eşitlik 2.1'de verilen piksel komşuluklarını gösteren alt indisli $c = c(i, j, t) = g(\|\nabla\mathbf{X}(i, j, t)\|)$ yayılma fonksiyonudur ve iki farklı seçimi mevcuttur:

$$g(\nabla\mathbf{X}) = e^{-(\|\nabla\mathbf{X}\|/K)^2}$$


$$g(\nabla\mathbf{X}) = \frac{1}{1 + \left(\frac{\|\nabla\mathbf{X}\|}{K}\right)^2}. \quad (2.3)$$

Burada K , yayılma işlemi sırasında görüntü içerisindeki kenarların korunup korunmayacağını belirleyen bir sabittir. Eşitlik 2.3'teki ilk yayılma fonksiyonu, yüksek kontrastlı kenarları korurken düşük kontrastlı kenarların yumuşamasını; ikinci yayılma fonksiyonu ise görüntü içerisinde geniş bölgeleri korurken küçük bölgelerde yumuşatma işleminin yapılmasını sağlamaktadır.

Yönbağımlı yayılım yöntemi iki boyutlu görüntülerde sadece piksellerin komşu pikseller ile uzamsal ilişkilerini incelemektedir. Çok bantlı görüntüler için genelleştirildiğinde uzamsal ilişkiye ek olarak piksellerin spektral ilişkileri de dikkate alınır. İki boyutta bir test pikseli için dört komşulu piksel yapısı, çoklu görüntüler için 26 komşuluklu üç boyutlu bir ağ yapısı halini alır. Şekil 2.2'de bu durum görselleştirilmiştir. Çok bantlı görüntülerde ikinci spektral banttıan başlanarak her bir pikselin uzamsal ve spektral 26 komşu piksel ile olan ilişkisi incelenir. Eşitlik 2.1'de dört komşuluk için geçerli olan ifade 26 komşuluk için geliştirilerek, bir test pikseli üzerinde 3 boyutlu evrişim (convolution) maskesi yardımıyla komşu pikseller yönünde yayılma hesaplanır. Yayılım yönünün piksel uzaklıklarından bağımsız olması için her bir yönde yayılma fonksiyonu komşu piksel uzaklığına bölünür. Bu işlem yinelemeli olarak d spektral bant olmak üzere $d - 1$. banda kadar devam eder. Yöntemin hiperspektral görüntülere uygulanması sonucunda veri içerisinde değişimin fazla olduğu noktalarda yumuşatma işleminin az, diğer homojen noktalarda yumuşatma işleminin fazla olduğu filtrelenmiş hiperspektral görüntü elde edilir.

2.2 Deneysel Sonuçlar

Yönbağımlı yayılma yöntemi, Şekil 2.3-(a)'da iki boyutlu görüntüsü verilen hiperspektral görüntü üzerinde yineleme sayısı sırasıyla 1, 3 ve 5 olacak şekilde uygulanmıştır. Yayılma fonksiyonu olarak Eşitlik 2.3'te verilen ikinci fonksiyon kullanılmıştır. Yayılma



Şekil 2.2. Bir test pikseli için 26 komşulu üç boyutlu ağ yapısı

işlemi sırasında görüntü içerisindeki kenarların korunup korunmayacağını belirleyen K sabiti 70 ve λ birleştirme sabiti $3/44$ alınmıştır.

Şekil 2.4'te mavi nokta ile gösterilen bir test pikseli üzerinde piksel spektrasının yineleme sayısına bağlı değişimi Şekil 2.5'te incelenmiştir. Şekil 2.5'te yineleme sayısı 1 iken elde edilen piksel spektrasının yönbağımlı yayılım yönteminin uygulanmadan önceki piksel spektrasına göre düzgünleştiği görülmektedir. Ancak yineleme sayısındaki artış piksel spektrasında bir öteleme meydana getirmiş, test pikselinin spektral örüntüsünden uzaklaşmasına sebep olmuştur. Bu durum göz önünde bulundurularak tez kapsamında hiperspektal görüntüler üzerinde uygulanan yönbağımlı yayılım yöntemi için yineleme sayısı 1 alınmıştır. Hiperspektal veri küpü üzerinde yineleme sayısına bağlı olarak elde edilen yumuşatılmış yönbağımlı yayılım çıktıları Şekil 2.3'te gösterilmektedir. Yineleme sayısındaki artışla beraber piksel spektralarının örüntülerini kaybetmesi görüntüler üzerinde ayırt edilebilirliği azaltmıştır. Şekil 2.3'te gösterilen yönbağımlı yayılım yöntem çıktılarını iki boyutta görselleştirmek için her bir pikselin bütün dalga boylarında ortalaması alınmıştır.



(a)



(b)




(c)

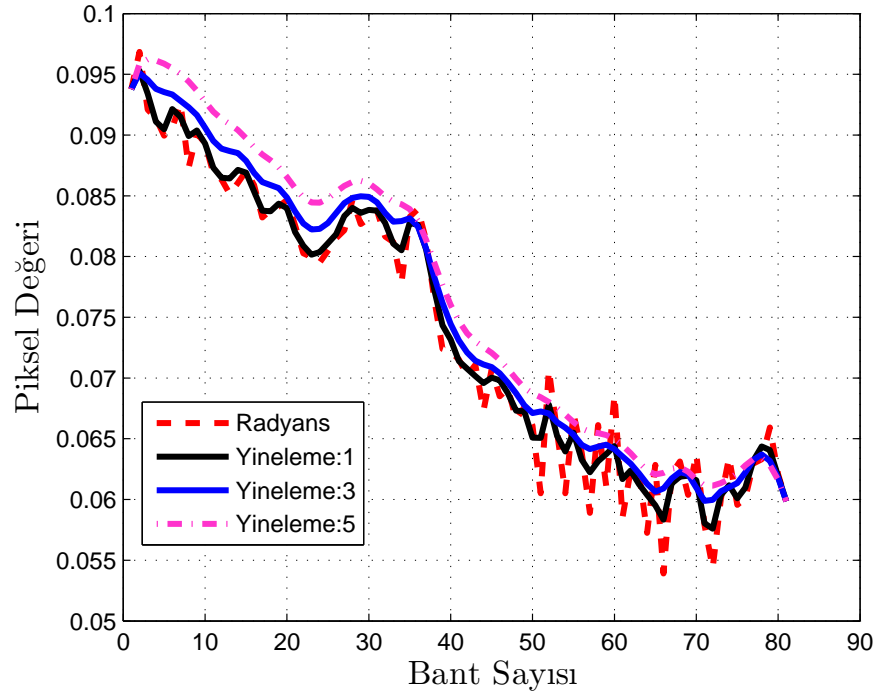


(d)

Şekil 2.3. Hiperspektral verinin (a) radyans görüntüsü, (b) yineleme sayısı 1 için yöntem çıktısı, (c) yineleme sayısı 3 için yöntem çıktısı, (d) yineleme sayısı 5 için yöntem çıktısı



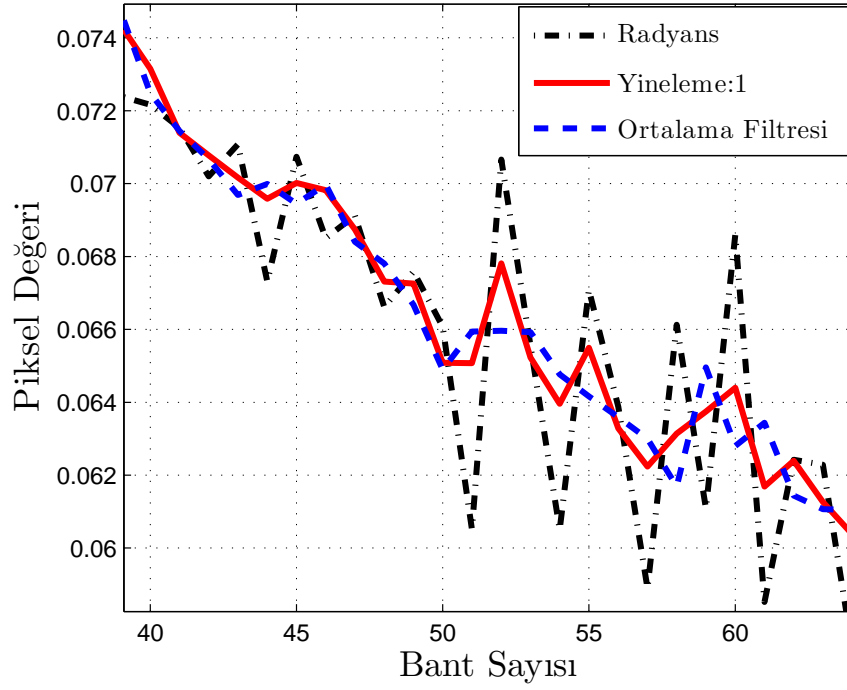
Şekil 2.4. Yineleme sayısına bağlı spektral değişimleri incelemek için hyperspektral veri küpü üzerinden alınan bir test pikseli (mavi nokta)



Şekil 2.5. Hyperspektral veri üzerinden alınan bir test pikseli için farklı yineleme sayısına bağlı spektral değişimler

Yineleme sayısı 1 için yönbağımlı yayılma yönteminin piksel spektrasında meydana getirdiği deęişim, aynı görüntü üzerinde ortalama filtresi (mean filter) uygulanarak Şekil 2.6'da karşılaştırılmıştır. Ortalama filtre, hiperspektral veri küpü üzerinde ikinci banttan başlanarak $d - 1$. banda kadar olan her bir piksel noktasının 3×3 'lük komşuluğunda yer alan piksel deęerlerinin ortalaması alınarak oluşturulmuştur. Örnek test pikseli için Şekil 2.4'te mavi nokta ile gösterilen test pikseli kullanılmıştır.

Spektral deęişimler incelendiğinde, test pikseli üzerinde ortalama filtre oldukça fazla yumuşatma işlemi uygulamıştır. Yönbağımlı yayılma yöntemi ise daha az yumuşatma işlemiyle beraber kenar bilgisini koruyabilmiştir.



Şekil 2.6. Hiperspektral veri üzerinden alınan bir test pikseli için ortalama filtre çıktısı ile yineleme sayısı 1 iken yönbağımlı yayılım yöntem çıktısından elde edilen spektral deęişimler

3. HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ

Hiperspektral görüntüleme teknolojisinin hedef tespiti ve teşhisindeki başarısı bu teknolojinin arama ve kurtarma faaliyetleri, sınır denetimi ve mayın tespiti gibi birçok askeri alanda uygulanmasına olanak sağlamıştır. Hedef tespiti temelde, görüntüdeki her bir pikseli hedef veya hedef değil olarak etiketleyen bir ikili sınıflandırıcıdır. Spektral imza tabanlı hedef bulucular hedef tespitinde bitki örtüsü, toprak ve kaya parçaları, doğal ve yapay mineral gibi birçok materyalin spektral bilgisini içeren kütüphanelerden faydalanırlar. Hedef tespitinde hedefe ait spektral imzanın bilindiği varsayılır ve her bir pikselin spektral imzası referans imza ile eşleştirilir. Ancak referans spektral imzalar spektral ışınımölçer ile ölçülürken görüntü pikselleri alıcılardan spektral radyans olarak ölçülür. Bu yüzden atmosferik düzeltme ile radyans değerlerinin yansıma değerlerine dönüştürülmesi gerekir.

Hedef tespitinde bir diğer özel durum da anomali tespitidir. Anomali, verideki bir nokta- nın veya alanın çevresindeki diğer noktalara göre farklılık göstermesi olarak tanımlanır. Anomali tespiti ise önsel hedef bilgisi olmaksızın verideki hedefleri bulmayı amaçlayan bir hedef tespit yaklaşımıdır. Anomali bulucular görüntünün genelinden farklı olarak öne çıkan kısımları buldukları için atmosferik düzeltme yapılmadan da kullanılabilirler.

3.1 Modelleme Tabanlı Anomali Tespit Algoritmaları

Anomali tespitinde amaç bir görüntü içerisinde çevresine göre farklılık gösteren noktaları tespit etmektir. Yaygın olarak kullanılan ve birçok anomali tespit algoritmasının türetilmesine olanak sağlayan Reed-Xiaoli (RX) anomali tespit algoritması [26], veride arka planı çok değişkenli bir Gauss dağılımı ile modeller ve test edilen bir pikselin bu modelden ne kadar saptığını hesap eder.

Anomali tespitinde altı çizilmesi gereken iki önemli problem vardır: arka planın nasıl belirleneceği ve anomali değerlerinin nasıl ölçüleceğidir. RX anomali bulucu arka planın homojen dağıldığı varsayımında bulunur ve arka planı çok değişkenli bir Gauss dağılımı ile modeller. Ancak bu hipotez bazı durumlarda yeterli olmayabilir. Bu yetersizliği giderebilmek için birçok RX tabanlı anomali tespit algoritması geliştirilmiştir [27, 28].

Tezin bu bölümünde, RX anomali bulucu ve RX anomali bulucudan türetilen anomali tespit algoritmaları bir arada sunulmuş, sentetik veri setleri üzerinde performansları karşılaştırılmıştır.

3.1.1 Global Reed-Xiaoli Algoritması

Anomali bulucular geliştirilmiş olabilirlik oran testinden (generalized likelihood ratio test) farklı arka plan ve gürültü modelleri kullanılarak elde edilmiştir [14]. Mahalanobis mesafe bulucu olarak da adlandırılan Global Reed-Xiaoli (GRX) algoritması arka planı tek bir Gauss dağılımı ile modellemektedir. GRX algoritmasının hedef tespiti için kullandığı model şu şekilde gösterilebilir:

$$\begin{aligned} H_0 : \mathbf{x} = \mathbf{b} & \text{ Hedef yok} \\ H_1 : \mathbf{x} = \mathbf{s} & \text{ Hedef var} \end{aligned} \quad (3.1)$$

Burada \mathbf{b} , ortalaması μ ve ortak değişinti matrisi Σ olan arka plan modeli, \mathbf{s} bilinmeyen anomali imzasıdır. Genelleştirilmiş olabilirlik oran testi, olasılık yoğunluk fonksiyonlarının bilinmeyen parametrelerinin yerine en büyük olabilirlik kestirimlerini kullanır.

$$\begin{aligned} p(\mathbf{x}|H_0) &= \frac{1}{(2\pi)^{K/2}} \frac{1}{|\hat{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \hat{\mu})^T \hat{\Sigma}^{-1}(\mathbf{x} - \hat{\mu}) \right\} \\ p(\mathbf{x}|H_1) &= \text{sabit} \end{aligned} \quad (3.2)$$

Eşitlik 3.2'de yer alan ifadeler geliştirilmiş olabilirlik oran testinin logaritmik formuna [27] yerleştirildiğinde Eşitlik 3.3'te gösterilen Mahalanobis mesafesi olarak da bilinen denklem halini alır.

$$D_{GRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu})^T \hat{\Sigma}^{-1}(\mathbf{r} - \hat{\mu}) \quad (3.3)$$

Burada \mathbf{r} test edilen piksel vektörü, $\hat{\mu}$ ve $\hat{\Sigma}$ sırasıyla arka planın ortalaması ve ortak değişinti matrisidir. Eşitlik 3.3'te hesaplanan Mahalanobis mesafe değeri, test edilen pikselin arka plan dağılımından ne kadar uzaklaştığının bir ölçüsüdür. Test pikseli için hesaplanan bu değer önceden belirlenen bir eşik değerinden büyük olması durumunda, test edilen piksel anomali olarak adlandırılır.

3.1.2 Yerel Reed-Xiaoli Algoritması

Yerel Reed-Xiaoli (Local Reed-Xiaoli-LRX) algoritması GRX'in kullandığı global arka plan modelinin yerine yerel arka plan modelini kullanır [14]. Veride arka plan sıfır ortalamaya ve bilinmeyen bir ortak değişinti matrisine sahip bir Gauss dağılımı ile modellenirken, hedef imza aynı ortak değişinti matrisli farklı ortalamalı bir Gauss dağılımı ile modellenir. LRX algoritmasının hedef tespitinde kullandığı hipotez şu şekilde gösterilebilir:

$$\begin{aligned} H_0 : \mathbf{x} &= \mathbf{b} \quad \text{Hedef yok} \\ H_1 : \mathbf{x} &= \mathbf{a}\mathbf{s} + \mathbf{b} \quad \text{Hedef var} \end{aligned} \tag{3.4}$$

H_0 hipotezinde $a = 0$ iken H_1 hipotezinde $a > 0$ dır. \mathbf{b} arka plan gürültüsü ve \mathbf{s} bilinmeyen hedefe ait imzadır.

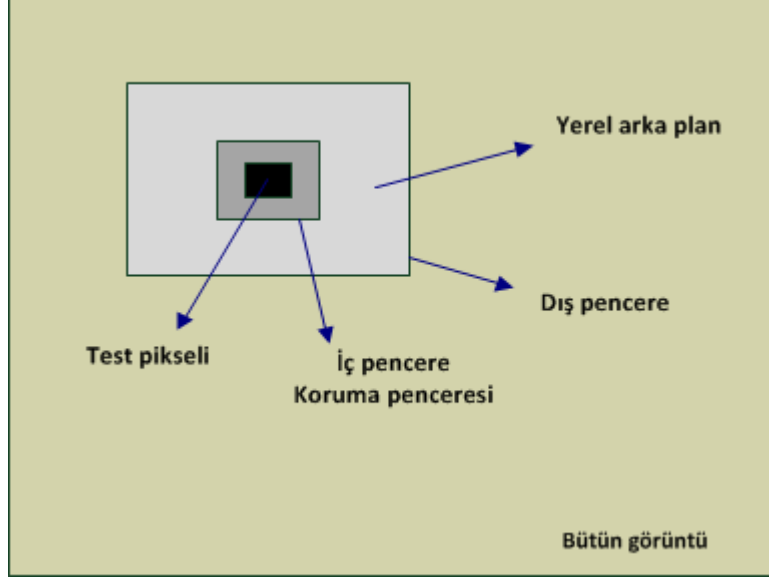
LRX algoritmasında olası anomali noktaların tespiti için Şekil 3.1'de gösterildiği gibi, veri üzerinde her bir piksel birbirinden bağımsız olacak şekilde eş merkezli iki pencere gezdirilir. Eş merkezli yapının iç kısmında bulunan küçük pencere veride öngörülen hedefin boyutuna göre ayarlanır. Koruma penceresi olarak da adlandırılan bu iç pencere test edilen pikseli çevreleyen olası anomalilerin ortalama hesabına katılmasını önler. Dış kısımda yer alan büyük pencere ise ortalama hesabı için kullanılacak alanı sınırlar. Yerel Gauss arka plan bileşenleri Eşitlik 3.3'te yer alan global Gauss arka plan bileşenlerinin yerini aldığı anda LRX algoritması için denklem yeniden düzenlenir.

$$D_{LRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_{yerel})^T \hat{\Sigma}_{yerel}^{-1} (\mathbf{r} - \hat{\mu}_{yerel}) \tag{3.5}$$

Denklemden \mathbf{r} test edilen piksel vektörü, $\hat{\mu}_{yerel}$ ve $\hat{\Sigma}_{yerel}$ sırasıyla yerel arka plan içinde kalan ortalama vektörü ve ortak değişinti matrisidir.

3.1.3 Reed-Xiaoli ve Uniform Hedef Bulucu

Ashton ve Schaum, hedef tespiti yapılacak görüntülerde arka planın yanı sıra gürültünün bastırılması ile RX anomali bulucunun performansının iyileşebileceği önerisinde



Şekil 3.1. Test pikselini çevreleyen eş merkezli pencereler

bulunmuşlardır [29]. Bu öneriden yola çıkılarak RX anomali bulucuya uniform hedef bulucu (Uniform Target Detector -UTD) eklenmesi ile yeni bir anomali bulucu geliştirilmiştir [28]. Geliştirilen anomali bulucunun matematiksel ifadesi, verinin uniform bir dağılıma sahip olduğu varsayımında bulunan UTD'nin RX anomali bulucudan çıkartılması sonucu aşağıda gösterildiği şekilde elde edilmiştir.

$$D_{RXD-UTD}(\mathbf{r}) = (\mathbf{r} - \mathbf{1}_{dx1})^T \hat{\Sigma}_b^{-1} (\mathbf{r} - \mu) \quad (3.6)$$

Burada $\mathbf{1}_{dx1} = (1, 1, \dots, 1)^T$ d boyutlu birim vektör ve d ise verideki spektral bant sayısıdır.

3.1.4 Çift Pencereci Reed-Xiaoli Algoritması

Çift Pencereci Reed-Xiaoli (Dual Window RX-DWRX) [30] algoritmasında LRX algoritmasında olduğu gibi eş merkezli iki pencere gezdirilir. LRX algoritmasında koruma penceresi, test edilen pikseli çevreleyen noktaların da anomali olduğunu varsayarak bu noktaların ortalama hesabına katılmasını önlemektedir. LRX algoritmasının aksine DWRX algoritması, test pikselini değil koruma penceresi içerisine düşen noktaların ortalamasını arka plan ortalamasından çıkarmaktadır. DWRX mesafesi aşağıdaki gibi he-

saplanır:

$$D_{DWRX}(\mathbf{r}) = (\hat{\mu}_{fark}(\mathbf{r}))^T \hat{\Sigma}_{yerel}^{-1} (\hat{\mu}_{fark}(\mathbf{r})) \quad (3.7)$$

$$\hat{\mu}_{fark}(\mathbf{r}) = \hat{\mu}_{i\check{c}}(\mathbf{r}) - \hat{\mu}_{dış}(\mathbf{r})$$

Burada \mathbf{r} test edilen piksel vektörü, $\hat{\mu}_{i\check{c}}$ iç koruma penceresi içerisine düşen, anomali olarak öngörülen örneklerin ortalama vektörü, $\hat{\mu}_{dış}$ yerel arka plan içinde kalan ortalama vektörü ve $\hat{\Sigma}_{yerel}$ ise yerel ortak değışinti matrisidir.

LRX ve DWRX algoritmalarında anomali tespit başarımını etkileyen faktör, veri içerisinde gezdirilecek olan eş merkezli pencerelerin boyutlarıdır. Koruma penceresinin boyutu verideki olası anomali boyutundan küçük seçilmemelidir. Aksi takdirde test pikseli anomali olarak tespit edilemeyecektir. Koruma penceresinin anomali boyutundan büyük seçilmesi durumunda ise pikselin anomali olarak tespit edilememe ihtimali oluşur. Dıştaki pencerenin boyutu Şekil 3.1’de gösterilen, yerel arka plan içerisinde tespit edilecek hedef boyutu kadar boşluk kalacak şekilde seçilmelidir.

3.1.5 Alt Uzay Reed-Xiaoli Algoritması

Alt uzay Reed-Xiaoli (Subspace RX-SSRX) [31] algoritması arka plan ve hedef piksellerin farklı alt uzaylarda ifade edilebileceği varsayımında bulunur. Arka planın ifade edildiği alt uzayın tespiti, verinin bu alt uzaya dik olan izdüşümünün bulunmasıyla gerçekleşir. Bu alt uzayın bulunması hem arka plan verilerinin bastırılmasına hem de veri boyutunun düşürülmesine olanak sağlar. SSRX mesafesi aşağıdaki gibi hesaplanır:

$$D_{SSRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_b)^T (I - WW^\dagger) (\mathbf{r} - \hat{\mu}_b) \quad (3.8)$$

Burada I birim matris, $\hat{\mu}_b$ arka plan ortalaması, $W = [w_1 w_2 \dots w_m]$ arka plan örneklerinden elde edilen m izdüşüm bileşeninden oluşan bir matristir. Eşitlik 3.9’da verilen W^\dagger , W matrisinin sözde-tersi (pseudo-inverse), WW^\dagger çarpımı ise arka plan alt uzayını gösteren izdüşüm operatörüdür.

$$W^\dagger = (W^T W)^{-1} W^T \quad (3.9)$$

Arka plan alt uzayını bulmak için özdeğer ayrışım yöntemi kullanılabilir. Bu yöntemle ortak değişinti matrisini oluşturan izdüşüm bileşenleri bulunur. Anlamlı/büyük özdeğerlere karşılık gelen özvektörler ile W matrisi oluşturulur [31]. Özdeğerlerin kaç tanesinin anlamlı olduğunu belirlemek için özdeğerlerin kümülatif toplamı alınır. Toplamın yaklaşık %80 - %95'ini oluşturan özdeğerlere karşılık gelen özvektörler ile W matrisi oluşturulur.

Eşitlik 3.8'de SSRX algoritma sonucunda elde edilen değer önceden belirlenen bir eşik değer ile karşılaştırılarak test edilen pikselin anomali olup olmadığına karar verilir. SSRX algoritmasında diğer algoritmaların aksine ortak değişinti matrisinin tersinin alınması gerektirmediğinden işlem yükü hafiftir. SSRX algoritmasının başarımını W matrisinin oluşmasını sağlayan anlamlı özdeğerlerin sayısı belirler.

3.1.6 Çekirdek Reed-Xiaoli Algoritması

LRX algoritması veride arka planın homojen bir dağılım gösterdiğini varsayar ve veride arka planı çok değişkenli bir Gauss dağılımı ile modeller. Ancak spektral bantlar arasında doğrusal olmayan ilişki söz konusu olabilmektedir. Çekirdek Reed-Xiaoli algoritması (Kernel RX - KRX) [32] verinin daha karmaşık karar sınırlarına ihtiyaç duyduğu bu durumlar için geliştirilmiş bir anomali bulucudur. KRX algoritması doğrusal olmayan modelleme kullanarak karmaşık olan veriyi yüksek boyuta taşır. Ancak yüksek boyutlarda modelleme yapılabilmesi için parametre kestiriminde çok sayıda veriye ihtiyaç duyulur. Bunu önlemek için çekirdek fonksiyonları kullanılır [33]. Çekirdek fonksiyonları verinin yüksek boyuta taşınmasına gerek kalmadan kendi uzayında işlem yapılmasına olanak sağlar. LRX algoritmasının kullandığı varsayımlar KRX algoritması için de geçerlidir. Eşitlik 3.4'te verilen LRX algoritmasının kullandığı hipotez KRX için şu şekilde düzenlenir:

$$H_{0\phi} : \phi(\mathbf{x}) = \mathbf{b}_\phi \quad \text{Hedef yok} \quad (3.10)$$

$$H_{1\phi} : \phi(\mathbf{x}) = \mathbf{a}\phi(\mathbf{s}) + \mathbf{b}_\phi \quad \text{Hedef var}$$

Burada \mathbf{b}_ϕ öznitelik uzayında arka plan gürültüsü, $\phi(\mathbf{s})$ ise aynı uzayda bilinmeyen hedefe ait imzadır. LRX algoritmasının 3.5'te kullandığı denklem öznitelik uzayında,

$$D_{KRX}(\phi(\mathbf{r})) = (\phi(\mathbf{r}) - \hat{\mu}_{b_\phi})^T \hat{\Sigma}_{b_\phi}^{-1} (\phi(\mathbf{r}) - \hat{\mu}_{b_\phi}) \quad (3.11)$$

şeklinde ifade edilir. Burada $\hat{\mu}_{b_\phi}$ ve $\hat{\Sigma}_{b_\phi}$ sırasıyla öznitelik uzayında kestirilen arka plan ortalama vektörü ve ortak değişinti matrisidir.

Eşitlik 3.12'de verilen, literatürde çekirdek teknikleri olarak bilinen yaklaşım sayesinde, çekirdek fonksiyonları öznitelik uzayında nokta çarpımı (dot product) halinde gösterilir. Çekirdek teknikleri kullanılarak Eşitlik 3.11'de verilen denklem Eşitlik 3.13'teki halini alır.

$$\begin{aligned} k(\mathbf{x}, \mathbf{y}) &= \langle \phi(\mathbf{x}), \phi(\mathbf{y}) \rangle \\ &= \phi(\mathbf{x}) \cdot \phi(\mathbf{y}) \end{aligned} \quad (3.12)$$

$$D_{KRX}(\mathbf{r}) = (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T)^T \hat{\mathbf{K}}_b^{-1} (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T) \quad (3.13)$$

Burada $\hat{\mathbf{K}}_b$ arka plan piksellerinden oluşan merkeze çekilmiş Gram (Çekirdek) matrisidir. Gram matrisi ayrıca $\hat{\mathbf{K}}_b = \mathbf{K}(\mathbf{X}_b, \mathbf{X}_b)$ ile gösterilir ve aşağıda verilen şekilde elde edilir:

$$\hat{\mathbf{K}}_b = \mathbf{K}(\mathbf{X}_b, \mathbf{X}_b) = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & k(\mathbf{x}_1, \mathbf{x}_2) & \cdots & k(\mathbf{x}_1, \mathbf{x}_M) \\ k(\mathbf{x}_2, \mathbf{x}_1) & k(\mathbf{x}_2, \mathbf{x}_2) & \cdots & k(\mathbf{x}_2, \mathbf{x}_M) \\ \vdots & \vdots & \ddots & \vdots \\ k(\mathbf{x}_M, \mathbf{x}_1) & k(\mathbf{x}_M, \mathbf{x}_2) & \cdots & k(\mathbf{x}_M, \mathbf{x}_M) \end{bmatrix}$$

Burada $\mathbf{X}_b = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(M)]$ piksel spektra vektörlerinden oluşan arka plan sütun matrisidir. Eşitlik 3.13'te yer alan \mathbf{K}_r^T terimi bir vektördür ve \mathbf{r} test pikseli için aşağıdaki gibi hesaplanır:

$$\mathbf{K}_r^T \equiv \mathbf{k}(\mathbf{X}_b, \mathbf{r})^T = \frac{1}{M} \sum_{i=1}^M k(\mathbf{x}(i), \mathbf{r}) \quad (3.14)$$

Eşitlik 3.14'de ilk terim

$$\mathbf{k}(\mathbf{X}_b, \mathbf{r}) = \left[\phi(\mathbf{x}_1) \cdot \phi(\mathbf{r}) \quad \phi(\mathbf{x}_2) \cdot \phi(\mathbf{r}) \quad \cdots \quad \phi(\mathbf{x}_M) \cdot \phi(\mathbf{r}) \right]$$

ile bulunur. Eşitlik 3.14'teki ikinci terim ise $\mathbf{k}(\mathbf{X}_b, \mathbf{r})$ ifadesinin sayısal ortalamasıdır. Son olarak, Eşitlik 3.13'te yer alan $\mathbf{K}_{\hat{\mu}_b}^T$ terimi aşağıdaki şekilde bulunur:

$$\mathbf{K}_{\hat{\mu}_b}^T \equiv \frac{1}{M} \sum_{i=1}^M \mathbf{K}(\mathbf{X}_b, \mathbf{x}(i)) - \frac{1}{M^2} \sum_{i=1}^M \sum_{j=1}^M k(\mathbf{x}(i), \mathbf{x}(j)) \quad (3.15)$$

Eşitlik 3.15'te yer alan ilk terim Gram matrisinin her bir sütununun ortalamasını içeren bir satır vektörüdür. İkinci terim ise Gram matrisinin sayısal ortalamasıdır.

Çekirdek teknikleri kullanılarak elde edilen, Eşitlik 3.13'te verilen denklem eşleme fonksiyonundan bağımsızdır. Pozitif tanımlı bir Gram matrisi oluşturabilmek için ihtiyaç duyulan tek gereksinim uygun k çekirdek fonksiyonunun seçilmesidir. KRX algoritmasının başarımını etkileyen faktör dış pencere boyutunun büyüklüğüdür. Dış pencere boyutu oluşturulacak Gram matrislerin boyutunu da belirlemektedir. Her bir piksel için Gram matrisin hesaplanması ve tersinin alınmasındaki işlem yükü, KRX algoritması için bir dezavantajdır.


Şimdiye kadar anlatılan modelleme tabanlı anomali tespit algoritmaları Çizelge 3.1'de özetlenmiştir. Modelleme tabanlı anomali tespit yöntemlerinin haricinde bölütleme yaparak verideki anomalileri tespit eden yöntemler olduğu gibi öznitelik kullanımına dayalı anomali tespit yöntemleri de bulunmaktadır. Tez kapsamında incelenen bir diğer anomali tespit algoritması da öznitelik tabanlı Reststrahlen oran tespit algoritmasıdır.

Algoritma	Referans No	Kullanılan Eşitlik
GRX	[14]	$D_{GRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu})^T \hat{\Sigma}^{-1} (\mathbf{r} - \hat{\mu})$
LRX	[26]	$D_{LRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_{yere1})^T \hat{\Sigma}_{yere1}^{-1} (\mathbf{r} - \hat{\mu}_{yere1})$
RXD-UTD	[28]	$D_{RXD-UTD}(\mathbf{r}) = (\mathbf{r} - \mathbf{1}_{dx1})^T \hat{\Sigma}_b^{-1} (\mathbf{r} - \mu)$
DWRX	[30]	$D_{DWRX}(\mathbf{r}) = (\hat{\mu}_{fark}(\mathbf{r}))^T \hat{\Sigma}_{yere1}^{-1} (\hat{\mu}_{fark}(\mathbf{r}))$
SSRX	[31]	$D_{SSRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_b)^T (I - WW^\dagger) (\mathbf{r} - \hat{\mu}_b)$
KKRX	[32]	$D_{KKRX}(\mathbf{r}) = (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T)^T \hat{\mathbf{K}}_b^{-1} (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T)$

Çizelge 3.1. Anomali tespit algoritmaları

3.2 Anomali Tespit Algoritmalarının Yapay Veri Seti Üzerinde Uygulanması

Bölüm 3.1’de anlatılan modelleme tabanlı anomali tespit algoritmaları iki farklı yapay veri seti üzerinde uygulanmıştır. Yapay veriler üzerinde algoritmaların başarımlarını etkileyen değişkenler detaylı bir şekilde araştırılmıştır. Anomali tespit algoritmalarının başarımlarını etkileyen parametrelerin seçimini incelemek için farklı gürültü seviyelerinde iki farklı yapay veri seti üretilmiştir. İlk veri seti 100x100x10 boyutlu bir veri küpünden oluşmaktadır. Veri küpü ortalama değeri 1 ve varyansı 0.1 olan normal dağılıma sahip bir arka plandan oluşmaktadır. Veri küpü içerisinde varyansı arka planla aynı, ortalama değeri ise 1.5 olan normal dağılıma sahip üç farklı anomali bölgesi oluşturulmuştur. Veri küpünde yer alan hedefler sırasıyla 5x5x10 (H1), 7x7x10 (H2) ve 9x9x10 (H3)’lük boyutlara sahiptir. İkinci veri seti için ortalama değeri 1 ve varyansı 0.2 olan normal dağılıma sahip bir arka plan oluşturulmuştur. Veri üzerindeki anomali bölgeleri ise ortalama değeri 1.2 ve varyansı arka plan ile aynı normal dağılıma sahiptir. İkinci veri setinin üretilmesinde amaç, hedef ve arka plan dağılımını olabildiğince benzer kılarak hedeflerin arka plandan ayırt edilebilmesini zorlaştırmaktır. Üretilen veri setlerinin tek bant görüntüleri Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Üretilen yapay veri setlerinde (a) birinci sahne, (b) ikinci sahne

Veri üzerinde eş merkezli pencere gezdirilerek anomalileri bulmaya çalışan pencere tabanlı algoritmalar için iç pencere boyutu H2 boyutunda 7x7, dış pencere boyutu ise yerel arka plan içerisine en fazla bir hedef yerleşebilmesini sağlayacak şekilde 15x15 olarak seçilmiştir. KRX için Gauss tipi çekirdek fonksiyonu $k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2 / (c))$ kul-

lanılmıştır ve c sabiti 40 olarak ayarlanmıştır. SSRX için özvektör sayısı temel bileşenlerin yaklaşık %50'sini içerecek şekilde seçilmiştir. Birinci veri seti için anomali tespit algoritmalarının herhangi bir eşikleme yapılmamış sonuçları Şekil 3.3'te gösterilmektedir. Tespit sonuçlarına göre GRX anomali bulucu çok sayıda yanlış alarm üretmiştir ve yanlış alarm sayısına göre GRX'i sırasıyla RXD-UTD, SSRX, KRX anomali bulucuları takip etmektedir. LRX ve DWRX anomali bulucuları H1 ve H2 hedeflerini tespit edebilmiş iken H3 hedefini tespit edememiştir. Burdan çıkarılacak sonuç LRX ve DWRX anomali bulucuları koşturulurken seçilen iç pencere boyutunun hedefte öngörülen anomali boyutundan küçük olmamasının gerekliliğidir. Dış pencere boyutundaki artış H1'in tespitinde olduğu gibi diğer hedeflerin tespitinde de iyileştirme sağlamıştır. LRX ve DWRX anomali bulucuları H2'nin merkez noktasını bulabilmiş iken, H1'in merkez noktalarının yanı sıra hedefin çevre noktalarını da tespit ettiği görülmüştür. Pencere tabanlı anomali bulucular için dış pencere boyutu bir başka hedefi içine almayacak şekilde artırılmalıdır. Aksi takdirde öngörülen hedef kendisini çevreleyen noktalara göre anomali olmaktan uzaklaşacaktır. KRX algoritması hedefleri fazlaca yanlış alarm üreterek tespit etmiştir. KRX algoritmasında seçilen dış pencere boyutu, Gram matrisinin boyutunu belirlediği için, algoritmanın harcadığı süre göz önüne alındığında oldukça kritik bir parametredir. Algoritmaların bu yapay veri seti üzerinde windows 8.1 core i7 2.4GHZ-16GB RAM-256SSD+1.5TB HDD-4GB özelliklerine sahip bir bilgisayarda harcadığı süreler Çizelge 3.2'te gösterilmektedir. KRX'in diğer anomali buluculara göre oldukça fazla süre harcadığı görülebilmektedir.

Anomali Bulucu	Harcanan Süre (Saniye)
GRX	0.791161
RXD-UTD	0.791461
SSRX	2.071365
LRX	2.113414
DWRX	5.844737
KRX	276.098141

Çizelge 3.2. Anomali bulucuların yapay veri seti üzerinde harcadığı süreler


İkinci veri setinde arka plan ve hedeflerin benzer bir dağılım göstermesi hedeflerin tes-

pitini zorlaştıran bir problemi de beraberinde getirmektedir. Bu yüzden hedef tespit başarımında parametre seçimi önemli bir hal almaktadır. İkinci veri seti üzerinde algoritmalar koşturulurken ilk veri seti için seçilen parametreler kullanılmıştır. Aynı parametre kullanım koşulu altında, ikinci veri seti için anomali tespit algoritmaların eşikleme yapılmamış sonuçları Şekil 3.4'te gösterilmektedir. Elde edilen sonuçlarda DWRX anomali bulucunun gürültüye karşı dirençli kaldığı, diğer anomali buluculara oranla daha az sayıda yanlış alarm üreterek hedefleri daha iyi bulduğu görülmektedir [34].


Şekil 3.5'te, ikinci veri seti üzerinde DWRX ve LRX anomali bulucularının pencere boyutlarına bağlı hedefleri tespit etme durumları karşılaştırılmıştır. Şekil 3.5-(a) ve Şekil 3.5-(b)'de dış pencere boyutunun iç pencere boyutuna yakın seçildiği durum için DWRX anomali bulucunun yalnız H1 ve H2 hedeflerini bulabildiği, LRX'in ise hiçbir hedefi bulamadığı görülmektedir. Dış pencere boyutunun 9x9'dan 21x21'e büyütülmesi, hem LRX'in hem de DWRX'in bütün hedefleri tespit etmesini sağlamıştır. Ancak LRX anomali bulucu çok sayıda yanlış alarm üretmişken, DWRX anomali bulucu oldukça az sayıda yanlış alarm üretmiştir. Şekil 3.5-(e) ve Şekil 3.5-(f)'de verilen, iç pencere boyutunun 7x7'den 9x9'a büyütüldüğü durumda, H1 hedefinin anomali bulucular tarafından tespit edilemediği görülmektedir. İç pencerenin neredeyse H1 (5x5) hedef boyutunun iki katı seçildiği bu durum, H1 anomali noktasının arka plandan ayırt edilememesine sebep olmuştur.

KRX ve SSRX anomali bulucuların ikinci veri seti üzerinde hedefleri tespit etme durumları Şekil 3.6'da gösterilmektedir. Arka plan ve hedeflerin benzer dağılım gösterdiği ikinci veri seti üzerinde, SSRX anomali bulucu üç farklı durumda da hedef noktaları net bir şekilde tespit edememiştir. Bu durumun sebebi, arka plan ve hedef noktalarının farklı alt uzaylarda gösterilememiş olmasıdır. KRX anomali bulucu ise pencere boyutlarının değişiminden fazla etkilenmemiş, üç farklı durumda da hedefleri tespit edebilmiştir. Ancak tespit esnasında oldukça fazla yanlış alarm üretmiştir.


Herhangi bir değişkene bağlı kalmadan hedefleri tespit etmeye çalışan GRX ve RXD-UTD anomali bulucuları ise Şekil 3.7'de karşılaştırılmıştır. RXD-UTD anomali bulucunun özellikle ikinci veri seti üzerindeki çıktısından da görülebileceği üzere, RXD-UTD arka plan gürültüsü bastırılarak hedeflerin belirginleşmesine olanak sağlamıştır.




(a) Üretilen veri




(b) GRX




(c) LRX



(d) DWRX



(e) SSRX




(f) KRX


Şekil 3.3. Birinci yapay veri seti üzerinde anomali tespit sonuçları




(a) Üretilen veri




(b) GRX




(c) LRX



(d) DWRX




(e) SSRX




(f) KRX


Şekil 3.4. İkinci yapay veri seti üzerinde anomali tespit sonuçları




(a) LRX-7-9




(b) DWRX-7-9




(c) LRX-7-21



(d) DWRX-7-21




(e) LRX-9-17




(f) DWRX-9-17


Şekil 3.5. İkinci yapay veri seti üzerinde DWRX - LRX anomali bulucuların karşılaştırılması. LRX-7-9 etiketi, LRX anomali bulucu için iç pencere boyutu 7x7, dış pencere boyutu 9x9 olarak kullanıldığını göstermektedir.




(a) SSRX-7-9




(b) KRX-7-9




(c) SSRX-7-21



(d) KRX-7-21




(e) SSRX-9-17




(f) KRX-9-17


Şekil 3.6. İkinci yapay veri seti üzerinde KRX - SSRX anomali bulucularının karşılaştırılması. KRX-7-21 etiketi, KRX anomali bulucu için iç pencere boyutu 7x7, dış pencere boyutu 21x21 olarak kullanıldığını göstermektedir.




(a) 1. Yapay veri seti




(b) 2. Yapay veri seti




(c) GRX



(d) GRX



(e) RXD-UTD



(f) RXD-UTD

Şekil 3.7. GRX ve RXD-UTD anomali tespit sonuçlarının karşılaştırılması (a) 1. yapay veri seti, (b) 2. yapay veri seti, (c) 1. yapay veri seti üzerinde GRX çıktısı, (d) 2. yapay veri seti üzerinde GRX çıktısı, (e) 1. yapay veri seti üzerinde RXD-UTD çıktısı, (f) 2. yapay veri seti üzerinde RXD-UTD çıktısı

3.3 Reststrahlen Oran Tespit Algoritması

Reststrahlen oran tespit algoritması, Reststrahlen etkisinden yola çıkılarak toprak yüzeyindeki farklılıkları tespit etmek için geliştirilmiş bir hedef tespit algoritmasıdır. Reststrahlen etkisi, kızılötesi dalga boyu bandında görülen, ışığın maddelerin atomik veya kristal yapılarında meydana getirdiği yankılanmadan (resonance) kaynaklanan salıcılık düşüşüdür. Kil, kuvarz gibi silikon içeren toprak yapıları için yankılanma dalgaboyu 8 - 9.5 μm aralığındadır [35, 36]. Bu dalga boyu aralığındaki salıcılık değerlerinde meydana gelen düşüşü topraktaki yapısal farklılıklar, toprağın tanecik boyutu ve nemliliği gibi etkenler belirler [36, 37].

Reststrahlen oran tespit algoritması iki aşamadan oluşmaktadır [17]. İlk adım olarak Reststrahlen etkisinin görüldüğü 8 - 11 μm aralığı iki farklı gruba ayrılır. İlk R grubu, silikon içeren maddeler için Reststrahlen bölgesi 8.87 - 9.40 μm aralığında olan spektral bantları içerir. Diğer N grubu ise Reststrahlen bölgesinin dışında kalan 10.9 - 11.5 μm aralığındaki bantlardan oluşmaktadır. Her bir grupta bulunan radyans değerlerinin ortalaması alınarak ilgili piksel değerleri hesaplanır. Reststrahlen oran tespit algoritmasında ikinci adım ise Reststrahlen oran özneliği S 'yi hesaplamaktır:

$$S(x, y) = \frac{1}{1 + e^{C(x,y)}} \quad (3.16)$$

burada

$$C(x, y) = \frac{R(x, y) - N(x, y)}{\frac{1}{P} \sum_{(u,v)} R(u, v) - N(u, v)} \quad (3.17)$$

ve P görüntüdeki piksel sayısıdır. Her bir piksel için elde edilen S öznelik değerine göre muhtemel anomali noktaları tespit edilmeye çalışılır.

3.4 Uç Eleman Analiz Yöntemleri

Hiperspektral görüntülerin zengin spektral bilgi sunması, spektral çözünürlüğün yüksek olmasına olanak sağlamaktadır. Ancak özellikle HP verilerinde hiperspektral görüntüler için uzamsal çözünürlük düşük olabilmektedir [4]. Uzamsal çözünürlüğü düşük hipers-

programlama yöntemidir. Materyallerin spektral imzalarını (uç elemanları) ve uç elemanların katışım oranlarını otomatik olarak belirlemeye yarar. Bunu yaparken, doğrusal katışım modeline bazı kısıtlar getirir ve bu kısıtlar eşliğinde ölçülen ile kestirilen değerler arasındaki hatayı minimize eder.

ICE algoritmasının doğrusal katışım modelini kullanarak uç elemanları ve katışım oranları tespit etmesi şu şekildedir:

Hiperspektral bir veri d hiperspektral bant sayısı ve N piksel sayısı olmak üzere $d \times N$ boyutlu bir \mathbf{X} matrisine dönüştürülür. \mathbf{X} matrisinin her bir sütunu, \mathbf{x}_i , görüntüde i . piksele denk gelen $d \times 1$ vektördür. \mathbf{X} matrisinin her bir satırı ise $1 \times N$ boyutlu \mathbf{x}_j vektördür. $\mathbf{x}_j, j = 1, \dots, d$ vektörü j . spektral banda karşılık gelen N gözlemi temsil etmektedir [41].

Doğrusal katışım modeline göre:

$$\mathbf{x}_i = \sum_{k=1}^M p_{ik} \mathbf{E}_k + \epsilon_i \quad i = 1, \dots, N \quad (3.18)$$

burada M uç eleman sayısı, ϵ_i hata terimi, \mathbf{E} uç elemanların yanyana dizilmesinden oluşan $d \times M$ boyutundaki uç eleman matrisidir. \mathbf{E}_k , bu matrisin sütunlarını oluşturan k . uç elemanın yer aldığı $d \times 1$ lik vektördür ve $\mathbf{E}_k^T = (e_{k1}, \dots, e_{kd})$ şeklinde gösterilir. e_{kj} j . spektral banttaki k . uç eleman değeridir. \mathbf{E} matrisinin her bir sırası ise $\mathbf{e}_j^T = (e_{1j}, \dots, e_{Mj})$ vektörünü oluşturur. Katışım oranı p_{ik} ise, k . uç elemanın i . pikselde bulunma oranıdır. Bu oranlardan oluşan p_i, i . pikseldeki uç elemanların $1 \times M$ boyutundaki katışım (bolluk) vektörüdür ve

$$\sum_{k=1}^M p_{ik} = 1, \quad p_{ik} \geq 0, \quad k = 1, \dots, M \quad (3.19)$$

ile sınırlanır. Katışım vektörleri $N \times M$ boyutunda \mathbf{P} , katışım oran matrisini oluşturur. Katışım oran matrisi her bir pikselde uç elemanların hangi oranda katışım halinde bulunduğunu göstermektedir.

ICE algoritması, ölçülen değer ile kestirilen değer arasındaki farkı en aza indirmeye

çalışır. Bunun için artık kareler toplamını (residual sum of squares) hesaplar:

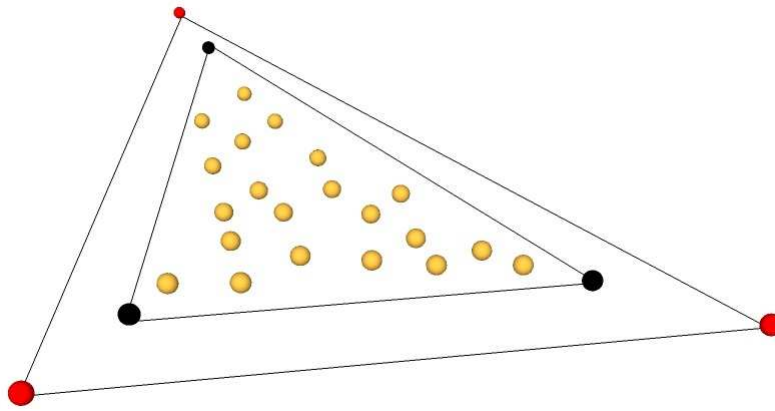
$$\begin{aligned}
 RSS &= \sum_{i=1}^N \left(\mathbf{x}_i - \sum_{k=1}^M p_{ik} \mathbf{E}_k \right)^T \left(\mathbf{x}_i - \sum_{k=1}^M p_{ik} \mathbf{E}_k \right) \\
 &= \sum_{j=1}^d (\mathbf{x}_j - \mathbf{P} \mathbf{e}_j)^T (\mathbf{x}_j - \mathbf{P} \mathbf{e}_j)
 \end{aligned} \tag{3.20}$$

Dışbükey geometri modeli, uç elemanların simpleksin köşelerinde bulunduğunu varsamaktadır. Eşitlik 3.20'de verilen RSS terimi gürültüden fazlaca etkilenmektedir ve gereğinden geniş bir dışbükey sınıra neden olabilmektedir. Bu duruma Şekil 3.9'da bütün verileri kapsayan iki simpleks örnek olarak gösterilmiştir.

Şekil 3.9'da üçgenin köşelerini oluşturan siyah ve kırmızı noktalar simplekslere ait uç elemanları, üçgen içerisindeki sarı noktalar ise verileri göstermektedir. ICE algoritması Eşitlik 3.20'de verilen haliyle bu iki üçgenden herhangi birini bulabilir. Bunu önlemek için bir düzenleştirme terimi eklenerek simpleks boyutu kısıtlanmaya çalışılır. Eşitlik 3.20'e (0-1) aralığında μ ödünleşim değişkeni eklenerek denklem aşağıdaki hale getirilir.

$$RSS_{reg}^* = (1 - \mu) \frac{RSS}{N} + \mu V \tag{3.21}$$

Düzenleştirme terimi V , simpleks köşelerinin birbirlerine olan uzaklığının karelerinin



Şekil 3.9. Bütün verileri kapsayan iki farklı simpleks [38]

toplamını küçültür ve uç eleman sayısından bağımsız olması için standartlaştırılır:

$$\begin{aligned}
 V &= \frac{1}{M(M-1)} \sum_{k=1}^{M-1} \sum_{l=k+1}^M (\mathbf{E}_k - \mathbf{E}_l)^T (\mathbf{E}_k - \mathbf{E}_l) \\
 &= \frac{1}{M(M-1)} \sum_{j=1}^d \mathbf{e}_j^T (M\mathbf{I}_M - \mathbf{1}\mathbf{1}^T) \mathbf{e}_j
 \end{aligned} \tag{3.22}$$

burada \mathbf{I}_M , $M \times M$ boyundaki birim matrisi göstermektedir, $\mathbf{1}$ ise $M \times 1$ boyutunda birlerden oluşan vektördür.

ICE algoritması Eşitlik 3.21'de verilen denklemi hem uç elemanlar için hem de her bir pikseldeki katışım oranları için minimize etmeye çalışır. Bu işlemi yinelemeli bir şekilde gerçekleştirir. Birbirinin ardısına önce uç eleman kestirimine göre katışım matrisini hesaplar, sonra da katışım kestirimlerini sabit tutarak uç elemanları tekrar hesaplar.

Eşitlik 3.21'de V terimi katışım oranları içermemektedir. Katışım oranlarını bulmak için geride kalan terimler 3.19'da verilen kısıtlar kullanılarak çözülür. Uç elemanların bulunması için ise sözde-ters yöntemi kullanılır ve uç elemanlar aşağıdaki şekilde elde edilir:

$$\begin{aligned}
 \mathbf{e}_j &= \left\{ \mathbf{P}^T \mathbf{P} + \lambda \left(\mathbf{I}_M - \frac{\mathbf{1}\mathbf{1}^T}{M} \right) \right\}^{-1} \mathbf{P}^T \mathbf{x}_j \\
 \lambda &= \frac{N\mu}{(M-1)(1-\mu)}
 \end{aligned} \tag{3.23}$$

3.4.2 SPICE

ICE algoritması verideki M , toplam uç eleman sayısı bilindiğinde sorunsuz bir şekilde uç elemanları bulabilmektedir. Ancak uç eleman sayısı bilinmediği durumlarda, ICE algoritmasının bu sayıyı otomatik olarak belirleyen bir yapısı yoktur. Bu eksikliği giderebilmek için Seyreklik teşvik eden yinelemeli kısıtlı uç elemanlar (Sparsity Promoting Iterated Constrained Endmember - SPICE) algoritması [42] geliştirilmiştir.

SPICE algoritması ortamda kaç uç eleman bulunduğunu, bu uç elemanları ve uç elemanların katışım oranlarını otomatik olarak belirler. Bunu gerçekleştirebilmek için ICE

algoritmasının kullandığı Eşitlik 3.21'de verilen denkleme seyreklik teşvik edici (sparsity promoting term) SPT bir terim ekler. SPICE algoritmasının kullandığı amaç fonksiyonu

$$RSS_{reg}^* = (1 - \mu) \frac{RSS}{N} + \mu V + SPT \quad (3.24)$$

halini alır. SPT , katışım oranları çok düşük olan uç elemanları yinelemeli bir şekilde eler. Eşitlik 3.24'te yer alan SPT aşağıdaki şekilde hesaplanır:

$$SPT = \sum_{k=1}^M \gamma_k \sum_{i=1}^N p_{ik} \quad (3.25)$$

burada γ_k katsayısı

$$\gamma_k = \frac{\Gamma}{\sum_{j=1}^N p_{jk}} \quad (3.26)$$

Eşitlik 3.26'da Γ katışım oranlarının hangi hızla sıfıra gideceğini ayarlayan bir sabittir. Eğer bir uç elemanın katışım oranlarının toplamı küçük ise γ_k katsayısı büyür ve katışım oranlarının minimizasyonu hızlanır.

Bu bilgiler ışığında, Eşitlik 3.24'te verilen denklemin hem tüm uç elemanlar için hem de her bir pikseldeki katışım oranları için minimize edilmesi gerekir. SPICE algoritması bu işlemi yinelemeli olarak yapar. Birbirinin ardına, önce uç eleman kestirimlerine göre katışım matrisini hesaplar, sonra da katışım kestirimlerini sabit tutarak uç elemanları tekrar hesaplar.

3.4.3 KİDDO

ICE ve SPICE algoritmaları uç elemanları bulmak için sözde-ters yöntemini kullanmaktadır. Ancak sözde-ters yöntemi fiziksel olarak mümkün olmayan negatif değerler üretebilmektedir. KİDDO (Kısıtlı İkinci Dereceden Denklemlerle Optimizasyon) algoritması [41] uç elemanların alabileceği değerlere (0-1) aralığında olma kısıtı koyarak fiziksel olarak mümkün olmayan bu problemi giderebilmektedir. SPICE algoritmasında olduğu

gibi, hem uç eleman sayısını, hem uç elemanların imzalarını hem de bolluk oranlarını otomatik olarak bulabilmektedir. KİDDO algoritması, ICE ve SPICE algoritmalarının aksine uç elemanları bulmak için sözde-ters yöntemini kullanmaz, katışım vektörlerini karesel programlama ile bulacak şekilde formalize eder.

Eşitlik 3.24'te verilen amaç fonksiyonu KİDDO algoritması için aşağıdaki şekilde yeniden düzenlenir:

$$\begin{aligned}
RSS_{reg} &= \frac{(1-\mu)}{N} \sum_{j=1}^d (\mathbf{x}_j - \mathbf{P}e_j)^T (\mathbf{x}_j - \mathbf{P}e_j) + \mu \frac{1}{M(M-1)} \sum_{j=1}^d e_j^T (M\mathbf{I}_M - \mathbf{1}\mathbf{1}^T) e_j \\
&\simeq \sum_{j=1}^d \left\{ \frac{(1-\mu)}{N} e_j^T (\mathbf{P}^T \mathbf{P}) e_j + \frac{(1-\mu)}{N} (-2) e_j^T \mathbf{P}^T \mathbf{x}_j + \frac{\mu}{M(M-1)} e_j^T (M\mathbf{I}_M - \mathbf{1}\mathbf{1}^T) e_j \right\} \\
&= \frac{(1-\mu)}{N} \sum_{j=1}^d e_j^T H e_j + e_j^T f
\end{aligned} \tag{3.27}$$

KİDDO algoritması katışım oranlarını bulmak için Eşitlik 3.24'te verilen denklemi, uç elemanları bulmak için ise Eşitlik 3.27'de verilen denklemi karesel programlama ile çözer. Eşitlik 3.27'de yer alan terimler ise şöyledir:

$$\begin{aligned}
H &= \mathbf{P}^T \mathbf{P} + \lambda \left(\mathbf{I} \frac{\mathbf{1}\mathbf{1}^T}{M} \right) \\
f &= -2\mathbf{P}^T \mathbf{x}_j \\
\lambda &= \frac{N\mu}{(M-1)(1-\mu)}
\end{aligned} \tag{3.28}$$

Burada yer alan eşitlikler optimizasyon kütüphaneleri ile çözülebilmektedir.

3.5 Uç Eleman Analiz Yöntemlerinin Yapay Veri Seti Üzerinde Uygulanması

Bölüm 3.4'te anlatılan uç eleman analiz yöntemleri, ASTER spektral kütüphanesinde bulunan materyallere ait spektral imzalar ile oluşturulmuş yapay bir veri seti üzerinde uygulanmıştır. Gelişmiş Uzay Termal Yayılma ve Yansıma Radyometresi (ASTER), jeolojik haritalama başta olmak üzere mineral arama, tarım, ormancılık ve savunma gibi birçok

uygulama alanında kullanılan pasif bir algılayıcı sistemdir [22]. ASTER kütüphanesi, hiperspektral görüntülerin yorumlanması için materyallerin spektral imzalarını referans bir kaynak olarak sunmaktadır. Kütüphane çeşitli özellikte yaklaşık 2000 materyalin dalga boyu-yansıma bilgisini içermektedir. 0.4 - 15.4 μm dalgaboyu aralığını kapsayan bitki örtüsü, toprak ve kaya parçaları, mineral ve yapay mineral gibi birçok materyalin spektral bilgisini içermektedir. ASTER sisteminin teknik özelliklerine Çizelge 3.3'te yer verilmiştir.


Uzamsal Çözünürlük	15x15m VNIR, 30x30m SWIR, 90x90m TIR
Kapladığı Alan	60km x 60km
Dinamik Aralık	8 bit
Spektral Bant Sayısı	14 (3 VNIR, 6 SWIR, 5 TIR)

Çizelge 3.3. ASTER sisteminin teknik özellikleri

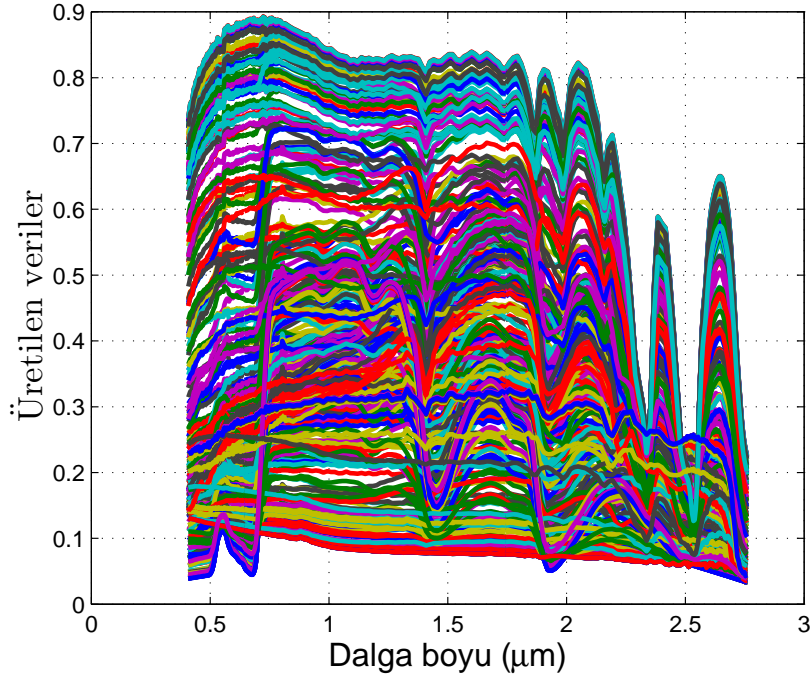
Yapay veri setini oluşturmak için ASTER spektral kütüphanesindeki verilerden beş farklı materyal seçilmiştir. Seçilen materyallerin aynı dalga boyu bandında olması için yansıma değerlerine ara değer kestirimi (interpolasyon) işlemi uygulanmıştır. Bu işlem sonucunda seçilen materyallere ait 0.4 - 2.6 μm dalga boyu aralığında 258 banttan oluşan yansıma değerleri elde edilmiştir. Seçilen materyallere ait spektral imzalar Şekil 3.10'da gösterilmektedir.

Bölüm 3.4'te anlatılan doğrusal katışım modeli kullanılarak karışım verisi hazırlanmıştır. Bunun için, öncelikle seçilen spektral imzalardan uç eleman matrisi oluşturulmuş, Dirichlet dağılımı kullanılarak katsayılar matrisi elde edilmiştir. Uç eleman ve katışım matrislerinden oluşan veri Şekil 3.11'de gösterilmektedir. Oluşturulan bu veriyi uç elemanlarına ayırıştırabilmek ve karışımındaki uç eleman sayısının doğru olarak bulunup bulunamadığını test etmek amacıyla SPICE ve KİDDO algoritmaları oluşturulmuştur. Algoritmaların kestirdikleri spektral imza değerleri ile ASTER kütüphanesinin sunduğu gerçek değerler iki farklı uzaklık ölçüm yöntemi kullanılarak karşılaştırılmıştır. Uzaklık ölçüm yöntemi olarak öncelikle Öklid uzaklığı kullanılmıştır. Ancak Öklid uzaklığı yüksek boyutlu verilerde yetersiz kaldığı için alternatif olarak Korelasyon uzaklığı tercih edilmiştir.

SPICE ve KİDDO algoritmaları için aynı parametreler kullanılarak algoritma sonuçları



Şekil 3.10. Seçilen beş farklı materyale ait spektral imzalar [38]



Şekil 3.11. Dirichlet dağılımı kullanılarak üretilen veriler [38]

karşılaştırılmıştır. İlk olarak, algoritmalara ortamda bulunan uç eleman sayısı 10 olarak girilmiş ve regülarizasyon parametresi $\mu = 0$ olarak alınmıştır. Regülarizasyon para-

metresi tüm verileri içeren simpleksin boyutunu sınırlandıran parametredir ve $\mu = 0$ durumu simpleks hacminin sınırlandırılmadığı durumu göstermektedir. Regülerizasyon parametresi sırasıyla, $\mu = 0.0001$ ve $\mu = 0.01$ olarak artırılmış ,simpleks hacmi üzerinde düzenleme etkisi incelenmiştir. Bu işlemler 50 kez tekrar edilmiş, elde edilen sonuçların ortalama değerleri alınarak Çizelge 3.4'te sunulmuştur. Çizelgenin üst kısmında, üç uç eleman için üretilmiş veriler, alt kısmında ise beş uç eleman için üretilmiş veriler kullanılmıştır.

		SPICE			KİDDO			
		$\mu = 0$	$\mu = 0.0001$	$\mu = 0.01$	$\mu = 0$	$\mu = 0.0001$	$\mu = 0.01$	
Uç Eleman Sayısı=3	1	<i>M</i> 'nin doğru bulunma sayısı	35/50	48/50	50/50	48/50	47/50	50/50
	2	Ort. Min. değer	-0.016	0.028	0.034	0.031	0.030	0.034
	3	Ort. Maks. değer	6.041	0.893	0.877	0.893	0.893	0.877
	4	Min. değer < 0	13NAN 2/50	2/50	0/50	0/50	0/50	0/50
	5	Maks. değer > 1	13NAN 1/50	0/50	0/50	0/50	0/50	0/50
	6	Ort. Korelasyon uzaklığı	0.41 ± 0.36	0.38 ± 0.34	0.33 ± 0.33	0.42 ± 0.37	0.43 ± 0.35	0.38 ± 0.35
	7	Ort. Öklid uzaklığı	5.29 ± 4.07	5.12 ± 4.00	4.59 ± 4.00	4.69 ± 4.13	5.74 ± 4.05	5.04 ± 3.90
Uç Eleman Sayısı=5	1	<i>M</i> 'nin doğru bulunma sayısı	31/50	36/50	50/50	47/50	47/50	50/50
	2	Ort. Min. değer	-0.032	0.001	0.033	0.017	0.019	0.033
	3	Ort. Maks. değer	0.909	0.892	0.865	0.902	0.893	0.865
	4	Min. değer < 0	11NAN 2/50	13NAN 9/50	0/50	0/50	0/50	0/50
	5	Maks. değer > 1	11NAN 1/50	13NAN 0/50	0/50	0/50	0/50	0/50
	6	Ort. Korelasyon uzaklığı	0.46 ± 0.34	0.46 ± 0.34	0.44 ± 0.29	0.47 ± 0.34	0.47 ± 0.34	0.43 ± 0.28
	7	Ort. Öklid uzaklığı	4.38 ± 3.50	4.38 ± 3.50	4.38 ± 3.23	4.45 ± 3.57	4.45 ± 3.57	4.60 ± 3.32

**M*=uç eleman sayısı; * μ =Regülerizasyon parametresi
 *NAN=Not A Number (SPICE algoritmasının spektral imzaları bulamadığı durumları gösterir.)
 *Ortalama uzaklıklar NAN olmayan değerlerin ortalaması olarak alınmıştır.

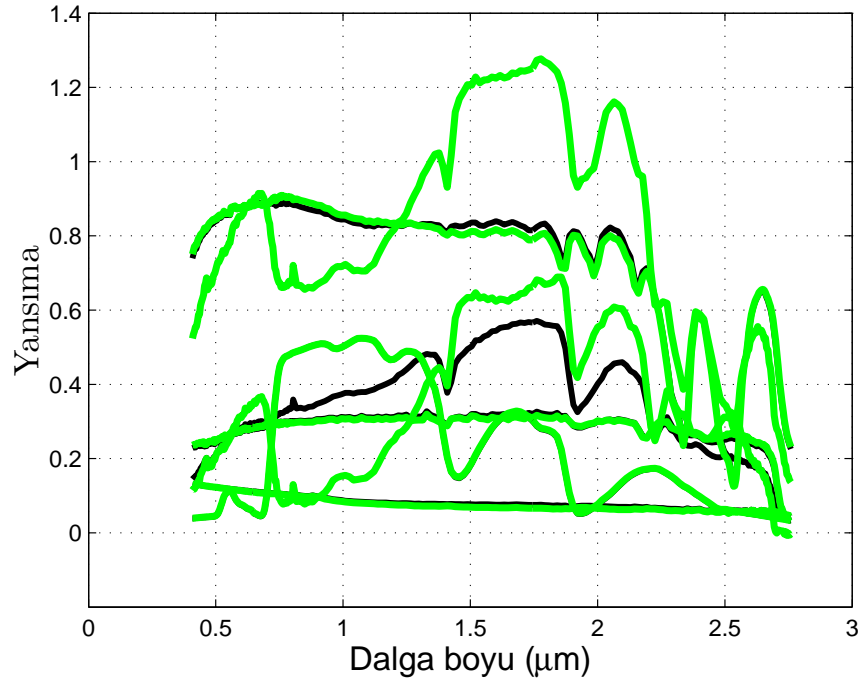
Çizelge 3.4. SPICE ve KİDDO algoritma çıktılarının karşılaştırılması [38]

Çizelge 3.4'te yer alan ilk satır, uç eleman sayısı 3 için algoritmaların uç eleman sayısını kaç kez doğru bulduğunu göstermektedir. Buna göre, regularizasyon parametresinin sıfıra yakın olduğu durumlarda, SPICE algoritması uç eleman sayısını 50 deneyden ancak 35'inde doğru olarak bulabilmiştir. Regülerizasyon arttığında bu durumun iyileştiği görülmektedir.


Çizelgedeki ikinci satır, uç eleman değerlerinin [0 – 1] aralığında bulunup bulunmadığını tespit etmek için yazılmıştır. Uç eleman matrisini oluşturan uç elemanların minimum yansıma değeri 0.333 iken algoritmalar tarafından bulunan ortalama minimum

değeri göstermektedir. Benzer şekilde, üçüncü satır, gerçek uç elemanların maksimum yansıma değeri 0.893 iken algoritmalar tarafından bulunan ortalama maksimum değeri göstermektedir. Buna göre, SPICE algoritması $[0 - 1]$ aralığının dışında da değerler verebilmektedir. Çizelgedeki dördüncü satır minimum değer kaç kez 0 dan küçük bulunduğunu, beşinci satır ise maksimum değer kaç kez 1 den büyük bulunduğunu göstermektedir. Dördüncü ve beşinci satırlarda yer alan *NAN* ifadeleri, SPICE algoritmasının amaç fonksiyonundaki değişimin tanımsız olduğu kaç denemenin meydana geldiğini belirtmektedir. Buna göre, regülarizasyon olmadığı durumda SPICE, 50 denemenin 13'ünde tanımsız uç eleman değerleri bulmuştur ve 3 denemede $[0 - 1]$ aralığının dışına çıkmıştır. Altıncı ve yedinci satırlar ortalama uzaklık ölçüm değerlerini ve standart sapmaları göstermektedir. Uzaklık ölçümü yapılırken SPICE algoritması için *NAN* veren denemeler çıkarılıp geriye kalan denemeler üzerinden ortalama değer hesabı yapılmıştır. Uzaklık değerleri incelendiğinde KİDDO'nun daha az bir hata ile uç eleman örüntülerini yakalayabildiği görülmektedir. Uç eleman sayısı 5 için aynı işlemler tekrarlanmış, Çizelge 3.4'te yer alan sonraki satırlar oluşturulmuştur.

SPICE ve KİDDO algoritmaları uç eleman tespitinde yüksek başarımlar elde etmişlerdir. SPICE algoritması 0 dan küçük ve 1 den büyük değerlere ulaşabilirken, KİDDO uç elemanları her zaman $[0 - 1]$ aralığında bulmuştur. SPICE algoritması, uç elemanları $[0 - 1]$ aralığında tespit edebilmesi için regülarizasyon parametresinin artırılması yani simpleks hacminin azaltılması gerekmektedir. Ancak bu parametrenin fazla artırılması gerçek uç eleman değerlerinin bulunamamasına yol açabilir. Regülarizasyon parametresi büyüdükçe SPICE ve KİDDO algoritmalarının benzer sonuç verdiği görülebilmektedir. Uzaklık ölçüm değerleri kıyaslandığında KİDDO algoritmasının daha az hata ile gerçek yansıma değerlerini izlediği görülmektedir. SPICE algoritmasından yüksek bulunduğu uzaklık ölçüm değerlerinde, SPICE algoritmasından *NAN* veren denemelerinin çıkartılarak ortalama alındığı unutulmamalıdır. SPICE ve KİDDO algoritmalarının materyallerin spektral imzalarını bulma değişimlerine sırasıyla Şekil 3.12'de ve Şekil 3.13'te yer verilmiştir. Yapılan deneyler SPICE algoritmasının başarılı olduğu noktalarda KİDDO algoritmasının da benzer başarıyı yakaladığını göstermiştir. Ayrıca KİDDO, uç eleman değerlerini $[0 - 1]$ aralığında daha az hata ile bulmuş, regülarizasyon parametresinden SPICE algoritması kadar etkilenmemiştir.



Şekil 3.12. Örnek SPICE algoritma çıktısı [38]



Şekil 3.13. Örnek KIDDO algoritma çıktısı [38]

Uç eleman sayısı 10 ve regülarizasyon parametresi $\mu = 0$ için SPICE algoritmasının örnek bir çıktısında algoritma uç eleman sayısını hatalı bir şekilde 6 bulmuş ayrıca fiziksel olarak mümkün olmayan spektral dağılımları 0' dan küçük ve 1' den büyük değerde bulmuştur. KİDDO algoritmasının örnek çıktısında, algoritma hem uç eleman sayısını 5 olarak doğru bulmuş hem de uç eleman değerlerini $[0 - 1]$ aralığında bularak spektral imzaları yakalayabilmiştir.

4. GERÇEK VERİLER ÜZERİNDE DENEYSEL ÇALIŞMALAR

Çalışmanın bu kısmında, tez kapsamında kullanılan gerçek hiperspektral veri setleri tanıtılmıştır. Bölüm 3'te anlatılan anomali tespit algoritmaları gerçek veriler üzerinde uygulanmış, algoritmaların veri içerisindeki hedefleri bulma başarımları ROC (Receiver Operating Characteristic) eğrileri kullanılarak karşılaştırılmıştır.

Tez kapsamında kullanılan hiperspektral görüntüler Telops'un Hyper-Cam LW (Uzun Dalga) hiperspektral kamerası ile elde edilmiştir. Hiperspektral kameranın bazı teknik özellikleri Çizelge 4.1'de gösterilmektedir. Görüntüler "Telops Reveal Air Calibrate" yazılımı ile kalibre edilmiştir. Seyrek çimen kaplı toprak yüzeye farklı fiziksel özellikteki malzemelerin serilmesi ile oluşturulan üç farklı sahne, SYP da farklı uzaklıkta konumlandırılan LWIR kamera ile görüntülenmiştir.

No	Özellik	Birim	Aralık Değeri
1	Spektral Aralık	nm	[7800 – 11500]
2	Spektral Çözünürlük	cm^{-1}	[0.25 – 150]
3	Uzamsal Çözünürlük	m	[0.11 – 1.07]
4	FPA Çerçeve Boyutu	Piksel	320x256
5	Piksel Boyutu	μm	30
6	Çalışma Sıcaklığı	$^{\circ}C$	(-20) - 40


Çizelge 4.1. Telops Hyper-Cam-LW kamerasının teknik özellikleri

4.1 Sahne 1

Sahne 1, içerisinde tahta sandık (H1), metal kova (H2), plastik bidon (H3) ve cam sürahi (H4) bulunan farklı özellikteki dört hedefin seyrek çimen kaplı toprak üzerine konulmasıyla oluşturulmuş ve görüntülenmiştir. Elde edilen hiperküp 150x320 pikselden ve 81 spektral banttandır. Sahne 1 verisinin iki boyutlu görüntüsü ve verinin temel doğrusu (ground truth) Şekil 4.1'de gösterilmektedir. Elde edilen hiperküpü iki boyuta indirgeyip görselleştirmek için her bir pikselin bütün dalga boylarında ortalaması alınmıştır.



(a)



(b)

Şekil 4.1. Sahne 1 hyperspektral verisinin (a) iki boyutlu görüntüsü, (b) temel doğrusu

4.1.1 Anomali Bulucuların Sahne 1 Üzerinde Uygulanması

Sahne 1 içerisindeki tahta sandık (H1) malzemesi anomali olamayacak kadar büyük bir hedeftir. Bu yüzden pencere tabanlı anomali bulucular için pencere büyüklükleri, sahnede ikinci büyük hedef olan plastik bidon (H3)'nun piksel alanı seçilmiştir. Seçilen iç pencere boyutu 25x31 iken dış pencere boyutu 49x61 olarak belirlenmiştir. Sahne 1 üzerinde anomali bulucuların eşikleme yapılmamış tespit çıktıları Şekil 4.2'de ve Şekil 4.3'te gösterilmiştir.

Tespit sonuçlarına bakıldığında LRX ve DWRX anomali bulucular, H2-H4 hedeflerini ol-

dukça az yanlış alarm üreterek bulmuşken GRX anomali bulucu fazlaca yanlış alarm üretmiştir. RXD-UTD anomali bulucu arka planı bastırarak hedeflerin belirginleşmesini sağlamıştır. SSRX anomali bulucu ise H1 hedefi de dahil bütün hedefleri tespit edebilmiştir.

Algoritmaların sahne 1 verisi üzerinde windows 8.1 core i7 2.4GHZ-16GB RAM-256SSD +1.5TB HDD-4GB özelliklerine sahip bir bilgisayarda harcadığı süreler Çizelge 4.2'de sunulmuştur. Harcanan süreler dikkate alındığında GRX ve RXD-UTD anomali bulucuların, diğer anomali buluculara kıyasla daha hızlı çalıştığı görülmektedir. KRX anomali bulucunun seçilen pencere boyutlarında tek bir test pikseli üzerinde gerekli Gram matrisini hesaplaması ve tersini alması için gereken süre yaklaşık 2 dakikadır. KRX'in görüntüdeki toplam 48000 piksel üzerinde harcayacağı süre dikkate alınmış, KRX anomali bulucunu sahne 1 verisi üzerinde kullanılmamıştır.

Anomali Bulucu	Harcanan Süre (Saniye)
GRX	0.443171
RXD-UTD	0.480788
SSRX	256.108270
LRX	303.109355
DWRX	475.239997
KRX	—

Çizelge 4.2. Anomali bulucuların sahne 1 verisi üzerinde harcadığı süreler

Algoritmaların hedefleri bulma başarımları ROC (Receiver Operating Characteristic) eğrileri kullanılarak Şekil 4.4'te karşılaştırılmıştır. ROC eğrileri, algoritma tespit çıktıları ile veride hedef noktaları içeren temel doğrunun karşılaştırılması sonucu elde edilmektedir. ROC performans değerlendirilmesinde kullanılan temel kavramlar şunlardır:

- **Doğru Pozitif (True Positive) [TP]:** Temel doğrudaki bir hedefin tespit edildiği durumdur.
- **Yanlış Pozitif (False Positive) [FP]:** Temel doğrudaki hedef bulunmayan alanda hedef tespit edildiği durumdur.



(a)



(b)




(c)

Şekil 4.2. Sahne 1 hiperspektral verisi üzerinde anomali tespit sonuçları (a) sahne 1'in iki boyutlu görüntüsü, (b) GRX çıktısı, (c) RXD-UTD çıktısı



(a)

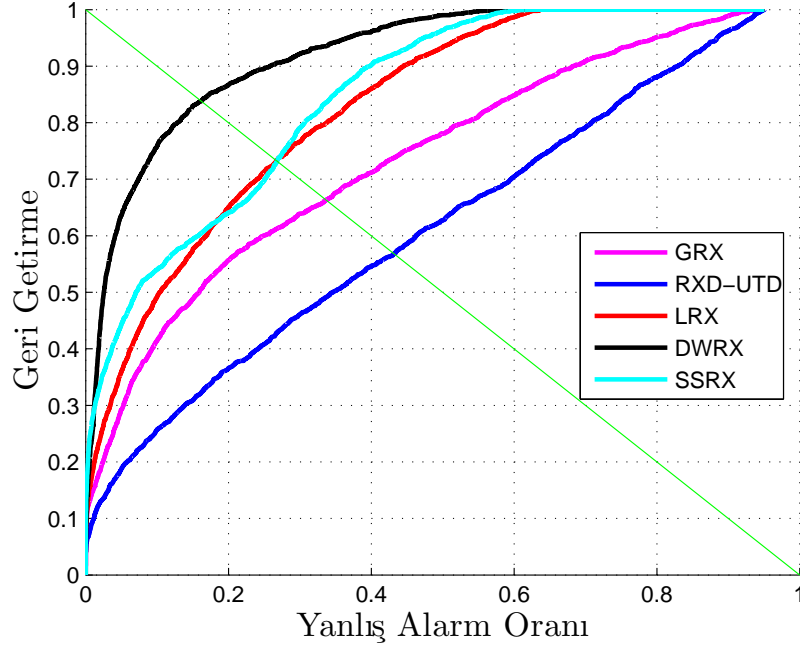


(b)



(c)

Şekil 4.3. Sahne 1 hiperspektral verisi üzerinde anomali tespit sonuçları (a) LRX çıktısı, (b) DWRX çıktısı, (c) SSRX çıktısı



Şekil 4.4. Sahne 1 hiperspektral verisi üzerinde anomali bulucuların hedefleri bulma başarımları

- **Yanlış Negatif (False Negative) [FN]:** Temel doğru olan bir hedefin tespit edilemediği durumdur.
- **Doğru Negatif (True Negative) [TN]:** Temel doğru hedef bulunmayan alanda hedef tespit edilmediği durumdur.
- **Geri Getirme (Recall):** Görüntüde bulunan hedef noktalarının kaçta kaçının tespit edildiğinin ölçüsüdür ve aşağıdaki şekilde hesaplanır:

$$\text{Geri Getirme} = \frac{TP}{TP + FN}$$

- **Yanlış Alarm Oranı (False Alarm Rate):** Birim alandaki Yanlış-Pozitif değeridir.

$$\text{Yanlış Alarm Oranı} = \frac{FP}{\text{Toplam alan}}$$

ROC eğrileri karşılaştırılan beş anomali bulucu içerisinde DWRX anomali bulucunun performansı ile öne çıktığı görülmektedir. DWRX anomali bulucu, %10 oranında yanlış alarm üreterek hedef noktaların yaklaşık %80'ini bulmuştur.

4.2 Sahne 2

Sahne 2 verisi halıfleks, laminant parke, polietilen köpük, muşamba, siyah ve gri alüminyum plaka malzemelerinin toprak yüzeye serilmesi ile oluşturulmuştur. Elde edilen hiperküp 180x266 pikselden ve 121 spektral banttandır. Oluşturulan sahne yaklaşık 50 m uzaklıktan görüntülenmiştir. Şekil 4.5'te verinin iki boyutlu görüntüsü gösterilmektedir.



Şekil 4.5. Sahne 2 hiperspektral verisinin iki boyutlu görüntüsü

4.2.1 Anomali Bulucuların Sahne 2 Üzerinde Uygulanması


Sahne 2 verisi üzerinde pencere tabanlı anomali bulucuları uygulamak için siyah alüminyum plakanın piksel alanı dikkate alınmıştır. Seçilen iç pencere boyutu 15x23 iken dış pencere boyutu 29x45 olarak belirlenmiştir. Sahne 2 verisi üzerinde yönbağımlı yayılım yöntemi yineleme sayısı 1 olacak şekilde uygulanmış, anomali bulucular yumuşatılmış veri üzerinde koşturulmuştur. Şekil 4.6'da sahne 2 üzerinde GRX çıktısı ve GRX'in eşikleme sonrası bulabildiği hedef noktalar gösterilmektedir.

Anomali bulucuların ürettiği değerlerin anomali olup olmadığını belirleyen eşik değeri aşağıdaki gibi hesaplanmıştır:

$$\text{Eşik değer} = \frac{\text{Temel doğruda hedef alanların piksel sayısı}}{\text{Görüntüdeki toplam piksel sayısı}} \quad (4.1)$$




(a)




(b)

Şekil 4.6. Sahne 2 hiperspektral verisi üzerinde (a) GRX çıktısı, (b) GRX çıktısının eşiklenmiş hali

Sahne 2 verisi için Eşitlik 4.1'de verilen ifadeye göre hesaplanan eşik değeri 0.0211'dir. GRX çıktısı bu değerin beş katı alınarak eşiklenmiştir. GRX anomali bulucu hedeflerin bazılarını bulabilmiş ancak oldukça fazla yanlış alarm üretmiştir. Şekil 4.7'de sahne 2 üzerinde RXD-UTD çıktısı ve RXD-UTD'nin eşikleme sonrası bulabildiği hedef noktalar gösterilmektedir. RXD-UTD çıktısı için seçilen eşik değeri GRX için kullanılan değerle aynıdır. Şekil 4.7'e bakıldığında arka planın bastırıldığı, hedeflerin belirginleştiği gö-



(a)



(b)

Şekil 4.7. Sahne 2 hiperspektral verisi üzerinde (a) RXD-UTD çıktısı, (b) RXD-UTD çıktısının eşiklenmiş hali

rılmektedir. Ancak RXD-UTD anomali bulucu da oldukça fazla yanlış alarm üretmiştir. Şekil 4.8'de sahne 2 verisi üzerinde LRX çıktısı ve LRX'in eşikleme sonrası bulabildiği hedef noktalar gösterilmektedir. LRX çıktısı için seçilen eşik değeri, sahne 2 verisi için Eşitlik 4.1'de hesaplanan değerin üç katı seçilmiştir. LRX anomali bulucu GRX ve RXD-UTD algoritmalarına kıyasla hedeflere ait daha fazla nokta tespit etmiştir. Ancak diğer algoritmalarda olduğu gibi oldukça fazla yanlış alarm üretmiştir. Şekil 4.9'da sahne 2

verisi üzerinde DWRX çıktısı ve DWRX'in eşikleme sonrası bulabildiği hedef noktalar gösterilmektedir. DWRX çıktısı için seçilen eşik değeri sahne 2 verisi için hesaplanan eşik değeri olarak belirlenmiştir. DWRX anomali bulucu diğer anomali buluculara kıyasla daha az sayıda yanlış alarm üretmiş, hedef noktaların neredeyse tamamını yakalayabilmiştir. Sahne 2 verisi üzerinde son olarak SSRX anomali bulucu oluşturulmuştur. Şekil 4.10'da sahne 2 verisi üzerinde SSRX çıktısı ve SSRX'in eşikleme sonrası bulabildiği hedef noktalar gösterilmektedir. SSRX çıktısı için seçilen eşik değeri sahne 2 verisi için hesaplanan eşik değeri olarak belirlenmiştir. SSRX anomali bulucu oldukça az sayıda yanlış alarm üreterek hedef noktaları tespit etmiştir. Algoritmalar için seçilen eşik değerleri, görsel olarak hedeflerin görülebileceği değeri olarak belirlenmiştir.

Anomali bulucuların Sahne 2 verisi üzerinde hedefleri bulma başarımları ROC (Receiver Operating Characteristic) eğrileri kullanılarak Şekil 4.11'de karşılaştırılmıştır. Karşılaştırılan beş anomali bulucu içerisinde SSRX anomali bulucunun performansı ile öne çıktığı görülmektedir. SSRX anomali bulucu %10 oranında yanlış alarm üreterek hedef noktaların yaklaşık % 90'ını bulabilmiştir.

4.3 Sahne 3


Sahne 3 verisi farklı özellikteki malzemelerin seyrek çimen kaplı toprak yüzeye serilmesi ile oluşturulmuştur. Elde edilen hiperküp 256x280 pikselden ve 120 spektral banttan oluşmaktadır. Oluşturulan sahne yaklaşık 20 m uzaklıktan görüntülenmiştir. Sahne 3 verisinin iki boyutlu görüntüsü ve veriye ait RGB görüntü Şekil 4.12'de gösterilmektedir. Elde edilen hiperküpü iki boyuta indirgeyip görselleştirmek için önceki sahnelerde olduğu gibi her bir pikselin bütün dalga boylarında ortalaması alınmıştır.

4.3.1 Reststrahlen Oran Tespit Algoritmasının Sahne 3 Üzerinde Uygulanması

Reststrahlen oran tespit algoritması sahne 3 verisi üzerinde uygulanmış Şekil 4.13'te gösterilen çıktılar elde edilmiştir. Sahne 3 verisi gün doğumunun hemen ardından çekilmiştir. Toprak yüzeyde bulunan malzemeler topraktan daha erken ısındığı için Reststrahlen oran tespit algoritmasında elde edilen S öznelik değerleri toprağa göre farklılık göstermiştir. Bu farklılık toprak yüzey üzerindeki malzemelerin ayırt edilebilmesine (Şekil 4.13 - (b)'de kırmızı renkli bölgeler) olanak sağlamıştır. Benzer şekilde Restst-



(a)




(b)

Şekil 4.8. Sahne 2 hiperspektral verisi üzerinde (a) LRX çıktısı, (b) LRX çıktısının eşiklenmiş hali

rahlen oran tespit algoritması ile toprak yüzeyde bulunan bitki örtüsü belirginleşmiştir (Şekil 4.13 - (b)'de sarı renkli bölgeler). Verinin radyans görüntüsünde tespit edilemeyen bitki örtüsü, Reststrahlen oran tespit çıktısında net bir şekilde ayırt edilebilir hale gelmiştir.



(a)



(b)

Şekil 4.9. Sahne 2 hyperspektral verisi üzerinde (a) DWRX çıktısı, (b) DWRX çıktısının eşiklenmiş hali

4.3.2 Anomali Bulucuların Sahne 3 Üzerinde Uygulanması

Anomali bulucuların şimdiye kadar anlatılan yapay ve gerçek veriler üzerindeki performansları karşılaştırıldığında, DWRX anomali bulucunun işlem yükü karmaşıklığının olmayışı ve gürültüye karşı kararlı yapısı ile ön plana çıktığı görülmektedir. Sahne 3 verisi üzerinde hedefleri bulmak için anomali bulucu olarak DWRX seçilmiştir. DWRX için



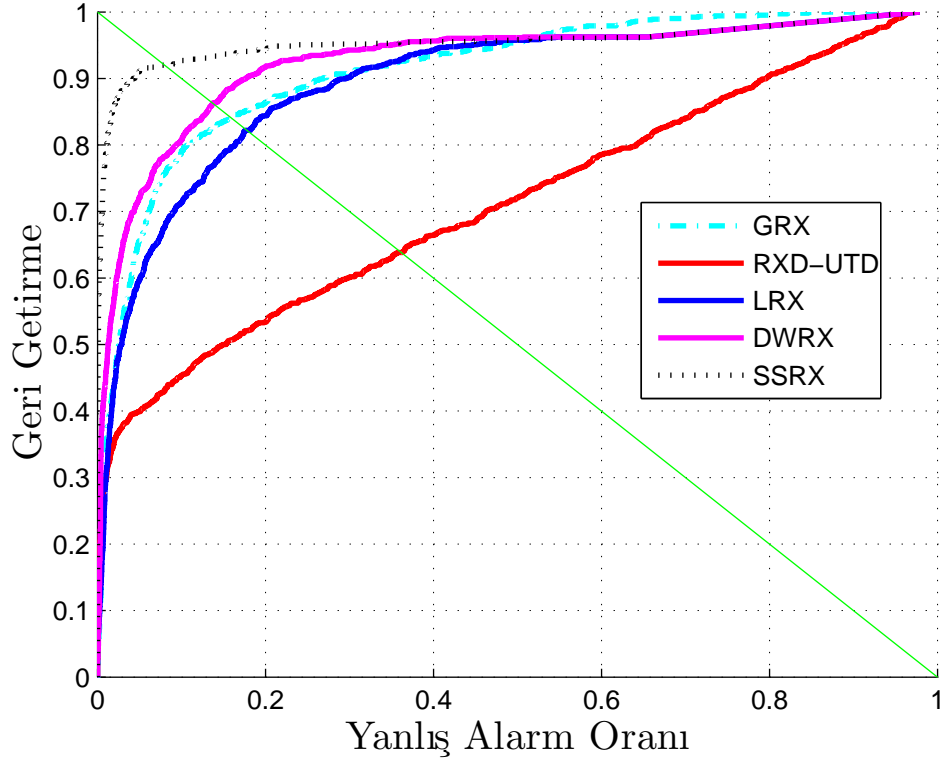
(a)



(b)

Şekil 4.10. Sahne 2 hyperspektral verisi üzerinde (a) SSRX çıktısı, (b) SSRX çıktısının eşiklenmiş hali

belirlenen iç pencere boyutu 23x23 iken dış pencere boyutu 45x45 olarak ayarlanmıştır. DWRX anomali bulucu sahne 3 üzerinde uygulanmadan önce sahne 3 radyans verisi salıcılık normalizasyonu yöntemi kullanılarak salıcılık ve sıcaklık bileşenlerine dönüştürülmüştür. Şekil 4.14'te sahne 3 verisinin salıcılık ve sıcaklık haritaları gösterilmektedir. Sıcaklık değerlerinde en yüksek sıcaklık yaklaşık 26 °C hesaplanırken en düşük sıcaklık yaklaşık 5 °C olarak hesaplanmıştır. Salıcılık verisini görselleştirmek için her bir




Şekil 4.11. Sahne 2 hiperspektral verisi üzerinde anomali bulucuların hedefleri bulma başarımları

pikselin bütün dalga boyları boyunca ortalaması alınmıştır. DWRX anomali tespit algoritması Şekil 4.14'te gösterilen iki boyutlu sıcaklık haritası üzerinde koşturulmuştur.

Sahne 3 verisi için Şekil 4.13'te gösterilen Reststrahlen oran tespit algoritma çıktısı ile DWRX çıktısı kullanılarak hedeflerin sınıflandırılması amaçlanmıştır. Algoritma çıktıları iki farklı öznelik olarak düşünülmüş, bu iki öznelik kullanılarak hedef noktaların veri içerisinde nasıl bir dağılım gösterdiği incelenmiştir. Sınıflandırma yapılırken özneliklerin etkisini eşit kılmak için her iki algoritma çıktısı da kendi içerisinde normalize edilmiştir. Normalize işlemi için algoritma skor değerleri ortalama değerlerinden çıkarılarak skor değerlerinin varyansına bölünmüştür. Normalize işleminin ardından yatay ekseninde Reststrahlen oran değerleri, dikey ekseninde ise DWRX skorları olacak şekilde iki boyutta hedef ve arka plan verilerinin dağılımı incelenmiştir. Şekil 4.15'ten de görülebileceği üzere hedef noktalar belirli bir bölgede kümelenmiştir. Şekil 4.17'de hedef noktalar için yatay ekseninde gösterilen Reststrahlen oran değerleri (2-4) aralığında eşiklendiğinde hedef noktaların arka plandan ayrıştığı görülmektedir. Şekil 4.17'de sahne

3 verisinin temel doğrusu ve Şekil 4.15'e göre eşiklenmiş çıktısı gösterilmektedir. Eşiklenmiş çıktıdan da görüleceği üzere hedeflere ait noktalar arka plandan ayrıştırılmıştır.

Sahne 3 verisinde yer alan çimlerden kaynaklanan yanlış alarmların bir kısmı elenemiştir. Bölüm 3'te anlatılan uç eleman analiz yöntemleri kullanılarak sahne 3 verisindeki çimlerden kaynaklanan yanlış alarmların elenmesi amaçlanmıştır. Bölüm 3'te yapay veriler üzerinde karşılaştırılması yapılan uç eleman analiz yöntemlerinden KİDDO algoritması sahne 3 salıcılık verisi üzerinde koşturulmuştur. KİDDO algoritması için sahnedeki uç eleman sayısı 6 olarak ilklendirilmiş ve simpleks boyutunu sınırlandıran regülarizasyon parametresi $\mu = 0$ olarak alınmıştır. KİDDO algoritma çıktısında elde edilen altı bolluk haritası karşılaştırılmış, verideki çimleri en iyi şekilde gösteren bolluk haritası seçilmiştir. Seçilen bolluk haritası Şekil 4.18'de gösterilmektedir. Şekil 4.17'de gösterilen eşiklenmiş çıktıda yanlış alarmları azaltmak için sahne 3 verisinin DWRX çıktısı ile Şekil 4.18'de gösterilen bolluk haritası iki farklı öznitelik olarak düşünülmüştür. Bu iki öznitelik kullanılarak yanlış alarmları azaltmak için Reststrahlen oran tespit algoritma çıktısı ile eşiklenmiş hedef noktaların veri içerisinde nasıl bir dağılım gösterdiği incelenmiştir. Yatay ekseninde bolluk değerleri dikey ekseninde ise DWRX skorları olacak şekilde iki boyutta hedef ve arka plan verilerinin dağılımı Şekil 4.16'da gösterilmektedir. Yanlış alarmları azaltmak için Şekil 4.16'da yatay ekseninde gösterilen bolluk değerleri 0.3 değeri ve üzeri için eşiklenmiştir. Şekil 4.19'da görüldüğü üzere çimlerden kaynaklı yanlış alarmların bir kısmının elenmesi sağlanmıştır.




(a)




(b)

Şekil 4.12. Sahne 3 hiperspektral verisinin (a) iki boyutlu görüntüsü, (b) renkli görüntüsü




(a)




(b)

Şekil 4.13. Sahne 3 hiperspektral verisinin (a) radyans görüntüsü, (b) Reststrahlen oran tespit algoritma çıktısı




(a)




(b)


Şekil 4.14. Sahne 3 radyan verisinin salıcılık normalizasyonu sonrası elde edilen (a) salıcılık görüntüsü, (b) sıcaklık haritası



Şekil 4.15. İki öznelik uzayında sahne 3 hiperspektral verisi üzerinde hedef noktaların gösterimi



Şekil 4.16. İki öznelik uzayında sahne 3 hiperspektral verisi üzerinde yanlış alarmların gösterimi




(a)



(b)

Şekil 4.17. Sahne 3 hiperspektral verisinin (a) temel doğrusu (b) hedef noktaların sınıflandırılması



Şekil 4.18. KIDDO algoritma çıktılarından seçilen bolluk haritası



Şekil 4.19. Sahne 3 hiperspektral verisi için bolluk haritası kullanılarak yanlış alarmların elenmesi

5. SONUÇLAR

Bu tez kapsamında hiperspektral görüntü işleme alanında en önemli araştırma konuları arasında olan, anomali tespiti ve uç eleman analizi konuları üzerine çalışmalar yapılmıştır. Çalışmada öncelikle, arka planı modelleyerek veri içerisinde muhtemel hedef noktaları işaret eden anomali bölgelerini bulmaya yönelik altı anomali tespit algoritması yapay veriler üzerinde uygulanmıştır. Anomali bulucuların performansını etkileyen değişkenler detaylı bir şekilde incelenmiş, algoritmaların hedefleri bulma başarımları karşılaştırılmıştır. Karşılaştırılan modelleme tabanlı altı anomali bulucu içerisinde, DWRX algoritmasının fazla işlem yükü gerektirmediği; az sayıda yanlış alarm üreterek hedef noktaları yüksek başarımla tespit ettiği görülmüştür. Benzer şekilde modelleme tabanlı anomali tespit algoritmaları gerçek LWIR hiperspektral görüntüler üzerinde uygulanmış, anomali bulucular içerisinde DWRX anomali bulucunun performansı ile ön plana çıktığı görülmüştür. Algoritmaların eşiklenmemiş hedef tespit çıktıları incelendiğinde, DWRX anomali bulucunun pencere boyutunu verideki olası hedef boyutunda seçilmesi durumunda, verideki hedef boyutunun bütününden ziyade hedeflerin merkez noktalarının tespit edildiği görülmüştür. Hedeflerin bütününden ziyade merkez noktaları ile ilgilenilen uygulamalarda bu önemli sonucun işe yarayabileceği öngörülmüştür.

LWIR görüntülerde görülen Reststrahlen etkisinden yola çıkılarak, toprak yüzeyindeki farklılıkları tespit etmek için geliştirilmiş Reststrahlen oran tespit algoritması ile toprak yüzeyine serili malzemelerin net bir şekilde toprak yüzeyinden ayrıştığı deneysel sonuçlarla ortaya konulmuştur.

Tez kapsamında çalışılmış diğer konu ise hiperspektral görüntülerde uç eleman analizidir. Uç eleman analizi ile anomali tespiti sonrası elenemeyen yanlış alarmların elenmesi amaçlanmıştır. Hiperspektral verilerde uç eleman çıkarımı sağlayan KİDDO ve SPICE algoritmaları gerçek veriler üzerinde uygulanmadan önce ASTER spektral kütüphanesinden oluşturulan yapay veriler üzerinde uygulanmış, yapay veri setleri üzerinde algoritma performansları karşılaştırılmıştır. Uç elemanlara $[0 - 1]$ aralığında olma kısıtı koyan KİDDO algoritmasının performansı ile de ön plana çıktığı tespit edilmiştir.

Çalışmaların son bölümünde, diğer modelleme tabanlı anomali buluculara kıyasla he-

def tespit başarımı ile ön plana çıkan DWRX anomali tespit bulucu ile KİDDO uç eleman tespit algoritması sahne 3 verisi üzerinde uygulanmak üzere seçilmiştir. Sahne 3 radyans verisi salıcılık normalizasyonu yöntemi ile sıcaklık ve salıcılık bileşenlerine dönüştürülmüş, sıcaklık haritası üzerinde DWRX algoritması koşturulmuştur. DWRX algoritma çıktısı ile sahne 3 verisi üzerinde denenen Reststrahlen oran tespit algoritma çıktısı iki farklı öznitelik olarak kullanılmış, Reststrahlen oran tespit algoritma çıktısı üzerinden hedeflerin arka plandan ayırt edilmesi sağlanmıştır. Reststrahlen oran tespit algoritma çıktısının bu iki öznitelik kullanılarak elde edilen sınıflandırılmış çıktısında bütün hedeflerin tespit edilebildiği ancak verideki vejetasyondan kaynaklı yanlış alarmların bir kısmının elenemediği görülmüştür. Uç eleman analiz yöntemleri kullanılarak yanlış alarmlara sebebiyet veren uç elemanların bulunması hedeflenmiş, bu doğrultuda KİDDO algoritması kullanılarak yanlış alarmların çoğuna sebebiyet veren vejetasyona ait bolluk haritası çıkarılmıştır. Yanlış alarmların nasıl bir dağılım gösterdiğini incelemek için, sahne 3 verisine ait sıcaklık haritası üzerinde koşturulan DWRX anomali tespit çıktısı ile KİDDO algoritma çıktısından elde edilen bolluk haritası kullanılmıştır. Bu iki öznitelik ile Reststrahlen oran tespit algoritmasının eleyemediği yanlış alarmların bir kısmının elendiği görülmüştür.

Sonuç olarak, gerçek ve yapay veriler üzerinde oldukça az sayıda yanlış alarm üreterek yüksek başarımla elde etmesi açısından DWRX'in etkin bir modelleme tabanlı anomali bulucu olduğunu görülmüştür. Benzer şekilde, Reststrahlen etkisinden yola çıkılarak geliştirilmiş Reststrahlen oran tespit algoritmasının, LWIR görüntüler üzerinde yapılacak hedef tespit çalışmalarında önemli bir rol oynadığı ortaya konulmuştur.

Tez kapsamında, bantlar arası doğrusal olmayan ilişkiyi inceleyen Çekirdek RX anomali bulucu, spektral bant sayısından kaynaklanan işlem yükünden dolayı gerçek veriler üzerinde kullanılamamıştır. Gelecek çalışmalarda, Çekirdek RX'in uygulanabilmesi için bant azaltma yöntemleri incelenebilir. Anomali tespiti sonrasında oluşan yanlış alarmların giderilebilmesi için KİDDO uç eleman analiz yöntemi kullanılmıştır. Buna ek olarak yanlış alarmların azaltılması için hedef spektralleri elde edilerek spektral eşleme yöntemleri üzerinde çalışılabilir.

KAYNAKLAR

- [1] Ateş S., Demir E., Uzaktan Algılamada çözünürlüğe bağlı veri kazanımı potansiyeli, *12. Türkiye Harita Bilimsel ve Teknik Kurultayı*, Ankara, Türkiye, **2009**.
- [2] Düzgün Ş., Uzaktan Algılamada Veri, *Türkiye Bilimler Akademisi*, **2015**, http://www.acikders.org.tr/pluginfile.php/633/mod_resource/content/0/Ders_Notlari/Unite2_Uzaktan_Algilamaya_Veri.pdf
- [3] Smith R. B., Introduction to Hyperspectral Imaging, <http://www.microimages.html> (Nisan, **2015**).
- [4] Gerçek D., Çeşmeci D., Güllü M. K., Ertürk A., Ertürk S., Hiperspektral görüntüleme ve görüntü işlemenin bugünü, yakın geleceği ve mevcut araştırma eğilimleri, *XYZ Dergi*, 18 - 25, **2013**.
- [5] Dalton S. R., *Algorithm Development for Hyperspectral Anomaly Detection*, Dissertation Thesis, University of Maryland, Maryland, **2008**.
- [6] Manolakis D., Marden D., Shaw G. A., Hyperspectral image processing for automatic target detection applications, *Lincoln Laboratory Journal*, 14, 79 - 116, **2003**.
- [7] Binol H., *Termal ve Hiperspektral Görüntülerde Hareketli Hedef Tespiti ve İzlenmesi*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul, **2012**.
- [8] Specim Spectral Imaging, <http://www.specim.fi/index.php/products/industrial/spectral-cameras/vis-vnir.html> (Nisan, **2015**).
- [9] Specim Spectral Imaging, <http://www.specim.fi/index.php/products/industrial/spectral-cameras/swir.html> (Nisan, **2015**).
- [10] Specim Spectral Imaging, <http://www.specim.fi/index.php/products/industrial/spectral-cameras/mwir.html> (Nisan, **2015**).
- [11] Specim Spectral Imaging, <http://www.specim.fi/index.php/products/industrial/spectral-cameras/lwir.html> (Nisan, **2015**).
- [12] Shippert P., Digital Number, Radiance, and Reflectance, <http://www.exelisvis.com/Home/NewsUpdates/TabId/170/ArtMID/735/ArticleID/13592/Digital-Number-Radiance-and-Reflectance.html> (Haziran, **2015**).
- [13] Richards, J. A., Xiuping J., *Remote Sensing Digital Image Analysis*, 4. Baskı, Springer, Berlin, **1999**.
- [14] Eismann, T. M., *Hyperspectral remote sensing*, SPIE, **2012**.
- [15] Marwaha R., Kumar A., Raju P. L. N., Murthy K., Target detection algorithm for airborne thermal hyperspectral data, *Remote Sensing and Spatial Information Sciences*, 8, 827 - 832, **2014**.

- [16] Ratto C. R., Morton K. D., Collins L. M., Torrione P. A., Bayesian context-dependent learning for anomaly classification in hyperspectral imagery, *Geoscience and Remote Sensing, IEEE Transactions on*, 52, 1969 - 1981, **2014**.
- [17] Zare A., Bolton J., Gader P., Schatten M., Vegetation mapping for landmine detection using long-wave hyperspectral imagery, *Geoscience and Remote Sensing, IEEE Transactions*, 46, 172 - 178, **2008**.
- [18] Kealy P. S., Hook S. J., Separating temperature and emissivity in thermal infrared multispectral scanner data: Implications for recovering land surface temperatures, *Geoscience and Remote Sensing, IEEE Transactions on*, 31, 6, 1155 - 1164, **1993**.
- [19] Düzgün Ş., Uzaktan Algılamaya Giriş, *Türkiye Bilimler Akademisi*, **2015**, http://www.http://www.acikders.org.tr/pluginfile.php/632/mod_resource/content/0/Ders_Notlari/Unite1_Uzaktan_Algilamaya_Giris.pdf
- [20] Keshava N., Mustard J. F., Spectral unmixing, *Signal Processing Magazine, IEEE*, 19, 44 - 57, **2002**.
- [21] Zare A., *Hyperspectral Endmember Detection And Band Selection Using Bayesian Methods*, Dissertation Thesis, University of Florida, Florida, **2008**.
- [22] Baldrige A., Hook S., Grove C., Rivera G., The ASTER spectral library version 2.0, *Remote Sensing of Environment*, 113, 711 - 715, **2009**.
- [23] Gao L., Zhang B., Chen Z., Lei L., Study on the issue of noise estimation in dimension reduction of hyperspectral images, *Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 1 - 4, **2011**.
- [24] Prasath S., Singh A., Multispectral image denoising by well-posed anisotropic diffusion scheme with channel coupling, *International Journal of Remote Sensing*, 31, 2091 - 2099, **2010**.
- [25] Perona P., Malik J., Scale-space and edge detection using anisotropic diffusion, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12, 7, 629 - 639, **1990**.
- [26] Reed, I. S., Xiaoli, Y., Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution, *Acoustics, Speech and Signal Processing, IEEE Transactions*, 38, 10, 1760 - 1770, **1990**.
- [27] Matteoli, S., Diani, M., Corsini G., A tutorial overview of anomaly detection in hyperspectral images, *Aerospace and Electronic Systems Magazine, IEEE*, 25, 7, 5 - 28, **2010**.
- [28] Chang, C., Chiang, S. S., Anomaly detection and classification for hyperspectral imagery, *Geoscience and Remote Sensing*, 40, 6, 1314 - 1325, **2002**.

- [29] Ashton, E. A., Schaum, A., Algorithms for the detection of sub-pixel targets in multispectral imagery, *Photogrammetric Engineering & Remote Sensing*, 64, 7, 723 - 731, **1998**.
- [30] Liu, W., Chang, C., A nested spatial window-based approach to target detection for hyperspectral imagery, *Geoscience and Remote Sensing Symposium, IEEE International, IGARSS'04*, **2004**.
- [31] Nasrabadi N., Hyperspectral target detection: An overview of current and future challenges, *Signal Processing Magazine, IEEE*, 31, 34 - 44, **2014**.
- [32] Kwon K., Nasrabadi N., Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery, *Geoscience and Remote Sensing, IEEE Transactions*, 43, 388 - 397, **2005**.
- [33] Scholköpfung B., Smola A. J., *Learning with kernels: support vector machines, regularization, optimization, and beyond*, MIT press, **2002**.
- [34] Küçük S., Yüksel S. E., Comparison of Rx-Based Anomaly Detectors on Synthetic and Real Hyperspectral Data, *7th Workshop on Hyperspectral Image and Signal Processing Evolution in Remote Sensing (WHISPERS)*, Tokyo, Japan, **2015**.
- [35] Hubbard W., Bishop G., Gagnon J. P., Lagueux P., Hannuna S., Campbell N., Detection of disturbed earth using hyperspectral LWIR imaging data, *in Proc. SPIE*, 7835, **2010**.
- [36] Johnson J. R., Lucey P. G., Horton K. A., Winter E. M., Infrared measurements of pristine and disturbed soils 1. Spectral contrast differences between field and laboratory data, *Elsevier*, 64, 34 - 46 **1998**.
- [37] Kenton A. C., Schwartz C. R., Horvath R., Cederquist J. N., Nooden L. S., Twede D. R., Nunez J. A., Wright J. A., Salisbury J. W., Montavon K., Detection of land mines with hyperspectral data, *International Society for Optics and Photonics*, 99, 917 - 928, **1999**.
- [38] Küçük S., Yüksel S. E., Hiperspektral Görüntülerde Son Eleman Tespiti, *7. Savunma Teknolojileri Kongresi (SAVTEK)*, Ankara, Türkiye, **2014**.
- [39] Ma W., Bioucas-Dias J., Gader P., Chan T., Gillis N., Plaza A., A signal processing perspective on hyperspectral unmixing, *IEEE Signal Processing Mag.*, 31, 67 - 81, **2013**.
- [40] Berman M., Kiiveri H., Lagerstrom R., Ernst A., Dunne R., Huntington J. F., ICE: A statistical approach to identifying endmembers in hyperspectral images, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 2085 - 2095, **2004**.
- [41] Yüksel S. E., Hiperspektral görüntülerde son elemanların geliştirilmiş kısıtlı optimizasyonla bulunması, *Signal Processing and Communications Applications Conference, Proceedings of the IEEE*, **2014**.

- [42] Zare A., Gader P., SPICE: A sparsity promoting iterated constrained endmember extraction algorithm with applications to landmine detection from hyperspectral imagery, *in Detection and Remediation Technologies for Mines and Minelike Targets XII*, 6553, 55319 - 55319, **2007**.

EKLER

EK 1: SÖZLÜK DİZİNİ

Alıcı İşlem Karakteristikleri	: Receiver Operating Characteristic
Alt Uzay	: Subspace
Aradeğerleme	: Interpolation
Arka Plan	: Background
Artık Kareler Toplamı	: Residual Sum of Squares
Atmosferik Düzeltme	: Atmospheric Correction
Ayrık Numara	: Digital Number
Çekirdek Fonksiyonu	: Kernel Function
Çekirdek Teknikleri	: Kernel Tricks
Çok Bantlı	: Multispectral
Değişinti	: Variance
Dışbükey Geometri	: Convex Geometry
Doğru Negatif	: True Negative
Doğru Pozitif	: True Positive
Eniyileme	: Optimization
Eniyi Olabilirlik	: Maximum Likelihood
Enküçükleme	: Minimization
Eşikleme	: Thresholding
Eşmerkezli	: Concentric
Evrişim	: Convolution
Geometrik Düzeltme	: Geometric Correction
Geri Getirme	: Recall
Görünür ve Yakın Kızılötesi	: Visible & Near Infrared
Hiperküp	: Hypercube
İşaret Gürültü Oranı	: Signal to Noise Ratio
Kara cisim	: Blackbody
Katışım Pikseli	: Mixed Pixel
Kazanç	: Gain

Kısa Dalga Kızılötesi	:	Short-Wave Infrared
Koruma Bandı	:	Guard Band
Merkeze Çekilmiş	:	Centered
Minimum Gürültü Kesri	:	Minimum Noise Fraction
Nokta Çarpım	:	Dot Product
Orta Dalga Kızılötesi	:	Mid-Wave Infrared
Ortak Değişinti	:	Covariance
Ön İşleme	:	Preprocessing
Özdeğer	:	Eigenvalue
Özvektör	:	Eigenvector
Pozitif Tanımlı	:	Positive Definite
Saf Piksel	:	Pure Pixel
Salıcılık	:	Emissivity
Salıcılık Normalizasyonu	:	Emissivity Normalization
Sapma	:	Bias
Seyreklik Teşvik Eden Terim	:	Sparsity Promoting Term
Sözde Ters	:	Pseudo Inverse
Temel Doğru	:	Ground Truth
Temel Bileşen Analizi	:	Principal Component Analysis
Uç Eleman	:	Endmember
Uzaktan Algılama	:	Remote Sensing
Uzun Dalga Kızılötesi	:	Long-Wave Infrared
Yankılanma	:	Resonance
Yanlış Alarm Oranı	:	False Alarm Rate
Yanlış Negatif	:	False Negative
Yanlış Pozitif	:	False Positive
Yansıma	:	Reflectance
Yayıma	:	Emission
Yerel	:	Local
Yinelemeli Kısıtlı Uç Elemanlar	:	Iterated Constrained Endmembers
Yön Bağımlı	:	Anisotropic

EK 2: SAVTEK 2014 BİLDİRİSİ

HİPERSPEKTRAL GÖRÜNTÜLERDE SON ELEMAN TESPİTİ

Sefa KÜÇÜK ^(a), Seniha Esen YÜKSEL ^(b)

^(a) Hacettepe Üniversitesi, Elektrik ve Elektronik Müh. Böl., 06800, Ankara,
skucuk@ee.hacettepe.edu.tr

^(b) Yrd. Doç. Dr. Hacettepe Üniversitesi, Elektrik ve Elektronik Müh. Böl., 06800, Ankara,
eyuksel@ee.hacettepe.edu.tr

ÖZET

Bu çalışmada, hiperspektral görüntülerde son eleman olarak adlandırılan saf materyallere ait spektral imzaların bulunması için SPICE (Sparsity Promoting Iterated Constrained Endmember) ve KIDDO (Kısıtlı İkinci Dereceden Denklemlerle Optimizasyon) algoritmaları karşılaştırılmıştır. Algoritmalar elli kez koşturulmuş, algoritmaların buldukları son eleman değerleri ile gerçek son eleman değerleri arasındaki Öklid ve Korelasyon uzaklıkları hesaplanmıştır. Aynı zamanda elli deney içerisinde son eleman sayılarının kaç kez doğru bulunduğu belirlenmiştir. Çalışmalar için ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) spektral kütüphanesi kullanılmıştır.

Anahtar Kelimeler: Hiperspektral Görüntüleme, Son Eleman, Öklid ve Korelasyon Uzaklıkları

ABSTRACT

In this study, the performance of SPICE (Sparsity Promoting Iterated Constrained Endmember) and KIDDO algorithms are compared to extract spectral signatures within hyperspectral images. The algorithms are repeated fifty times; and Euclidean and Correlation distances between true endmembers and estimated endmembers are calculated. Also, among these fifty experiments, the number of times the correct number of endmembers is found is determined. ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) spectral library is used for studies.

Keywords: Hyperspectral Imaging, Endmember, Euclidean and Correlation Distances

Doğrusal karışım modeli olarak da bilinen konveks geometri modeli, bir görüntüyü son elemanların katışım katsayıları ile orantılı olarak modeller [3, 4]:

$$\mathbf{x}_i = \sum_{k=1}^M p_{ik} \mathbf{E}_k + \varepsilon_i \quad i = 1, \dots, N \quad (1)$$

Burada N piksel sayısı, M son eleman sayısı, ε_i hata terimi ve \mathbf{x}_i görüntüde i. piksele denk gelen d hiperspektral bant sayısını olmak üzere d x 1 vektörü temsil etmektedir. \mathbf{E} son elemanların yan yana dizilmesinden oluşan d x M boyutundaki son eleman matrisidir. Karışım oranı p_{ik} , k. son elemanın i. pikselde bulunma oranıdır. Bu oranlardan oluşturulan \mathbf{p}_i i. pikseldeki son elemanların 1 x M boyutundaki katışım (bolluk) vektörüdür ve

$$p_{ik} \geq 0, \forall_k = 1, \dots, M, \sum_{k=1}^M p_{ik} = 1 \quad (2)$$

ile sınırlanır. Birçok spektral katışım analiz algoritması ölçülen ve kestirilen değerler arasındaki hatayı minimize ederek katışım oranlarını belirler.

$$J = \sum_{i=1}^N \|\mathbf{x}_i - \mathbf{E}\mathbf{p}_i\|^2 \quad (3)$$

Örneğin, yinelemeli kısıtlı son elemanlar algoritması (Iterated Constrained Endmembers - ICE) [5] ve seyreklik teşvik eden yinelemeli kısıtlı son elemanlar algoritması (Sparsity Promoting Iterated Constrained Endmember - SPICE) [6] doğrusal katışım modelini iteratif bir şekilde çözmek için geliştirilmiş saf piksel gerektirmeyen kuadratik programlama yöntemleridir. ICE ve SPICE algoritmaları, son elemanları bulmak için eşitlik 2'de verilen kısıtlamaları kullanarak eşitlik 3'te verilen denklemin en küçük kareler minimizasyonu yöntemini ile çözer. ICE algoritmasında minimize edilmek istenen amaç fonksiyonu

$$J_{\text{reg}} = (1 - \mu) \frac{J}{N} + \mu V \quad (4)$$

Burada μ , (0,1) aralığında regülarizasyon parametresidir, V de düzenleştirme terimidir:

$$V = \frac{1}{M(M-1)} \sum_{k=1}^{M-1} \sum_{l=k+1}^M (\mathbf{E}_k - \mathbf{E}_l)^T (\mathbf{E}_k - \mathbf{E}_l) \quad (5)$$


Çözüm tek değildir, tüm verileri kapsayan herhangi bir simpleks bu denklemin sağlayabilmektedir. V terimi bu simplekslerden en küçüğünün tercih edilmesini sağlamaktadır. Şekil 1(b)'de bütün verileri kapsayan iki simpleks gösterilmiştir. SPICE algoritması eşitlik 4'de seyrekliği teşvik edici bir terim ekler ve denklem

$$J_{\text{reg}} = (1 - \mu) \frac{J}{N} + \mu V + \text{SPT} \quad (6)$$

halini alır. Böylece eğer bir son elemanın katışım oranı sıfıra giderse bu son eleman elenir. SPICE algoritması katışım vektörlerini sözde-ters yöntemi ile hesaplamaktadır. Ancak sözde-ters yöntemi fiziksel olarak mümkün olmayan negatif değerler verebilmektedir. KİDDO (Kısıtlı İkinci Dereceden Denklemlerle Optimizasyon) algoritması [7] son elemanlara [0-1] aralığında olma kısıdını koyarak fiziksel olarak mümkün olmayan bu problemi giderebilmektedir. KİDDO algoritması, SPICE algoritmasının aksine sözde-ters yöntemini kullanmaz, katışım vektörlerini kuadratik programlama ile bulacak şekilde formalize eder.

Çalışmada, ASTER spektral kütüphanesindeki verilerden 5 farklı materyal seçilmiştir. Seçilen materyallerin aynı dalga boyu bandında olması için reflektans değerlerine ara değer kestirimi (interpolasyon) işlemi uygulanmıştır. Bu işlem sonucunda seçilen materyallere ait 0,4-2,6 μm dalga boyu aralığında 258 banttan oluşan reflektans değerleri elde edilmiştir. Bu materyallerin spektral imzaları Şekil 2(a)'da gösterilmektedir.

Daha sonra, eşitlik 3'te yer alan doğrusal karışım modeli kullanılarak karışım verisi hazırlanmıştır. Bunun için, öncelikle seçilen spektral imzalardan \mathbf{E} son eleman matrisi oluşturulmuştur. Daha sonra da Dirichlet dağılımı kullanılarak katsayılar matrisi elde edilmiştir. Eşitlik 1'de yer alan \mathbf{x}_i matrisini oluşturmak için 400 adet Dirichlet katsayısı üretilmiş, oluşturulan \mathbf{E} son eleman matrisi ile çarpılmıştır. Karışım ile oluşan veriler Şekil 2(b)'de gösterilmektedir.



Şekil 2. (a) Son eleman matrisi içerisinde yer alan 5 farklı materyale ait spektral imzalar, (b) Dirichlet dağılımı kullanılarak üretilen veriler.

Oluşturulan bu veriyi son elemanlarına ayrıştırabilmek ve karışımındaki son eleman sayısının doğru olarak bulunup bulunmadığını test etmek amacıyla SPICE ve KİDDO algoritmaları uygulanmıştır. Algoritmaların kestirdikleri spektral imza değerleri ile ASTER kütüphanesinin sunduğu gerçek değerler iki farklı uzaklık ölçüm yöntemi ile karşılaştırılmıştır. Uzaklık ölçüm yöntemi olarak öncelikle Öklid uzaklığı kullanılmıştır. Ancak Öklid uzaklığı yüksek boyutlu verilerde yetersiz kaldığı için alternatif olarak Korelasyon uzaklığı tercih

edilmiştir. Çizelge 1’de kullanılan uzaklık ölçüm yöntemlerinin formüsel ifadeleri yer almaktadır.

Çizelge 1. Uzaklık ölçüm yöntemleri

Uzaklık Ölçüm Yöntemi	Formülü
Öklid Uzaklığı	$d_{st}^2 = (x_s - x_t)(x_s - x_t)^T$
Korelasyon Uzaklığı	$d_{st}^2 = 1 - \frac{(x_s - \bar{x}_s)(x_t - \bar{x}_t)^T}{\sqrt{(x_s - \bar{x}_s)(x_s - \bar{x}_s)^T} \sqrt{(x_t - \bar{x}_t)(x_t - \bar{x}_t)^T}}$

3. SONUÇ

Çalışmada, SPICE ve KİDDO algoritmaları için aynı parametreler kullanılarak karşılaştırma yapılmıştır. İlk olarak, algoritmalara ortamda bulunan son eleman sayısı 10 olarak girilmiş ve regülarizasyon parametresi $\mu=0$ olarak alınmıştır. Regülarizasyon parametresi tüm verileri içeren simpleksin boyutunu sınırlandıran parametredir ve $\mu=0$ durumu simpleks hacminin sınırlandırılmadığını gösterir. Sonrasında regülarizasyon parametresi sırasıyla, $\mu=0.0001$ ve $\mu=0.01$ olarak artırılmış simpleks hacmi üzerinde düzenleme işleminin etkisi incelenmiştir. Bu işlemler 50 kez tekrar edilmiş, elde edilen sonuçların ortalama değerleri alınarak Çizelge 2’de sunulmuştur. Tablonun üst kısmında, üç son eleman için üretilmiş veriler; alt kısmında ise beş son eleman için üretilmiş veriler kullanılmıştır.

Çizelge 2’de yer alan ilk satır, son eleman sayısı 3 için algoritmaların son eleman sayısını kaç kez doğru bulduğunu göstermektedir. Buna göre, regularizasyon parametresinin sıfıra yakın olduğu durumlarda, SPICE algoritması son eleman sayısını 50 deneyden ancak 35’inde doğru olarak bulabilmiştir. Regülarizasyon arttığında bu durum düzelmektedir.

Çizelgedeki ikinci satır, son eleman değerlerinin [0 1] aralığında bulunup bulunmadığını tesbit için yazılmıştır. Son eleman matrisini oluşturan son elemanların minimum reflektans değeri 0.333 iken algoritmalar tarafından bulunan ortalama minimum değeri göstermektedir. Benzer şekilde, üçüncü satır, gerçek son elemanların maksimum reflektans değeri 0.893 iken algoritmalar tarafından bulunan ortalama maksimum değeri göstermektedir. Buna göre, SPICE algoritması [0 1] aralığının dışında da değerler verebilmektedir. Tablodaki dördüncü satır minimum değer kaç kez 0’dan küçük bulunduğunu, beşinci satır ise maksimum değer kaç kez 1’den büyük bulunduğunu göstermektedir. Dördüncü ve beşinci satırlarda yer alan “NAN” ifadeleri, SPICE algoritmasının amaç fonksiyonundaki değişimin tanımsız

olduğu kaç denemenin meydana geldiği belirtmektedir. Altıncı ve yedinci satırlar ortalama uzaklık ölçüm değerlerini ve standart sapmaları göstermektedir. Uzaklık ölçümü yapılırken SPICE algoritması için "NAN" veren denemeler çıkarılıp geriye kalan denemeler üzerinden ortalama değer hesabı yapılmıştır. Son eleman sayısı 5 için aynı işlemler tekrarlanmış, çizelge 2'de yer alan sonraki satırlar oluşturulmuştur.


SPICE ve KİDDO algoritmaları son eleman tespitinde yüksek başarımla elde etmişlerdir. SPICE algoritması 0'dan küçük ve 1'den büyük değerlere ulaşabilirken, KİDDO son elemanları her zaman [0-1] aralığında bulmuştur. SPICE algoritması, son elemanları [0-1] aralığında tespit edebilmesi için regülarizasyon parametresinin artırılması yani simpleks hacminin azaltılması gerekmektedir. Ancak bu parametrenin fazla artırılması gerçek son eleman değerlerinin bulunamamasına yol açabilir. Regülarizasyon parametresi büyüdükçe SPICE ve KİDDO algoritmalarının benzer sonuç verdiği görülebilmektedir. Uzaklık ölçüm değerleri kıyaslandığında KİDDO algoritmasının daha az hata ile gerçek reflektans değerlerini izlediği görülmektedir. SPICE algoritmasından yüksek bulunduğu uzaklık ölçüm değerlerinde, SPICE algoritmasından "NAN" veren denemelerinin çıkartılarak ortalama alındığı unutulmamalıdır. Yapılan deneyler SPICE algoritmasının başarılı olduğu noktalarda KİDDO algoritmasının da benzer başarıyı yakaladığını göstermiş; son eleman değerlerini [0-1] aralığında daha az hata ile bulması ve regülarizasyon parametresinden SPICE algoritması kadar etkilenmemesi sebebiyle de KİDDO algoritmasını avantajlı kılmıştır.

SPICE ve KİDDO algoritmalarının materyallerin spektral imzalarını bulma değişimlerine Şekil 3'te yer verilmiştir. Son eleman sayısı 5 ve regülarizasyon parametresi $\mu=0$ için Şekil 3(a)'da SPICE algoritmasının spektral dağılımları 0'dan küçük ve 1'den büyük olarak bulunduğu bir çıktı yer alırken Şekil 3(b)'de KİDDO algoritmasının gerçek spektral imzaları bulunduğu bir çıktı gösterilmiştir.

Çizelge 2. SPICE ve KİDDO algoritma çıktıları

		SPICE			KİDDO			
		$\mu=0$	$\mu=0.0001$	$\mu=0.01$	$\mu=0$	$\mu=0.0001$	$\mu=0.01$	
Son Eleman Sayısı = 3	1	M'in doğru bulunma sayısı	35/50	48/50	50/50	48/50	47/50	50/50
	2	Ort. Min. değer	-0.016	0.028	0.034	0.031	0.030	0.034
	3	Ort. Maks. değer	6.041	0.893	0.877	0.893	0.893	0.877
	4	Min. Değer < 0	13NAN 2/50	2/50	0/50	0/50	0/50	0/50
	5	Maks.Değer > 1	13NAN 1/50	0/50	0/50	0/50	0/50	0/50
	6	Ort. Korelasyon uzaklığı	0.41± 0.36	0.38± 0.34	0.33± 0.33	0.42± 0.37	0.43± 0.35	0.38± 0.35
	7	Ort. Öklid uzaklığı	5.29± 4.07	5.12± 4.0	4.59± 4.00	4.69± 4.13	5.74± 4.05	5.04± 3.90
Son Eleman Sayısı = 5	1	M 'in doğru bulunma sayısı	31/50	36/50	50/50	47/50	47/50	50/50
	2	Ort. Min. değer	-0.032	0.001	0.033	0.017	0.019	0.033
	3	Ort. Maks. değer	0.909	0.892	0.865	0.902	0.893	0.865
	4	Min. Değer < 0	11NAN 2/50	13NAN 9/50	0/50	0/50	0/50	0/50
	5	Maks.Değer > 1	11NAN 1/50	13NAN 0/50	0/50	0/50	0/50	0/50
	6	Ort. Korelasyon uzaklığı	0.46± 0.34	0.46± 0.34	0.44± 0.29	0.47± 0.34	0.47± 0.34	0.43± 0.28
	7	Ort. Öklid uzaklığı	4.38± 3.50	4.38± 3.50	4.38± 3.23	4.45± 3.57	4.45± 3.57	4.60± 3.32

* M=son eleman sayısı; * μ =Regülerizasyon parametresi
 * NAN=Not A Number (SPICE algoritmasının spectral imzaları bulamadığı durumları gösterir)
 * Ortalama uzaklıklar NAN olmayan değerlerin ortalaması olarak alınmıştır.



Şekil 3. Algoritmaların son eleman sayısının 10 olduğu iklendirilmiş ve regülazisyon parametresi $\mu=0$ alınmıştır. (a) SPICE algoritması son eleman sayısını 5 olarak doğru bulmuştur. Ancak son elemanların minimum ve maksimum değerleri [-0.007 1.277] olarak gözlenmiştir. (b) KIDDO algoritması ise hem son eleman sayısını 5 olarak doğru bulmuş hem de son eleman değerlerini [0 1] aralığında bularak spektral imzaları yakalayabilmiştir.

KAYNAKÇA

- [1] D. Gerçek, D. Çeşmeci, M. K. Güllü, A. Ertürk, and S. Ertürk, (2013), "Hiperspektral görüntüleme ve görüntü işlemenin bugünü, yakın geleceği ve mevcut araştırma eğilimleri," XYZ Dergi, pp. 18–25.
- [2] A. Baldrige, S. Hook, C. Grove, and G. Rivera, (2009), "The ASTER spectral library version 2.0," Remote Sensing of Environment, vol. 113, pp. 711-715.
- [3] N. Keshava and J. F. Mustard, "Spectral unmixing, (2002), " Signal Processing Magazine, IEEE, vol. 19, pp. 44-57.
- [4] W. Ma, J. Bioucas-Dias, P. Gader, T. Chan, N. Gillis, A. Plaza, et al., (2013), "A signal processing perspective on hyperspectral unmixing," IEEE Signal Processing Mag, vol. 31, pp. 67-81.
- [5] M. Berman, H. Kiiveri, R. Lagerstrom, A. Ernst, R. Dunne, and J. F. Huntington, (2004), "ICE: A statistical approach to identifying endmembers in hyperspectral images," IEEE Transactions on Geoscience and Remote Sensing, vol. 42, pp. 2085-2095.
- [6] A. Zare and P. Gader, (2007), "SPICE: A sparsity promoting iterated constrained endmember extraction algorithm with applications to landmine detection from hyperspectral imagery - art. no. 655319," in Detection and Remediation Technologies for Mines and Minelike Targets XII. vol. 6553, pp. 55319-55319.
- [7] S. E. Yüksel (2014), "Hiperspektral Görüntülerde Son Elemanların Geliştirilmiş Kısıtlı Optimizasyonla Bulunması", Signal Processing and Communications Applications Conference, Proceedings of the IEEE.

COMPARISON OF RX-BASED ANOMALY DETECTORS ON SYNTHETIC AND REAL HYPERSPECTRAL DATA

Sefa Küçük, Seniha Esen Yüksel

Hacettepe University, Department of Electrical and Electronics Engineering, Ankara, Turkey

ABSTRACT

Anomaly detection refers to detecting the deviations from the normal background behavior without any prior information about the target or the background. For hyperspectral image analysis, Reed-Xiaoli (RX) algorithm is arguably the most popular anomaly detector. It models the background as a multidimensional Gaussian distribution and computes how much a test vector is deviating from the background model. Over the years, many versions of RX have been developed and compared on VNIR or SWIR data, but longwave-infrared (LWIR) data comparisons are very few. In this paper, a comprehensive comparison of six different anomaly detectors, namely the global RX, local RX, dual window RX, subspace RX, kernel RX and the global RX combined with a uniform target detector, have been presented. The comparisons have been made on real LWIR hyperspectral data and synthetic data with varying noise levels and target sizes. Several factors to consider such as parameter selection, resilience to noise, effect of window size, computational complexity have been discussed and the detection performance have been presented on receiver operating characteristic curves.

Index Terms— Anomaly detection, hyperspectral, LWIR.

1. INTRODUCTION

Due to the vast sizes of data but little targets of interest, anomaly detection holds an important part in hyperspectral image processing. The goal of anomaly detection is to detect the pixels in the scene whose spectra differ from their surroundings. Most anomaly detection algorithms in literature [1] are based on the family of Gaussian distributions, and the most commonly used anomaly detector, Reed-Xiaoli (RX) [2], can be considered as a benchmark.

The anomaly detection problem can be broken down into two sub-problems: how to characterize the background and how to measure the anomaly score. RX detector assumes that the background is homogeneous and models it with a multivariate Gaussian distribution. However, this hypothesis may not always be adequate. Therefore, several extensions to RX were developed that address the two sub-problems [1, 3]. In the rest of the paper, we compare six variations of RX in

We would like to HAVELSAN Inc., Turkey for providing the LWIR data.

terms of speed and accuracy on synthetic and real hyperspectral (LWIR) datasets and discuss parameter selection.

2. ANOMALY DETECTION METHODS

In this section, we provide the basics of anomaly detectors from the implementation point of view under a unified syntax.

2.1. Global Reed-Xiaoli Detector (GRX)

GRX [4], also called the Mahalanobis distance detector, models the background of the complete scene with a multivariate Gaussian distribution with mean $\hat{\mu}_b$ and covariance $\hat{\Sigma}_b$. It computes the Mahalanobis distance between a test pixel \mathbf{r} and the mean of the background vector as follows:

$$D_{GRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_b)^T \hat{\Sigma}_b^{-1} (\mathbf{r} - \hat{\mu}_b). \quad (1)$$

The test pixel is called an anomaly if this distance D is bigger than a defined threshold.

2.2. Local Reed-Xiaoli Detector (LRX)

LRX [2] is basically a spatially adaptive version of the GRX statistic that replaces the global background model with a local normal model [4]. To detect anomalies, a double concentric window is slid over every pixel in the image as illustrated in Fig.1. The size of inner window that is called guard band is assumed to be the size of target in the image. For the local RX detector, Eq.(1) is modified as follows:

$$D_{LRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_{local})^T \hat{\Sigma}_{local}^{-1} (\mathbf{r} - \hat{\mu}_{local}). \quad (2)$$

where \mathbf{r} is the test pixel, $\hat{\mu}_{local}$ is the mean vector and $\hat{\Sigma}_{local}$ is the covariance matrix of the local background, respectively.

2.3. Reed-Xiaoli and Uniform Target Detector (UTD)

In [5], it has been suggested that removal of the background and also noise has improved the performance of RX detector. A new type of anomaly detector was developed by incorporating the UTD into RX [3]. By subtracting the UTD from the RX, the equation is obtained as follows:

$$D_{RXD-UTD}(\mathbf{r}) = (\mathbf{r} - \mathbf{1}_{d \times 1})^T \hat{\Sigma}_b^{-1} (\mathbf{r} - \mu). \quad (3)$$

where $\mathbf{1}_{d \times 1} = (1, 1, \dots, 1)^T$ is the d dimensional unity vector where d is the number of spectral bands in the data.




Fig. 1. Double concentric window surrounding the test pixel.

2.4. Dual Window Reed-Xiaoli Detector (DWRX)

In LRX, guard band is used to prevent the target pixels from penetrating into the calculation of background statistics. Unlike the LRX, DWRX [6] uses this guard band information. Instead of using the spectra of the test pixel under test, it uses the mean of the spectral pixels falling into the guard band. DWRX distance is computed as follows:

$$D_{DWRX}(\mathbf{r}) = (\hat{\mu}_{diff}(\mathbf{r}))^T \hat{\Sigma}_{local}^{-1} (\hat{\mu}_{diff}(\mathbf{r})). \quad (4)$$

$$\hat{\mu}_{diff}(\mathbf{r}) = \hat{\mu}_{inner}(\mathbf{r}) - \hat{\mu}_{outer}(\mathbf{r}). \quad (5)$$

where $\hat{\mu}_{inner}$ is the mean of the spectral pixels in the inner window, $\hat{\mu}_{outer}$ is the mean vector and $\hat{\Sigma}_{local}$ is the covariance matrix of the local background region, respectively.

2.5. Subspace Reed-Xiaoli Detector (SSRX)

SSRX [7] assumes that target pixels and background statistics can be expressed in different subspaces. The background subspace is projected onto a subspace that provides suppression of the background statistics. SSRX is computed as follows:

$$D_{SSRX}(\mathbf{r}) = (\mathbf{r} - \hat{\mu}_b)^T (I - WW^T) (\mathbf{r} - \hat{\mu}_b). \quad (6)$$

where I is the identity matrix, $\hat{\mu}_b$ is the mean of the background samples, W is a matrix consisting of eigenvectors corresponding to large eigenvalues of background covariance matrix and W^\dagger denotes the pseudo-inverse of W . The product WW^\dagger is the projection operator.

2.6. Kernel Reed-Xiaoli Detector (KRX)

RX assumes that the background is homogeneously distributed. However, there may be a non-linear relationship between the spectral bands. KRX [8] has been developed for the case that the samples need more complex decision boundaries. KRX uses non-linear models and maps the input space to a high dimensional feature space using kernel functions. A possible kernel function is the Gaussian RBF, given as

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / c)$$

With the kernel function defined, the KRX value for the test pixel \mathbf{r} can be computed as follows:

$$D_{KRX}(\mathbf{r}) = (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T)^T \hat{\mathbf{K}}_b^{-1} (\mathbf{K}_r^T - \mathbf{K}_{\hat{\mu}_b}^T). \quad (7)$$

where $\hat{\mathbf{K}}_b$ is the Gram (kernel) matrix of the M background pixels, obtained as follows:

$$\hat{\mathbf{K}}_b = \mathbf{K}(\mathbf{X}_b, \mathbf{X}_b) = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & \cdots & k(\mathbf{x}_1, \mathbf{x}_M) \\ k(\mathbf{x}_2, \mathbf{x}_1) & \cdots & k(\mathbf{x}_2, \mathbf{x}_M) \\ \vdots & \ddots & \vdots \\ k(\mathbf{x}_M, \mathbf{x}_1) & \cdots & k(\mathbf{x}_M, \mathbf{x}_M) \end{bmatrix}$$

The Gram matrix is also denoted by $\hat{\mathbf{K}}_b = \mathbf{K}(\mathbf{X}_b, \mathbf{X}_b)$ where $\mathbf{X}_b = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(M)]$ is the background matrix whose columns are the spectral pixels of d dimensions. In Eq.7, \mathbf{K}_r^T is a vector and equals the kernel map of the test pixel \mathbf{r} as follows:

$$\mathbf{K}_r^T \equiv \mathbf{k}(\mathbf{X}_b, \mathbf{r})^T - \frac{1}{M} \sum_{i=1}^M k(\mathbf{x}(i), \mathbf{r}). \quad (8)$$

where the first term in Eq.8 is given as:

$$\mathbf{k}(\mathbf{X}_b, \mathbf{r}) = [k(\mathbf{x}(1), \mathbf{r}) \quad \cdots \quad k(\mathbf{x}(M), \mathbf{r})]$$

and second term in Eq.8 is the scalar mean of $\mathbf{k}(\mathbf{X}_b, \mathbf{r})$. Finally, $\mathbf{K}_{\hat{\mu}_b}^T$ in Eq.7 equals:

$$\mathbf{K}_{\hat{\mu}_b}^T \equiv \frac{1}{M} \sum_{i=1}^M \mathbf{k}(\mathbf{X}_b, \mathbf{x}(i)) - \frac{1}{M^2} \sum_{i=1}^M \sum_{j=1}^M k(\mathbf{x}(i), \mathbf{x}(j)). \quad (9)$$

The first term in Eq.9 is a row vector, containing the mean of each column of the Gram matrix. The second term is the scalar mean of the Gram matrix. This section provides the sufficient details to implement KRX. Detailed derivations to arrive at these equations can be found in [8].

3. EXPERIMENTAL RESULTS

SYNTHETIC DATA: Two synthetic datasets were generated with different noise levels and various target sizes. The first dataset is a datacube of size 75x75x10 and has two anomaly regions of size 5x5x10. The anomaly regions were generated from a normal distribution with mean 1.5 and variance 0.1; and the background were sampled from a normal distribution with mean 1 and variance 0.1. The detection results for this dataset is given in Fig.2. The second dataset had background mean 1, variance 0.2; and anomaly mean 1.2 with variance 0.2. Therefore, anomalies and the background were barely distinguishable as shown in Fig 3(a). In this second dataset, targets were of size 5x5, 7x7 and 9x9 from left to right to investigate the relations between the window and target size.

On the first dataset, window-based anomaly detectors were run with a 5x5 inner window and 9x9 outer window. For KRX, using the Gaussian RBF kernel, c was set to 40. Fig.2 shows the results of the detection without thresholding. For SSRX, the number of eigenvectors were selected as the principal components that account for about fifty percent of

the variances. For KRX, the size of outer window determines the dimension of Gram matrix and is a very critical parameter in terms of computational complexity. Table 1 shows the elapse time of detectors on both synthetic data and real data. The second dataset presents a much harder problem as the targets and the background have very similar distributions. Therefore, the detections decreased significantly and it became more important to select the best window parameters.




Fig. 2. Detection results for the first synthetic data. GRX generated the most false alarms, followed by RXD-UTD, KRX and SSRX. The LRX and DWRX detected only the center of anomalies due to the window size (5x5), but generated very few false alarms.

For LRX and DWRX, targets could not be detected if the inner window was smaller than 5x5. Thus, the size of inner window should not be smaller than the size of the target. For the outer window, results were enhanced with increasing outer window size as long as the window did not include any other targets. Therefore, an estimate about the distance between the targets can be used to determine the size of the outer window.

The GRX and RXD-UTD have no parameters. However, looking at Fig.3, it is clear that none of them are resilient to noise. This is partly due to the target signatures effecting the background model. However, local RX and SSRX also seems to fail under noise, and the selection of window parameters becomes a rather important issue. The only algorithm that stayed resilient to noise was DWRX.

REAL DATA: Real hyperspectral data was acquired by a LWIR (8–12 μm) imager and was calibrated with Telops Reveal Air Calibrate software. The dataset contains 150x320 pixels and 81 spectral bands. In the scene, four targets composed of different materials including a wooden crate (T1), metallic bucket (T2), plastic jerrycan (T3), and glass jug (T4) were laid on a surface covered with sparse grass. The 3rd




Fig. 3. Detection results for the second synthetic data for varying window sizes. LRX-7-15 means that a 7x7 inner window and a 15x15 outer window was used for local RX.

band image (898.48 cm^{-1}) and its ground truth are shown in Fig.4(a) and (b), respectively.




Fig. 4. LWIR data with four targets. (a) A snapshot of the 3rd spectral band (898.48 cm^{-1}) image. (b) The ground truth.

In the scene, the wooden crate (T1) is too large to be an anomaly. Therefore, for the LRX, DWRX and SSRX detectors, the size of inner and outer windows was selected as the size of plastic jerrycan (25x31 pixels) that is the second largest target in the scene. The size of inner and outer window was set to 25x31 and 49x61 pixel areas, respectively. Fig.5 shows the detection results of the compared anomaly detectors on the LWIR data, without thresholding. LRX and DWRX detected the targets (T2-T4) with a few false alarms,

while the GRX generated much more false alarms. The RXD-UTD suppressed the background. The SSRX detected all targets including T1 with many false alarms. The performance of detectors was compared using the receiver operating characteristic (ROC) in Fig.6. Note that the DWRX is an outstanding detector among five of them, similarly. KRX was not used here as it takes about 2 seconds to compute and invert the Gram matrix for every text pixel in the image for windows of this size.




Fig. 5. Detection results for LWIR data.

AD	On Synt. Data (in sec.)	On Real Data (in sec.)
GRX	0.057361	0.443171
RXD-UTD	0.057646	0.480788
LRX	1.215343	303.109355
DWRX	3.963727	475.239997
SSRX	1.182056	256.108270
KRX	21.555117	—

Table 1. The elapse time of detectors on both synthetic and real data for a fixed window size. Anomaly detectors were run on a PC with Windows 8.1 core i7 2.4GHZ-16GB RAM.

4. CONCLUSIONS

We compared the performance of six RX-based anomaly detectors comprehensively and pointed out the issues in parameter selection. When we consider that it is not time-consuming and generates less false alarms, DWRX is an outstanding anomaly detector among six variations of the RX.

When the inner window size was small or equal to the target, DWRX detected only center of anomaly regions as in Fig.2. When window sizes were increased as in Fig.3; it found the whole target. This is also a pretty interesting result since

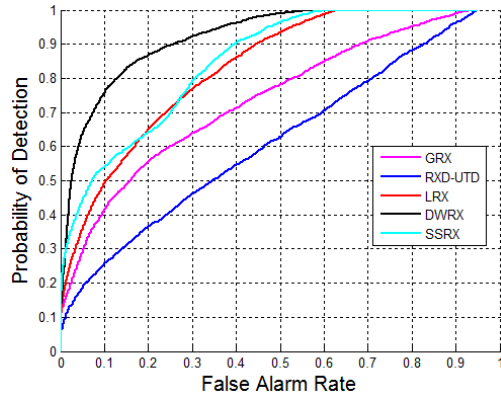


Fig. 6. ROC curves of the anomaly detectors on LWIR data.

in some applications, we are really interested in the center of the target and not the whole target itself.

References

- [1] Stefania Matteoli, Marco Diani, and Giovanni Corsini, "A tutorial overview of anomaly detection in hyperspectral images," *Aerospace and Electronic Systems Magazine, IEEE*, vol. 25, no. 7, pp. 5–28, 2010.
- [2] Irving S Reed and Xiaoli Yu, "Adaptive multiple-band cfar detection of an optical pattern with unknown spectral distribution," *Acoustics, Speech and Signal Processing, IEEE Trans. on*, vol. 38, no. 10, pp. 1760–1770, 1990.
- [3] Chein-I Chang and Shao-Shan Chiang, "Anomaly detection and classification for hyperspectral imagery," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 40, no. 6, pp. 1314–1325, 2002.
- [4] Michael Theodore Eismann, "Hyperspectral remote sensing," SPIE, 2012.
- [5] Edward A Ashton and Alan Schaum, "Algorithms for the detection of sub-pixel targets in multispectral imagery," *Photogrammetric Engineering & Remote Sensing*, vol. 64, no. 7, pp. 723–731, 1998.
- [6] Weimin Liu and Chein-I Chang, "A nested spatial window-based approach to target detection for hyperspectral imagery," in *IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2004, vol. 1.
- [7] N Nasrabadi, "Hyperspectral target detection: An overview of current and future challenges," *Signal Processing Magazine, IEEE*, vol. 31, no. 1, pp. 34–44, 2014.
- [8] Heesung Kwon and Nasser M Nasrabadi, "Kernel rx-algorithm: a nonlinear anomaly detector for hyperspectral imagery," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 43, no. 2, pp. 388–397, 2005.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı: Sefa KÜÇÜK

Doğum Yeri: Erzurum

Medeni Hali: Bekar

E-posta: skucuk@ee.hacettepe.edu.tr

Adresi: Etiler Mahallesi 1456 Sokak No: 6 D: 3 Etimesgut / ANKARA

Eğitim

Lise: Erzurum Anadolu Lisesi, ERZURUM

Lisans: Atatürk Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü, ERZURUM

Yüksek Lisans: Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü, ANKARA

Yabancı Dil ve Düzeyi

İngilizce : İleri düzey - (YDS 2014 : 85 B Seviye)

İş Deneyimi

Erzurum Teknik Üniversitesi Elektrik - Elektronik Mühendisliği, Ocak 2013-Şubat 2013, Araştırma Görevlisi, ERZURUM

Hacettepe Üniversitesi Elektrik - Elektronik Mühendisliği, Şubat 2013-..., Araştırma Görevlisi, ANKARA

Deneyim Alanları

Uzaktan algılama, hiperspektral görüntüleme, görüntü işleme

Tezden Üretilmiş Projeler ve Bütçesi

—

Tezden Üretilmiş Yayınlar

"Hiperspektral Görüntülerde Son Eleman Tespiti", *7. Savunma Teknolojileri Kongresi (SAVTEK)*, Haziran 2014, Ankara, Türkiye.

"Comparison of Rx-Based Anomaly Detectors on Synthetic and Real Hyperspectral Data", *Workshop on Hyperspectral Image and Signal Processing Evolution in Remote Sensing (WHISPERS)*, June 2015, Tokyo, Japonya.

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

SAVTEK 2014, 7. Savunma Teknolojileri Kongresi, Ankara.

WHISPERS 2015, Workshop on Hyperspectral Image and Signal Processing Evolution in Remote Sensing, Tokyo.