

**HİPERSPEKTRAL GÖRÜNTÜLERDE ESER MİKTARDA
KİMYASAL MADDE TESPİTİ**

**DETECTION OF TRACE AMOUNT CHEMICAL
SUBSTANCES IN HYPERSPECTRAL IMAGES**

Şafak ÖZTÜRK

Doç. Dr. Seniha Esen YÜKSEL ERDEM

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2022

ÖZET

HİPERSPEKTRAL GÖRÜNTÜLERDE ESER MİKTARDA KİMYASAL MADDE TESPİTİ

Şafak ÖZTÜRK

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği

Tez Danışmanı: Doç. Dr. Seniha Esen YÜKSEL ERDEM

Ocak 2022, 80 sayfa

Hiperspektral görüntüler doğası gereği sahip oldukları yüzlerce bant bilgisi sayesinde içeriğindeki nesnelere hakkında oldukça detaylı bilgi sağlar. Bu sayede tek ya da 3 bantlı görüntülerin analizi ile ayırt edilemeyecek ya da sağlıklı bir şekilde tespit edilemeyecek farklılıkların ortaya çıkarılmasının önü açılır. Her piksel için yüzlerce banttan oluşan bir bilgi vektörü sağlayan hiperspektral kameralar ile yapılan çekimler görüntüdeki nesnelere uzamsal analizinin mümkün olmadığı ya da çok kısıtlı yapılabildiği durumlarda bile spektral analiz imkânı sağlar. Hiperspektral görüntüleme teknolojisi ile renk ya da şekil olarak birbirine benzeyebilen nesne ya da arka planların spektral olarak ayrışması mümkün kılınır.

Hiperspektral görüntülerin analizi ve bu görüntüler kullanılarak içeriğindeki nesnelere sınıflandırılması ya da aranan bir nesnenin tespiti için denenebilecek birçok yaklaşım mevcuttur. Bu yaklaşımlar aranan nesneye ait ön bilgi olup olmamasına, problemin analizine dair zengin veri kümesine sahip olup olmamaya ya da veri çekim şartlarının ne kadar farklı parametreye göre değişip değişmediğine göre farklı yöntemleri temel alarak şekillenebilir. Örneğin ne olduğu tam olarak bilinmeyen ancak arka plandan ayrılmış nesnelere tespiti için anomali tespiti temelli yöntemler baz alınırken aranan nesneye dair ön bilginin sağlandığı durumlarda spektral imza eşleştirme odaklı yöntemler baz alınabilir.

Bu tezde, farklı arka planlar üzerine nanogramlarla (500ng -10000ng) ölçülen seviyelerde yerleştirilmiş eser miktarda kimyasal maddelerin tespiti ve teşhisi amacıyla yapılan çalışmalar anlatılır. Hedef ve arka plan çeşitliliği, hedefin çok az miktarda olacak şekilde yerleştirilmesi, kullanılan sensörün herhangi bir radyometrik düzeltme işlemi yapmadan ham veri üretmesi, ışık ve hedefin konumunun değişebilmesi gibi birçok farklı zorluklar ile karşılaşmıştır. Bu zorlukların olabildiğince önüne geçerek gürbüz bir algoritma üretebilmek için geliştirilen çözümler adım adım sunulmuştur. Öncelikle sensörden alınan ham radyans veriler incelendiğinde bu ham verilerde arka plan ve hedef ayrımının iyi yapılamadığı gözlenmiştir. Bu sebeple alınan radyans veriler üzerinde yapılan farklı işlemler ile doğrultma amaçlı bir takım veri dönüşüm algoritmaları uygulanmıştır. Böylece hedef ve arka plan ayrımı daha başarılı bir şekilde gerçekleştirilir. Daha sonra çeşitli imza tabanlı hedef tespit algoritmaları denenerek bu teze konu olan problem için başarılı sonuçlar üreten yöntemler ortaya çıkarılmıştır.

Kimyasal maddelerin tespiti ve teşhisi probleminin çözümü, girdi olarak görüntü ve gerekli diğer bilgileri alıp çıktı olarak hedef tipi ve lokasyonu bilgisi veren bir algoritma yaratma gerektirir. Bu yüzden skor haritalarını oluşturmak yeterli değildir. İlgili skor haritalarını anlamlandırarak gerekli çıktıları üreten adımlara da ihtiyaç duyulur. Bu amaçla çeşitli son işleme adımları da denenerek daha gürbüz sonuçlar almayı sağlayan son işleme algoritmaları da bu tezde yapılan çalışmaların bir parçasıdır. Bu adımlar sayesinde yanlış alarmlar olabildiğince elenir.

Özetle, yukarıda bahsi geçen problemin çözümü amaçlı literatürdeki farklı spektral imza eşleştirme odaklı yöntemler kullanılarak “Çoklu Hedef Tespiti” isimli hibrit bir yöntem geliştirilmiştir. İlk olarak ultraviyole ve yakın kızıl ötesi spektrumda çekilmiş hiperspektral görüntü ve görüntüde aranan hedef referans imzalarına uygulanan ön işleme adımları (beyazlatma ve Savitzky-Golay filtresi) detaylandırılmıştır. Sonrasında uygulanan hibrit tespit yöntemi detayları ile aktarılmıştır. Çapraz ilintileme ve spektral imza ayrımı algoritmaları temelli iki aşamalı bir skor haritası üretim algoritması anlatılmıştır. Daha sonra skor haritalarını anlamlandırmak için skora göre eşikleme ve sonrasında potansiyel hedef kümeleri için belirli bir eşik değerinden daha fazla sayıda piksel içermesi gibi şartlar içeren son işleme adımları hakkında bilgi verilmiştir.

“Çoklu Hedef Tespiti” yöntemine ek olarak, daha önce elde edilmiş skor haritaları üzerinde uygulanan son işleme adımlarını derin öğrenme ile sağlayan POSTNET isimli yöntem geliştirilmiş ve detaylarıyla sunulmuştur. Ayrıca hiperspektral veriye yapılan ön işleme

adımlarının ve tespit sonrası yapılan son işleme adımlarının algoritma başarımına olan büyük katkısı vurgulanmıştır.

Anahtar Kelimeler: hiperspektral, nesne tespiti, beyazlatma, ultraviyole, yakın kızıl ötesi, spektral imza eşleştirme, derin öğrenme, çoklu hedef tespiti, POSTNET.

ABSTRACT

DETECTION OF TRACE AMOUNT CHEMICAL SUBSTANCES IN HYPERSPECTRAL IMAGES

Şafak ÖZTÜRK

Master of Science, Electrical and Electronic Engineering

Supervisor: Assoc. Prof. Seniha Esen YÜKSEL ERDEM

January 2022, 80 pages

Hyperspectral images, by their very nature, provide a great deal of information about the contents of an image. In this way, they open the way to reveal the evidences that cannot be distinguished or detected properly by the analysis of single or 3-band images. Shots made with hyperspectral cameras, which provide an information vector consisting of hundreds of bands for each pixel, provide spectral analysis even in cases where spatial analysis of the objects in the image is not possible or can be made very limited. Spectral separation of objects or backgrounds that can resemble each other in color or shape is made possible with hyperspectral imaging technology.

There are many approaches that can be tried to analyze hyperspectral images, to classify the objects in their content using these images, or to detect a searched object. These approaches can be shaped based on different methods, depending on whether there is a preliminary information about the searched object, whether there is a rich data set on the analysis of the problem, or whether the data acquisition conditions change based on different parameters settings. For example, anomaly detection-based methods are used for the detection of objects that are not known exactly but separated from the background, while spectral signature matching-oriented methods can be used in cases where the preliminary information about the sought object is provided.

In this thesis, studies for the detection and identification of trace amounts of chemical substances placed at levels measured in nanograms (500ng -10000ng) on different backgrounds are described. Many different difficulties are faced such as target and background diversity, placement of the very small amount of target, using raw data without any radiometric correction, change of light and target position. The solutions developed to avoid these difficulties and to produce a robust algorithm are presented step by step. First of all, when the raw radiance data taken from the sensor is examined, it is observed that the background and target separation cannot be made well in raw data. For this reason, a number of data conversion algorithms are applied for data rectification with different operations on the received radiance data. Thus, target and background separation is performed more successfully. Afterwards, various signature-based target detection algorithms have been tried and the methods that produce successful results for the problem that is the subject of this thesis have been revealed.

Solving the problem of detection and identification of chemicals requires creating an algorithm that takes images and other necessary information as input and gives target type and location information as output. Hence, creating score maps is not enough. Steps that produce the necessary outputs by using relevant score maps are also needed. For this purpose, post-processing algorithms that lead to more robust results are also part of the work done in this thesis. These steps eliminate false alarms as much as possible.

In summary, a hybrid method called "Multiple Target Detection" has been developed by using different spectral signature matching-oriented methods in the literature to solve the above-mentioned problem. First, the hyperspectral image taken in the ultraviolet and near infrared spectrum and the preprocessing steps (whitening and Savitzky-Golay filter) applied to the target reference signatures sought in the image are detailed. Afterwards, the applied hybrid detection method is explained in detail. A two-stage score map generation algorithm based on cross-correlation and spectral information divergence algorithms is described. Then information is given about the final processing steps, which include conditions such as thresholding according to the score and selecting final detected areas by connective pixel analysis for potential target clusters.

In addition to the "Multiple Target Detection" method, a method named POSTNET, which provides the final processing steps applied on the previously obtained score maps with deep learning, has been developed and presented in detail. In addition, the great contribution of

the pre-processing steps applied to the hyperspectral data and the post-processing steps applied after creation of score maps are emphasized.

Keywords: hyperspectral, object detection, whitening, ultraviolet, near infrared, spectral signature matching, deep learning, multi-target detection, POSTNET.

TEŐEKKÜR

Gerek ders dönemi gerekse tez döneminde yapmış olduğum çalışmalarında bana yön gösteren, destek ve emeklerini esirgemeyen değerli hocam, tez danışmanım Doç.Dr. Seniha Esen YÜKSEL ERDEM'e teşekkürlerimi sunarım.

Görüntü işleme alanında çalışmama olanak sağlayan, uzaktan algılama ve hiperspektral görüntü analizi konularıyla ilgili çalışmalarda bulunmama katkı sağlayan, yüksek lisans süresince her türlü kolaylığı sağlayan HAVELSAN ailesine teşekkürlerimi sunarım.

Son olarak, bu süreçte her türlü desteęi ile yanımda olan kıymetli eşim Habibe ÖZTÜRK'e, biricik kızım Mualla'ya, aileme ve değerli dostlarıma ayrıca teşekkür ederim.

İÇİNDEKİLER

SAYFA

ÖZET	i
ABSTRACT	iv
TEŞEKKÜR	vii
İÇİNDEKİLER.....	viii
TABLolar.....	x
ŞEKİLLER	x
SİMGELER VE KISALTMALAR	xiii
SÖZLÜK DİZİNİ	xiv
1. Giriş	1
1.1. Tezin Amacı Ve Kapsamı	2
1.2. Tezin Akışı	3
2. Hiperspektral Görüntüleme	4
2.1. Hiperspektral Görüntü Özellikleri ve Kullanım Alanları	4
2.2. Hiperspektral Kamera Genel Yapısı ve Çalışma Prensibi.....	8
3. Hiperspektral Görüntü Analiziyle Alakalı Mevcut Yaklaşımlar	12
3.1. Anomali Tespiti Odaklı Yaklaşım.....	12
3.2. Spektral Ayırıştırma Odaklı Yöntemler	14
3.3. Spektral İmza Eşleştirme Odaklı Yöntemler.....	16
3.4. Derin Öğrenme Odaklı Yöntemler	18
4. Problem Tanımı Ve Veri Kümesi.....	20
5. Çoklu Hedef Tespiti Yöntemi	25
5.1. Görüntü Girdisi	27
5.2. Referans İmza Girdisi.....	28
5.3. Görüntü ve Referans İmza Birleşimi.....	33
5.4. Beyazlatma Algoritması.....	34
5.5. Savitzky-Golay Filtresi Uygulama.....	43
5.6. Görüntü ve Referans İmza Kümesinin Ayırımı.....	44
5.7. Tespit.....	44
5.7.1. İlk Aşama: Çapraz İlintileme	45
5.7.2. İlk Eşikleme.....	47
5.7.3. İkinci Aşama: Spektral Bilgi Ayırımı.....	49

5.7.4. Son Eşikleme.....	54
5.8. Grup Piksel Sayısına Göre Eşikleme.....	57
5.9. Skor Kıyaslama ve Karar	59
6. POSTNET Yöntemi	61
6.1. Skor Haritalarını Oluşturma	62
6.2. Ön İşleme	62
6.3. POSTNET Modeli ve Eğitimi	64
7. Deneyler ve Sonuç.....	69
8. Değerlendirme	73
KAYNAKLAR	75
ÖZGEÇMİŞ	80

TABLULAR

	<u>Sayfa</u>
Tablo 1 POSTNET eğitim kümesi veri sayısı.....	64
Tablo 2 Çoklu Hedef Tespiti (ÇHT) Performans Tablosu	70
Tablo 3 POSTNET Performans Tablosu.....	71

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1 Elektromanyetik Spektrum [1].....	5
Şekil 2 VNIR spektrum aralığında gösterimi yapılan örnek 2 spektral imza	6
Şekil 3 Hiperspektral kamera tarama tipleri.....	8
Şekil 4 Örnek hiperspektral sensör yapısı	9
Şekil 5 Örnek hava platformu [11].....	10
Şekil 6 Örnek döner platform [11]	10
Şekil 7 Yürüyen bant sistemi örneği [11].....	11
Şekil 8 Hiperspektral görüntüsü çekilen örnek materyal görseli (kimyasal madde kahverengi deri ortasındaki beyaz maddedir.)	20
Şekil 9 Örnek tek bant görüntüsü	21
Şekil 10 Bant ortalaması ve tek bant görselleri karşılaştırması (a) Bant ortalaması görseli (b) Tek bant görseli	22
Şekil 11 Sahte renk görselleri karşılaştırması (a) 50/450/350 bantları ile elde edilmiştir. (b) 450/150/350 bantları ile elde edilmiştir.	22
Şekil 12 Temsili spektral imza gösterimi	23
Şekil 13 Yanlış alarm örneği (a) Yanlış alarm alınan bölge kırmızı halka içindeki parlak alandır. (b) Yanlış alarm imzası ile aranan hedef imzasının üst üste gösterimidir.	24
Şekil 14 Çoklu hedef tespiti yöntemi akış diyagramı.....	26
Şekil 15 Yüksek değerli piksellerin sıfırlanması (a) Sıfırlama öncesi (b) Sıfırlama sonrası silinmiş piksel grupları yuvarlak daireler içinde siyah olarak görülmektedir.....	28
Şekil 16 Hedef 1 spektral imzaları (ilk küme)	29
Şekil 17 Hedef 2 spektral imzaları (ilk küme)	29
Şekil 18 Hedef 3 spektral imzaları (ilk küme)	30
Şekil 19 Hedef 4 spektral imzaları (ilk küme)	30
Şekil 20 Hedef 1 spektral imzaları (ikinci küme).....	32
Şekil 21 Hedef 2 spektral imzaları (ikinci küme).....	32
Şekil 22 Hedef 3 spektral imzaları (ikinci küme).....	33
Şekil 23 Hedef 4 spektral imzaları (ikinci küme).....	33
Şekil 24 Görüntü ve referans imza kümesi birleşimi	34
Şekil 25 (a) Orijinal veri dağılımı (b) Dekorelasyon işlemi (c) Beyazlatılmış veri [47].....	35
Şekil 26 Örnek beyazlatma matrisleri	36
Şekil 27 Ham veri örnek bant (253nm) görüntüsü	37
Şekil 28 Ham veriden alınan hedef ve arka plan spektral imzaları	37

Şekil 29 Beyazlatılmış veri örnek bant (253nm) görüntüsü.....	38
Şekil 30 Beyazlatılmış veriden alınan hedef ve arka plan spektral imzaları.....	39
Şekil 31 (a) Ham radyans görseli (450nm) (b) Beyazlatılmış veri görseli (253nm).....	40
Şekil 32 Aynı referans imzanın farklı iki test verisi ile beyazlatılması.....	40
Şekil 33 Aynı piksele ait radyans eğrileri (Veri 1 ve Veri 2).....	41
Şekil 34 Aynı piksele ait beyazlatma eğrileri (Veri 1 ve Veri 2).....	42
Şekil 35 Aynı hedef referans imzasına ait beyazlatma eğrileri (Veri 1 ve Veri 2).....	42
Şekil 36 Aynı hedef referans imzasına ait beyazlatma eğrileri (Veri 1 ve Veri 2).....	43
Şekil 37 SGF uygulanmamış ve uygulanmış beyazlatılmış imza eğrileri.....	44
Şekil 38 Görüntü ve referans imza kümesi ayrımı gösterimi.....	44
Şekil 39 Örnek hedef imza kümesinin test görüntüsünde çapraz ilintileme sonuçları.....	46
Şekil 40 Çapraz ilintileme sonuçlarının yakınlaştırılmış hali.....	47
Şekil 41 Örnek hedef imza kümesinin eşiklenmiş çapraz ilintileme sonuçları.....	48
Şekil 42 Eşiklenmiş çapraz ilintileme sonuçlarının yakınlaştırılmış hali.....	48
Şekil 43 Örnek hedef imza kümesinin eşiklenmiş SBA-1 sonuçları.....	50
Şekil 44 Eşiklenmiş SBA-1 sonuçlarının yakınlaştırılmış hali.....	50
Şekil 45 Örnek hedef imza kümesinin eşiklenmiş SBA-2 sonuçları.....	51
Şekil 46 Eşiklenmiş SBA-2 sonuçlarının yakınlaştırılmış hali.....	52
Şekil 47 SBA-1 nihai skor haritası.....	53
Şekil 48 SBA-2 nihai skor haritası.....	53
Şekil 49 Örnek son eşikleme gösterimi.....	54
Şekil 50 SBA-2 skor haritaları (a) Hedef tipi 1, en düşük skor: 4.0081, en yüksek skor: 10.2351 (b) Hedef tipi 2, en düşük skor: 2.1297, en yüksek skor: 18.3786 (c) Hedef tipi 3, en düşük skor: 6.1283, en yüksek skor: 69.9211 (d) Hedef tipi 4, en düşük skor: 3.6834, en yüksek skor: 17.9633	55
Şekil 51 Sonuçların daha yakın görünmesi için kırpılmış SBA-2 skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4.....	55
Şekil 52 Son eşikleme sonrası elde edilen nihai skor haritaları (a) Hedef tipi 1, en düşük skor: 10.2351, en yüksek skor: 10.2351 (b) Hedef tipi 2, en düşük skor: 10.1603, en yüksek skor: 18.3786 (c) Hedef tipi 3, en düşük skor: 33.683, en yüksek skor: 69.9211 (d) Hedef tipi 4, en düşük skor: 10.0741, en yüksek skor: 17.9633.....	56
Şekil 53 Sonuçların daha yakın görünmesi için son eşikten geçirme sonrası kırpılmış nihai skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4.....	56
Şekil 54 Örnek grup piksel sayısına göre eşikleme.....	57
Şekil 55 Grup piksel sayısına göre eşikleme sonrası nihai skor haritaları (a) Hedef tipi 1, en düşük skor: 0, en yüksek skor: 0 (b) Hedef tipi 2, en düşük skor: 10.8615, en yüksek skor: 18.3786 (c) Hedef tipi 3, en düşük skor: 33.683, en yüksek skor: 69.9211 (d) Hedef tipi 4, en düşük skor: 10.7705, en yüksek skor: 17.9633.....	58
Şekil 56 Sonuçların daha yakın görünmesi için grup piksel sayısına göre eşikleme sonrası 4 hedef tipi için elde edilen kırpılmış nihai skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4.....	59
Şekil 57 Örnek karar akışı.....	60
Şekil 58 POSTNET eğitim akış diyagramı.....	61
Şekil 59 POSTNET test diyagramı.....	61
Şekil 60 POSTNET eğitimi için skor haritalarını oluşturma akış diyagramı.....	62

Şekil 61 Yer doğruluk haritası (solda), hedef pikselleri içerebilecek 16x16'lık parçaları kapsayan en geniş küme(ortada, açık mavi), hedef içermeyen 16x16'lık parçaların seçildiği alan (sağda, turkuaz ve yeşil) gösterimi	63
Şekil 62 Örnek 16x16 parçalar ve ilgili yer doğruluk maskeleri.....	64
Şekil 63 POSTNET akış diyagramı	66
Şekil 64 16x16'lık veri için yer doğruluk haritası (solda) ve POSTNET çıktısı (sağda) -1	67
Şekil 65 16x16'lık veri için yer doğruluk haritası (solda) ve POSTNET çıktısı (sağda) -2	68

SİMGELER VE KISALTMALAR

Simgeler

X	Girdi matris (C x N)
μ	Girdi matristen elde edilen ortalama vektör
W	Beyazlatma matrisi (N x N)
eps	Sabit değer (örn. 0,0001)
I	Birim matris (N x N)
Z	Çıktı matrisi (C x N)
P	Hedef referans spektral imzası
σ	Standart sapma
\bar{F}_i	i'inci pikselin spektral ortalama değeri
\bar{P}_k	k'inci referans hedef imzasının spektral ortalama değeri
CC_{ik}	k'inci referans hedef imzası ve i'ninci piksele ait çapraz ilintileme skoru
F	Piksel spektral imzası
i	Piksel numarası
k	Referans hedef numarası

Kısaltmalar

ÇHT	Çoklu Hedef Tespiti
OMSEÇ	Otomatik Morfolojik Son Eleman Çıkarımı
PYİ	Piksel Yoğunluk İndeksi
SAB	Spektral Açık Bulucu
SBA	Spektral Bilgi Ayrımı
SUSA	Spektral Uyumlu Süzgeç Algoritması
ZBA	Zirve Bileşen Analizi

SÖZLÜK DİZİNİ

Arka plan	Background
Çapraz ilintileme	Cross correlation
Eşik değeri	Threshold
Evrişimsel	Convolution
Genelleştirilmiş benzerlik testi	Generalized likelihood ratio test
Gürültü	Noise
N-Bulucu	N-Finder
Otomatik morfolojik son eleman çıkarımı	Automatic morphological endmember extraction
Spektral açı bulucu	Spectral angle mapper
Spektral bilgi ayrımı	Spectral information divergence
Uyumlu süzgeç	Matched filter
Zirve bileşen analizi	Vertex component analysis

1. GİRİŞ

Merak duygusu, evrenin tahmin edilen yaşı temel alındığında, insanlığın bu denli kısa sürede bilimde aldığı yola katkı sağlayan en önemli unsurlardan biri olarak adlandırılabilir. İnsanlık, bu duygunun getirdiği bilinmeyi bilme hırsı ve öğrenilen her bilginin sağladığı katlanarak büyüme ile görece çok kısa bir sürede ateşin keşfinden gezegenler arası haberleşmeye kadar süren ve gelecekte nereye varacağı tahmin dahi edilemeyen bir serüveni yaşamaktadır. Etrafını gözleme ve olan biteni anlama çabası düşünüldüğünde insanoğlunun ışık ile olan ilişkisi çok önemli bir yere oturacaktır. Optik olarak adlandırılan ve ışık hareketlerini, özelliklerini, ışığın diğer maddelerle etkileşimini inceleyen bilim dalı Antik Mısır ve Mezopotamya uygarlıklarının merceği icadına kadar dayanmaktadır. O günden bu güne kadar insanlık ve ışık arasındaki ilişki giderek büyümüştür. 1800’lü yıllarda fotoğrafın icadıyla başlayan sensör teknolojisi günümüzde çok ileri boyutlara varmıştır. Elektromanyetik spektrumun farklı aralıklarında oldukça hassas ölçümler yapılmasına olanak sağlayan kameralar geliştirilebilmiştir.

Son yıllarda gelişen teknoloji, uzaktan algılama ve tespit yöntemlerinde kullanılmak üzere edinilen görüntü yapılarında önemli değişiklikler sağlamıştır. Gerek görüntü alınabilen elektromanyetik spektrum aralığının genişlemesi gerekse ilgili bant aralığında sağlanan kanal (bant) sayısındaki artış uzaktan algılama problemlerine etkin çözümlerin bulunmasının önünü açmıştır. Özellikle, gelişen hiperspektral görüntüleme teknolojisi sayesinde hedef özel spektrum aralığında sağlanan yüzlerce bant bilgisi, problemi çözümede uzamsal bilgi işleme temelli yaklaşımların yanı sıra sinyal işleme temelli yaklaşımları da mümkün kılmaktadır.

Hiperspektral görüntüleme; tarım, sağlık, savunma sanayii, madencilik, kamu güvenliği gibi birçok alanda uygulama imkânı bulmaktadır. Hiperspektral kameranın çekim yaptığı spektral aralıktan elde edilen yüzlerce bant bilgisi, referans kütüphanelerden temin edilen spektral imzalarla karşılaştırılarak aranan objenin tespiti mümkün olmaktadır. Tek bantlı ya da üç bantlı görüntülerde sıkça rastlanılan yeterince ayırt edici bilgiye sahip olunmaması ya da uzamsal çözünürlüğün yeterli olmaması gibi engeller hiperspektral görüntünün sağladığı yüzlerce bant bilgisi ve sinyal işleme temelli algoritmalar ile önemli ölçüde aşılabilmektedir.

Hedef tespiti ve sınıflandırılması hiperspektral görüntü işlemenin yaygın kullanım uygulamalarından biridir. Bu tezin konusu da temel olarak hiperspektral görüntülerde hedef tespiti ve sınıflandırması odaklıdır.

1.1. Tezin Amacı Ve Kapsamı

Bu tezin amacı eser miktarda sayılabilecek (500 ile 10000 nanogram arası) kimyasal maddelerin farklı arka plan (siyah deri, kahverengi deri, siyah polyester ve gri skai) malzemeleri üzerine yerleştirilerek çekilen hiperspektral görüntülerde tespiti ve teşhisidir. Dolayısıyla üzerinde çalışılan problem genel olarak ele alındığında hiperspektral görüntülerde hedef tespiti ve sınıflandırması olarak temellendirilebilir. Bu tez, hiperspektral görüntü çekimi ve analizinin güvenlik alanında kullanımını içeren bir sistem aracılığıyla denenmesi odaklı bir çalışmadır. Sistem bileşenleri görüntü çekimi ve görüntülerin analizi olarak ikiye ayrılabilir. Bu tezin konusu çekilen görüntülerde eser miktarda kimyasal maddeleri bulmak üzere hedef tespiti ve sınıflandırması ile ilgili yapılan çalışmalardır.

Merkez laboratuvarı Hollanda'da bulunan ve çok uluslu organizasyona sahip bir firmaya ait geliştirme aşamasında olan üründen elde edilen görüntüler üzerinde çalışılmıştır. İlgili ürünün havaalanı gibi halka açık ve büyük güvenlik önlemleri alınan yerlerde ayakkabılar üzerinde tehlikeli-patlayıcı kimyasal madde tespiti amaçlı kullanımı öngörülmektedir. Hiperspektral görüntüler ultraviyole ve yakın kızıl ötesi spektrumda çekilmektedir. Çekim yapan sensör çizgi tarama prensibine göre çalışmaktadır. Dolayısıyla sahnenin ya da kameranın hareket etmesi gerekmektedir. Mevcut görüntüler sahnenin konveyör bant yardımıyla hareketi ile alınmaktadır. Konveyör bant üzerine konulan ayakkabı ya da ayakkabı malzemeleri bant yardımıyla hareket ettirilerek görüntü çekimi sağlanmaktadır. 4 farklı hedef tipi ve 4 farklı arka plan üzerinde çalışılmıştır. Hedef miktarları oldukça az (500ng ile 10000ng arası) olup genellikle görüntüde kapsadığı alan 2-10 piksel arasındadır. Gerek çalışılan hedeflerin çok az miktarlarda bulunması gerek birden fazla hedef ve arka plan tipi için sonuç üretilmesi gerekliliği açısından oldukça zorlayıcı bir problemidir.

Bu tezin kapsamında probleme iki temel yaklaşım ile çözüm getirilmeye çalışılmıştır. Bunlardan ilki literatürdeki farklı ön işleme, hedef tespiti ya da son işleme algoritmaları temel alınarak oluşturulan bir dizi adımlardan oluşur. Öncelikle, çekilen hiperspektral veri ham radyans verisi olarak kullanılmak yerine veri beyazlatma algoritmasından geçirilerek hedef ve arka planın birbirinden ayırt ediciliği önemli ölçüde yükseltilir. Daha

sonra uygulanan Savitzky Golay filtresi ile iğne tipi gürültüler giderilir ve kullanılan spektral imzaların daha genel temsil yeteneği kazanması sağlanır. Hedef tespiti için çapraz ilintileme ve spektral bilgi ayırımından oluşan iki aşamalı bir adım tercih edilmiştir. Böylece yanlış alarmlar olabildiğince azaltılır. Ayrıca hedef olarak öngörülen piksel kümeleri asgari piksel sayısı şartı ile elenerek sonuçlar daha gürbüz hale getirilir. Tüm bu adımların ardışık olarak uygulandığında ortaya çıkan yöntem özgün olup Çoklu Hedef Tespiti (ÇHT) olarak adlandırılmıştır. Diğer yaklaşım ise ÇHT içinde kullanılan son işleme adımlarının bir derin öğrenme algoritması yardımı ile yapılmasıdır. Bu amaçla ÇHT içeriğine benzer adımlarla elde edilen skor haritaları kullanılarak eğitilen evrişim temelli bir yöntem olan POSTNET ortaya çıkmıştır. Her iki yöntem de en başında hiperspektral görüntü ve referans hedef imza kümesini alıp hedef tipi, hedef skoru, sonuç haritası ve hedef bulunan piksellerin indekslerini dönecek şekilde sonuç veren bir “exe” dosyası şeklinde hazırlanmıştır. Bunun için MATLAB ve PYTHON geliştirme ortamı kullanılmıştır.

1.2. Tezin Akışı

Bölüm 2’de, hiperspektral görüntüleme teknolojisi ve uygulama alanları hakkında genel bir bilgilendirme yapılmıştır. Bölüm 3’te, hiperspektral görüntü analiziyle ilgili mevcut yaklaşımlar hakkında bilgi verilmiştir. Bu yaklaşımlar anomali tespiti odaklı, spektral ayrıştırma odaklı, spektral imza eşleştirme odaklı ve derin öğrenme odaklı olarak ayrı alt başlıklar halinde sunulmuştur. Bölüm 4’te, bu tezin konusu olan çoklu hedef tespit algoritmasının (ÇHT) işleyişi ve kullanılan ara adımlar detayları ile açıklanmıştır. Sırasıyla görüntü girdisi, referans imza girdisi, görüntü ve referans imza birleşimi, beyazlatma algoritması, Savitzky-Golay filtresi uygulaması, görüntü ve referans imza kümesinin ayrımı, tespit, grup piksel sayısına göre eşikleme ve skor kıyaslama ve karar adımları alt başlıklar halinde sunulmuştur. Bölüm 5’te, ÇHT yöntemine alternatif olarak oluşturulan, elde edilen skor haritalarına uygulanan son işleme adımlarının derin öğrenme ile gerçekleştirildiği POSTNET yöntemi anlatılmıştır. Bölüm 6’da, test için kullanılan örnek veri kümesi açıklanmış ve koşulan yöntemlerin performans sonuçları sunulmuştur. Son olarak, Bölüm 7’de, tez değerlendirmesi yer almaktadır.

2. HİPERSPEKTRAL GÖRÜNTÜLEME


Bu bölümde hiperspektral görüntü özellikleri, uygulama alanları ve kamera teknolojileri hakkında genel bir bilgilendirme yapılmıştır.

2.1. Hiperspektral Görüntü Özellikleri ve Kullanım Alanları

Çok bantlı görüntülerin analizi tek ya da 3 bantlı görüntülerin analizine göre farklı yaklaşımlara açıktır. Nesnelere şekil bilgisinden daha çok spektral uzayda temsil ettikleri konumları ile birbirinden ayrışır. Yüzlerce boyutlu bir uzayı hayal etmek güç olabilir. Ancak hiperspektral görüntüleme ile elde edilen bilgi tam da budur. İlgili piksele düşen nesnenin yüzlerce boyuta sahip bir uzaydaki konum bilgisi aslında o piksele ait bilgi vektörüdür. Bu vektör spektral imza olarak da adlandırılabilir. Böylece piksellerin uzamsal bilgilerine ek olarak oldukça büyük bir üçüncü boyut sağlanır. Bu da hem şekil hem de malzeme bilgisinin kullanılabilmesi için zengin bir içerik sunar.

Hiperspektral görüntüleme, dijital görüntülemenin gücünü ve spektroskopi bilgisini birleştirir. Hiperspektral kamera, görüntüdeki her piksel için ardışık ve çok sayıda spektral bant bilgisini sağlar. Hiperspektral veri elektromanyetik spektrumun belirli bir bant aralığında alınan çok bantlı veriden oluşur. Genellikle yüzler seviyesinde alınan bant bilgisi incelenen obje hakkında ayrıntılı bir analiz yapma olanağı sağlar. Elektromanyetik spektrum, elektromanyetik tayf olarak da adlandırılır. Bir nesnenin elektromanyetik tayfi denildiğinde o nesnenin etrafa yaydığı elektromanyetik radyasyon akla gelir. Bu radyasyon, dalga boylarına göre atom altı değerlerden başlayıp (bkz. X ışını veya Gama Işını) binlerce kilometre uzunlukta olabilecek radyo dalgalarına kadar farklı radyasyon tipleri olarak karşımıza çıkar. Elektromanyetik tayf için örnek bir görsel aşağıda (Şekil 1) sunulmuştur.


Hiperspektral görüntüleme ise genellikle elektromanyetik tayfin morötesi ile uzak kızılötesi bant aralığında çok bantlı görüntüler sağlar. Elde edilen görüntünün hangi bant aralığında olacağı ya da kaç banttan oluşacağı gibi bilgiler kullanılan kameranın özelliklerine bağlı olarak değişebilmektedir.



Şekil 1 Elektromanyetik Spektrum [1]

Normal kameralar tek ya da kısıtlı sayıda bant bilgisi sunar. Her bir piksel için genellikle görünür bant aralığında (400nm-700nm) ve 3 bant (kırmızı, yeşil ve mavi) olarak bilgi sağlar. Hiperspektral kameralar ise ilgili elektromanyetik spektrumda her bir piksel için yüzlerce banttan oluşan bir bilgi sunar. Bu bilgi sayesinde çok boyutlu uzaylarda daha karmaşık algoritmalar ile çalışma olanağı sağlanır. Ayrıca hiperspektral görüntüleme sayesinde bant bilgisi çok daha dar spektral aralıklar ile temsil edilebildiği için gözle görülemeyecek ya da spektrumun çok geniş aralıklarla temsil edildiği birkaç bantlı görüntülerde elde edilemeyecek farklılıklar ortaya çıkarılır.

Gözle bakıldığında benzer ya da aynı görünebilecek nesnelerin elektromanyetik tayf boyunca ayrıntılı incelendiklerinde kendilerine özgü bir tür parmak izi bıraktıkları görülür. Bu parmak izleri spektral imzalar olarak bilinir ve görüntüsü işlenen nesnenin barındırdığı maddeleri tanımlayabilirler. Yukarıda bahsedildiği üzere hiperspektral görüntüleme sayesinde dar bant aralıklarında yüksek bant sayısı elde edilerek bu spektral imzalara ulaşılabilir. Bu da nesne tespit ve teşhisine olanak sağlar. Görünür yakın kızılötesi bant aralığı elektromanyetik spektrumda yaklaşık 400-1000nm bant aralığına denk gelmektedir. Bu bant aralığında bitki sağlığı [2] ya da hassas tarım [3] odaklı birçok çalışma bulunur. Ayrıca kamuflej tespiti gibi askeri uygulamalarda da görünür yakın dalga hiperspektral görüntüleri kullanılabilir [4]. Aşağıda (Şekil 2) görünür yakın kızılötesi bant aralığında (Visible Near Infrared, VNIR) çalışan hiperspektral kamera ile çekilmiş bir görüntüden alınan iki temsili imza gösterimi yapılmaktadır. İlgili imza vektörlerinin birbirinden ayrıştığı görülür.



Şekil 2 VNIR spektrum aralığında gösterimi yapılan örnek 2 spektral imza

Kısa dalga kızılötesi (Short-wave Infrared, SWIR) bant aralığında malzemelerin sahip olduğu kimyasal özelliklerden dolayı, birçok farklı materyal karakteristik yansıtım ve geçirgenlik özelliği sergilemektedir. Kısa dalga kızılötesi bant aralığı, elektromanyetik spektrumda yaklaşık olarak 1000-2500 nm aralığına denk gelmektedir. Bu bölgede yapılan çalışmalara örnek olarak, mineral tespiti, çatılar ve inşaat malzemeleri gibi şehir özelliklerinin belirlenmesi, bitki örtüsü tespiti, petrol ve birçok insan yapısı madde bulunması, kar/buz/bulut/duman ayrımı, bitki durumu belirlenmesi, toprak ve bitkilerdeki su miktarının tahminini gösterilebilir. Bu bant aralığı orman yangınlarının belirlenmesinde de etkin olarak kullanılabilir [5].

Orta dalga kızılötesi (Mid-wave infrared, MWIR) ve uzun dalga kızılötesi (Long wave infrared, LWIR) bölgeleri aynı zamanda "termal kızılötesi" olarak da adlandırılır çünkü nesnenin kendisinden radyasyon yayılır ve nesneyi görüntülemek için herhangi bir harici ışık kaynağı gerekmez. Bir nesnenin bir termal görüntüleme cihazına ne kadar parlak görüldüğünü iki ana faktör belirler: nesnenin sıcaklığı ve emisyonu. Emisyon bir materyalin yüzeyinin nispi olarak radyasyon ile enerji yayma yeteneğidir. Bir nesne ısındıkça, daha fazla enerji yayar ve bir termal görüntüleme sistemine daha parlak görünür. MWIR, ışığı 3000-5000 nm spektral bantta toplar. MWIR kameralar, birincil hedef sıcaklık ölçümlerine ve hareketliliğe odaklanmak yerine yüksek kaliteli görüntüler elde etmek için kullanılır. Spektrumun MWIR bandı, kara cisim fiziği nedeniyle termal kontrastın daha yüksek olduğu bölgedir; LWIR bandında MWIR bandına kıyasla karasal nesnelere çok daha fazla radyasyon yayılırken, radyasyon miktarı sıcaklıkla daha az değişir (bkz. Planck eğrileri). MWIR görüntülerinin genellikle LWIR'dan daha iyi kontrast sağlamlarının nedeni budur. Örneğin, sıcak motorların ve egzoz gazlarının emisyon tepe noktası MWIR bandında meydana gelir, bu nedenle bu kameralar özellikle araçlara ve uçaklara duyarlıdır. LWIR, ışığı 8000-14000 nm spektral bantta toplar ve en uygun termal görüntüleme kameralarının bulunduğu dalga boyu aralığıdır. LWIR

sistemleri uygulamaları arasında termografi/sıcaklık kontrolü, kestirimci bakım, gaz kaçağı tespiti, çok geniş bir sıcaklık aralığına yayılan (ve geniş bir dinamik aralık gerektiren) sahnelerin görüntülenmesi, kalın dumanla görüntüleme vb. yer alır [6].

Morötesi bölgesi elektromanyetik spektrumda görünür spektrumdan önce gelen aralığı kapsar. Ultraviyole olarak da adlandırılan morötesi spektrumda astronomi, atmosfer bilimleri, tıp, spektroskopi vb. alanlardan örnek verilebilecek çok çeşitli uygulamalar mevcuttur [7]. Astronomlar bu spektral görüntüleri kullanarak galaksileri, yıldızları ve gezegenleri inceler; atmosferdeki ozon çalışması da bu spektral bölgede yapılır [8]. Ayrıca tıpta floresan mikroskobu kullanılarak kanserli hücreleri normal hücrelerden ayırmak için bu spektral aralıkta görüntüler işlenir [9]. Ek olarak bu bölgede kimyasal analiz elde çalışmaları da yapılır. Bu tezin içeriğinde de morötesi ve görünür bant aralığının bir kısmını kapsayan spektrumda alınan görüntüler üzerinde kimyasal madde tespiti odaklı analiz ve algoritma geliştirme faaliyetleri gerçekleştirilmiştir.

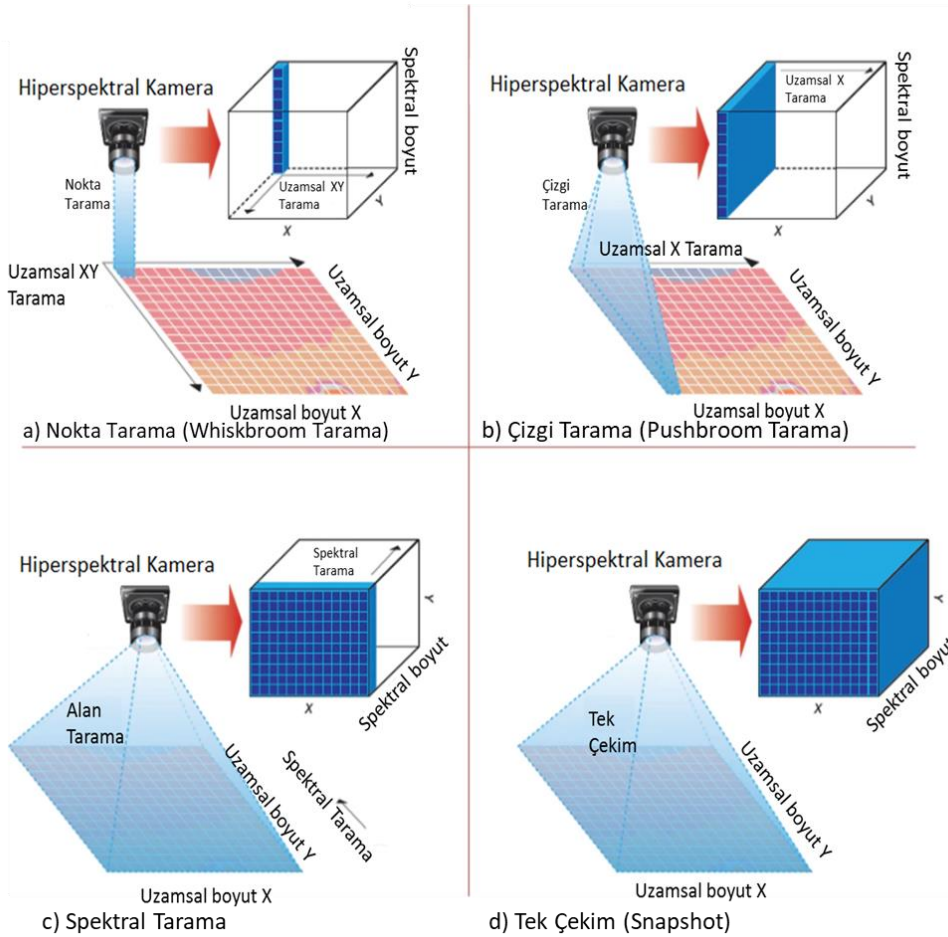
Hiperspektral görüntüleme teknolojilerinin sağlık, savunma sanayi, tarım, adli vakalar vb. birçok alanda oldukça geniş bir kullanımı mevcuttur. Bununla birlikte gıda kontrolü, atık ayrıştırma gibi endüstriyel kullanımları da yaygındır. Önceden operatör yardımıyla tek tek numune alınarak detaylı analiz sonucu gıdaya yönelik bilgiler çıkarılmaktaydı. Günümüzde SWIR spektrumda yapılan hiperspektral görüntüleme ile analiz edilen her molekülün farklı dalga boylarına veya spektral parmak izine göre içerik, yağ yüzdesi, şeker seviyesi ve tazelik gibi bilgiler bu analizleri oldukça etkin hale getirebilmektedir. Bunun yanı sıra hasat öncesi bitki örtüsünün durumu, yıllık ürün tahmini, bitki sağlığı gibi birçok alanda da hiperspektral görüntülemeyle faydalanılır. Ayrıca atık, plastik, kâğıt, metal vb. ayrıştırma amaçlı endüstriyel kullanım da yaygındır. Örneğin SWIR bantta çekim yapacak bir kamera ile akan bant üzerinde ilerleyen atıklardan plastik olanlarının konumu kolayca belirlenebilir ve el değmeden ayrıştırılabilir [10].

Özetle, hiperspektral görüntüleme teknolojisi gerek ortam içi gerek uzaktan algılama gibi birçok uygulamada ana unsur olarak kullanılmaktadır. Laboratuvar ortamında yapılan yakın çekimlerden uydular üzerinde bulunan sensörler ile binlerce kilometre uzaklığa kadar oldukça geniş bir yelpazede sağlanan bu görüntüler günümüzde birçok alanda karşılaşılan problemlere özel çözümler sunabilmektedir. Bu da gerek hiperspektral görüntüleme teknolojilerinin gerekse bu teknoloji ürünü olan görüntülerin analizinde koşturulan tespit ve analiz algoritmalarının gelişimine olanak sağlar.

2.2. Hiperspektral Kamera Genel Yapısı ve Çalışma Prensibi

Hiperspektral kameralar, dört şekilde çalışabilir: Nokta tarama kameralar, çizgi tarama kameralar, spektral taramaya dayalı kameralar ve anlık görüntü (tek çekim) kameralar. Nokta tarama (Whiskbroom) tarama kameraları bir seferde tek bir pikseli yakalar (Şekil 3a). Görüntü, kamera taraması numuneyi tararken oluşturulur ve tüm spektral bilgileri içerir. Görüntü edinimi çok zaman alıcı olsa da, yöntem çok yüksek bir spektral çözünürlük sağlar.

Nokta tarama kameralarından daha hızlı olan ve yüksek spektral çözünürlük sunan çizgi tarama (Pushbroom) kameraları, bir seferde bir hattı yakalar (Şekil 3b). Kamera, tam görüntüyü oluşturmak için örnek boyunca bu çizgiyi tarar. Nokta tarama kameralarından daha hızlı olmasına rağmen, çizgi kamera görüntülerinde örtüşme ve hareket kusurları oluşabilir.




Şekil 3 Hiperspektral kamera tarama tipleri

Spektral tarama kameraları, belirli bir dalga boyu için tüm uzamsal bilgileri tek seferde toplar (Şekil 3c). Bir hiperspektral küp, bir seferde bir görüntü / bir dalga boyuna dayalı

olarak üretilir. Spektral tarama tek bir bant için üretilen görüntü başına hızlı iken, dalga boylarını değiştirmek için gereken süre nedeniyle toplamda daha yavaş veri küpü üretir.

Hiperspektral anlık tek çekim görüntü kameraları, hiperspektral video yakalayabilir (Şekil 3d) ve hızlıdır ve hareketli nesnelere görüntülemek için idealdir. Ancak bu kameralar tipik olarak sınırlı spektral ve uzamsal çözünürlükler sunar.


Bu tezin içeriğinde kullanılan veriler çizgi tarama kamerası ile çekilmiştir. Çizgi tarama yapan hiperspektral kameranın çalışma prensibi için Şekil 4 örnek verilebilir. Görüldüğü üzere kameranın giriş açıklığından giren ışık demeti fokus aynası yardımıyla yarığa odaklanır. Yarıktan geçen demet hizalama aynası üzerinden yansıtılarak ızgara yapısına düşer. Bu yapı ışığı farklı dalga boylarına ayırır. Daha sonra farklı dalga boylarına ayrılan ışık lens optiği yardımıyla detektör üzerine düşer. Detektör boyutu spektral bant sayısı (spektral çözünürlük) ile bir çizgideki piksel sayısı (uzamsal çözünürlük) çarpımı kadar olur. Veri diziden okunduğunda, spektral bir hiperspektral görüntünün bir dilimini içerir. Bir yönde spektral bilgi sağlanırken diğerinde uzamsal (görüntü) bilgi sağlanır.



Şekil 4 Örnek hiperspektral sensör yapısı

Çizgi tarama kameraları ile görüntü çekimi genellikle aşağıdaki yollardan biriyle yapılır:

- Kameranın doğrusal hareketi: Uçağa monte edilmiş kamera ile görüntü alınması örnek olarak verilebilir. Havadan görüntü alınırken sistem navigasyon altyapılarını (GPS ve IMU) kullanarak kameranın anlık konum ve yönelim bilgisini tutar. Bu da çekimi yapılan görüntünün koordinatlandırılmasını sağlar. Uçağın hızı kameranın görüntü yakalama hızıyla uyumlu olarak seçilir. Örnek bir hava sistemi aşağıda (Şekil 5) gösterilmiştir.




Şekil 5 Örnek hava platformu [11]

- Kameranın döndürülmesi: Döner platform üzerine monte edilen kamera ile görüntü alınması örnek olarak verilebilir. Döner platformun hızı kameranın görüntü yakalama hızına göre ayarlanarak görüntü oluşturulur. Örnek bir döner platform aşağıda (Şekil 6) gösterilmiştir.



Şekil 6 Örnek döner platform [11]

- Sahnenin doğrusal çevirisi: Konveyör bandın hareketi veya benzeri hareketler ile sahne hareket ederken sabit duran kamera ile görüntü alınması örnek verilebilir (Şekil 7).



řekil 7 Yürüyen bant sistemi örneđi [11]

3. HİPERSPEKTRAL GÖRÜNTÜ ANALİZİYLE ALAKALI MEVCUT YAKLAŞIMLAR

Bu bölümde hiperspektral görüntü analiziyle ilgili mevcut yaklaşımlar hakkında bilgi verilmiştir. Bu yaklaşımlar anomali tespiti odaklı, spektral ayrıştırma odaklı, spektral imza eşleştirme odaklı ve derin öğrenme odaklı olarak 4 farklı alt başlık halinde sunulmuştur.

3.1. Anomali Tespiti Odaklı Yaklaşım

Anomali tespiti, basit olarak ele alındığında, görüntüye ait herhangi bir ön bilgi olmadığı ya da görece homojen yapıya sahip arka planda farklılık oluşturacak durumların tespiti amaçlı yapılan çalışmaları kapsar. Ancak aranan nesne ya da durum hakkında kabaca bile olsa bilgi sahibi olduğunda daha iyi başarımlar sağlamak amacıyla bu bilgilerin kullanıldığı görülebilir. Örneğin sadece belirli bantlarda görünür olan bir nesne için ilgili bantlarda çalışan anomali tespit algoritması hazırlamak ya da boyut bilgisinin kestirilebildiği durumlarda iç içe pencereler yardımıyla daha kompleks bir anomali tespiti çalışması yapmak gibi birçok yardımcı etmen performansı doğrudan ya da dolaylı yoldan etkileyebilir.

Anomali tespitinin temelinde arka plan modellemesi vardır. Literatürde öne çıkan yöntem ise 1990'da Reed ve Yu tarafından geliştirilen RX algoritmasıdır [12]. Algoritmanın temelinde test edilen pikselle arka planın ortalaması arasındaki farkın normalize edilmesi yatmaktadır. Algoritma uygulanırken her piksel için bir güven aralığı sunulmaktadır. Eğer güven aralığı belirlenen eşik değerinden büyükse piksel anomali olarak kabul edilir. RX anomali tespit algoritması spektral imzası hakkında bilgi sahibi olunmayan pikselleri ortak değişinti (kovaryans) matrisi bilinmeyen arka plandan ayırma amacıyla üretilmiştir. Arka plan modellemesinin ortalaması ve ortak değişinti matrisi tahmin edilebilen, çok değişkenli Gauss dağılımları ile modellenebileceğine dayandırılarak oluşturulmuştur. Algoritma arka planın homojen dağılım gösterdiğini varsaymaktadır ve bu nitelikteki görüntüler için yüksek performans göstermektedir.

Standart RX algoritması global uygulanır ancak lokal versiyonları da mevcuttur [13]. Global RX algoritması tüm veri kümesinden faydalanırken, lokal RX algoritmasında önceden belirlenen pencereler içinde tanımlanan arka planlarla çalışılmaktadır. Bu noktada global algoritmaların varsaydığı homojen arka sınıf tanımlaması yetersiz olabilirken, lokal tanımlamalarda da kullanılacak pencere boyutu önemli bir faktör

olmaktadır. Lokal RX yöntemlerinde anomali hedefinin niteliği yöntem parametrelerinin belirlenmesinde büyük önem teşkil etmektedir. Lokal yöntemler küçük anomaliler için daha yüksek performans göstermektedir, ancak yüksek işlem gücü gerektirmektedir.

Probleme bir başka yaklaşım ise verinin homojen dağılım göstermediği durumlarda karışım modelleri kullanımınıdır. Bu kapsamda karşımıza çıkan yöntem Gauss Bileşim Modeli tabanlı RX yöntemidir. GBM yönteminin heterojen verilerde karmaşık sınıf dağılımlarını daha iyi modellemesi avantaj olarak nitelendirilebilirken, aynı yöntem için bileşen sayısının doğru tespiti gereksinimi dezavantaj olarak karşımıza çıkmaktadır [14].

Anomali tespiti odaklı doğrusal olmayan ve alt uzay tabanlı yöntemler mevcuttur. Doğrusal olmayan yöntemlerde arka planın mevcut boyutlulukta doğru modellenemeyeceği, ancak yüksek boyutluluğa taşındığı zaman daha doğru karar sınırlarının öğrenilebileceği savunulmaktadır. Bu kapsamda Çekirdek-RX yöntemi öne çıkmaktadır [15]. Gauss dairesel tabanlı çekirdek fonksiyonu hiperspektral analizlerde en çok kullanılan çekirdek fonksiyonu olarak bilinmektedir ve Çekirdek-RX uygulamasında kullanılmaktadır. Yöntemin başarısı kullanılacak çekirdek fonksiyonuna doğrudan bağlıdır ve fonksiyonun doğru belirlenmesini gerektirir.

Doğrusal olmayan yöntemlerde karşımıza çıkan bir diğer yaklaşım ise destek vektör veri tanımlama algoritmasıdır. Bu algorithmada eldeki veri üzerinde tek sınıflı destek vektör makine sınıflaması yöntemi ile destek bölgeleri belirlenmektedir [16]. Yöntem verinin dağılımı hakkında herhangi bir varsayımda bulunmamakla beraber, arka planı bir en küçük hiperküre ile modellemektedir. Bu hiperküre dışında olan pikseller ise anomaliler olarak tespit edilmektedir. Algorithmada normal sınıfın etrafında, kapsadığı normal obje sayısını en büyükmeye çalışarak uygulanan hiperküre yöntemi, aynı zamanda en küçük hacimde/yarıçapta bir çevreleme yapmaya çalışmaktadır. Bu hacim ya da yarıçapın sınırları anomali objelerinin tespitini sağlayacak biçimde oluşturulmaktadır.

Alt uzay yöntemlerinde ise arka plan ve anomalilerin farklı alt uzaylar tarafından ifade edilebileceği varsayılmakta ve arka planı ifade eden alt uzay öğrenilmektedir. Girdi verinin bir alt uzaya izdüşümü alınarak, yine izdüşüm vektörleri ile tanımlanmış arka plan üzerinde işlem uygulanmaktadır. Bu algorithmada seçilecek alt uzay boyutu önem taşımaktadır. Yaklaşımın avantajı olarak verinin homojen dağılım göstermesine daha az duyarlı oluşu gösterilebilir. Doğrusal yöntemlerin de çekirdek tabanlı makine öğrenimi yöntemi ile doğrusal olmayan versiyonları oluşturulabilmektedir. Çekirdekler aracılığı ile

doğrusal olmayan özelliklerin örtük değerlendirilmesi eğitim tabanlı yöntemlerle ya da doğrusal yöntemlerle elde edilemeyecek verilerin ortaya çıkarılmasını sağlamaktadır.

Anomali tespitinde en temel zorluk arka planın karmaşıklığı ve bu karmaşıklığın modellenmesidir. Dolayısı ile algoritmaların elde edilen verilerde ve gerçek test ortamında koşturulması sırasında ortaya çıkacak performans farkları temel olarak bu karmaşıklığa bağlıdır. Verilerin elde edilmesinde farklı arka plan karmaşıklığının sağlanması ve algoritmaların bu farklara göre performanslarının belirlenmesi yararlı olacaktır. Ancak söz konusu arka plan karmaşıklığının oluşturulmasında bir sınır olmadığından en kötü ve en iyi senaryo seçimlerinin yapılması ve performans aralığının buna göre oluşturulması önemlidir.

3.2. Spektral Ayırıştırma Odaklı Yöntemler

Spektral ayırıştırma odaklı yöntemler piksellere ait spektral imzaların karışım olduğu fikrine dayanır. Bu karışım birden fazla saf vektörün doğrusal ya da doğrusal olmayan biçimde birleşmesi ile oluşur. Ortaya çıkan yeni spektral imza onu oluşturan saf imzalar cinsinden formüle edilmeye çalışılır. Bunun için kimi yöntemler ilgili saf imzaları girdi olarak kullanırken kimileri ise ilgili saf imzaları da görüntüden çıkarmayı amaçlar. Uzamsal çözünürlüğün yeterli olmadığı, ya da incelenen materyalin homojen olmadığı durumlarda spektral ayırıştırma odaklı yöntemler öne çıkabilmektedir.

Literatürdeki spektral ayırıştırma makaleleri incelendiğinde, büyük çoğunluğunda doğrusal karışım modelinin kullanıldığı ve bu model üzerinden ayırıştırma yöntemlerinin türetildiği görülmektedir. Bu yöntemlerden genel kabul görmüş olanlar piksel yoğunluk indeksi (PYİ), N-Bulucu, otomatik morfolojik son eleman çıkarımı (OMSEÇ) ve zirve bileşen analizi (ZBA) yöntemleridir.

PYİ algoritması, spektral ayırıştırma problemini çözen yaygın algoritmalarından biridir. Bu nedenden dolayı MATLAB ve ENVI gibi programlarda hazır uygulanmış olarak gelir. Bu algoritmanın birçok farklı türevi de bulunmaktadır. Otomatik PYİ ve hızlı iteratif PYİ yöntemleri örnek olarak verilebilir [17]. Rastgele PYİ yöntemi ile normalde denetimli olan PYİ yöntemi denetimsiz hale getirilmiştir [18]. Ayrıca PYİ algoritmasının paralel uygulaması gerçekleştirilmiş ve bu şekilde algoritmanın çalışma zamanında ciddi bir düşüş gözlenmiştir [19].

N-Bulucu görüntüdeki saf piksellerin tespitinde kullanılmaktadır. Gürültüden çokça etkilendiği için kullanılabilirliği azdır. Algoritmada saf piksel bulunmaması durumunda, en az karışıma sahip pikseller tespit edilmektedir [20].

Literatürde çokça rastlanan bir diğer yöntem ise OMSEÇ'tir. Görüntü içinde saf veya safa yakın piksellerin bulunması önkoşulu ile çalışan bu algoritma, görüntünün spektral ve uzamsal özelliklerini birlikte kullanarak son eleman çıkarımı yapmaktadır. Sadece son elemanları bulmakla kalmayıp, son elemanların bolluk oranlarını da hesaplayan OMSEÇ algoritması, N-Bulucu ve PYİ algoritmalarına göre daha yüksek bir başarıya sahiptir [21]. Bununla beraber çalışma zamanı üstel olarak artmaktadır.

Denetimsiz spektral ayrıştırma yapan yöntemlerinden biri olan ZBA, literatürde genel kabul görmüş yöntemlerden bir tanesidir. Görüntü içinde saf piksel bulunması varsayımı ile çalışan ZBA, gürültüden az etkilenen yöntemler arasında öne çıkmaktadır [22]. Algoritma, bolluk oranlarının pozitif olması ve toplam bolluk oranlarının bir olması kısıtlamaları ile çalışır. Belirli koşullar altında, literatürde sıkça kullanılan yöntemlerden daha yüksek performans gösteren algoritmalar da mevcuttur. Doğrusal karışım modelini çözen geometrik yaklaşımlardan bir tanesi de en küçük hacim dönüşümü-negatif olmayan matris etkinleştirme yöntemi olarak açıklanmıştır [23]. Bu yöntemde PYİ yönteminin aksine görüntü içinde saf piksel bulunma zorunluluğu yoktur. Bu yöntem sonuçları iyi olsa da sadece sentetik veriler üzerinde denenmiştir.

(Ren2003)'deki çalışmada dikey alt-uzay izdüşümü kullanılarak alt piksel seviyesinde hedef tespiti yapılmıştır. Bu yöntemde görüntüde saf piksel bulunma zorunluluğu olmadığı gibi, aranan hedefin imzasına da ihtiyaç duyulmamaktadır. Yapılan çalışmada alınan sonuçlar, algoritmanın hedefleri iyi bir performansla bulduğunu göstermiş, fakat algoritma diğer yöntemlerle karşılaştırılmamıştır [24].

SPICE algoritması, görüntüde kaç son eleman bulunduğunu, hem bu son elemanları hem de son elemanların katışım oranlarını otomatik olarak tespit etmektedir [25]. KIDDO algoritması SPICE algoritmasını geliştirerek, daha iyi performanslar elde etmiştir [26, 27].

Spektral ayrıştırma yöntemlerinin varsayımları çok çeşitlidir. Bu yöntemlerden bazıları, görüntü içerisinde saf piksel olduğu varsayımıyla çalışmaktadır. Kimi yöntemler görüntüdeki son eleman sayısına ihtiyaç duyarken, kimi yöntemler gürültüden çok etkilenmektedir. Bu nedenle tek bir mükemmel yöntem seçmek mümkün değildir.

Görüntünün özellikleri çok iyi analiz edilip, uygun ayrıştırma yönteminin seçilmesi gerekmektedir. Bunun dışında çok başarı gösteren yöntemlerden bir kısmı sadece yapay veri üzerinde çalışıldığından dolayı bu yöntemlerin gerçek veriye uygulandığında başarı durumlarının ne derece etkileneceği kestirilememektedir.

3.3. Spektral İmza Eşleştirme Odaklı Yöntemler

Spektral imza eşleştirme odaklı yöntemler görüntüde daha önce belirlenmiş olan hedefleri çeşitli yöntem ve dönüşümler kullanarak aramaya dayalı çalışmalardır. Hedefe ait bir ya da daha fazla temsili imza doğrudan ya da belirli ön işleme adımları sonrasında görüntüde aranır.

Spektral imza eşleştirme için yaygın olarak kullanılan yöntemlerden birisi uyumlu süzgeç algoritmasıdır (USA) [28]. Genellikle radar uygulamalarında da kullanılan uyumlu süzgeç algoritması görüntüden çıkarılan kovaryans matrisini kullanarak referans spektral imzanın her piksel için skor haritasını oluşturur. Uyumlu süzgeç algoritmasının birçok varyasyonu bulunmaktadır. Örneğin bir çalışmada [29] arka planı bir bütün olarak ele almak yerine parçalara bölerek bölütlenmiş kovaryans matrisler üzerinden uyumlu süzgeç algoritması çalıştırılmıştır. Yine aynı çalışmada görüntünün Mahalonobis uzaklığı temel alınarak bölütlere ayrılmasına dayanan yöntemler kıyaslanmıştır. Hiperspektral görüntülerde gaz tespiti amaçlı bir başka çalışmada ise uyumlu süzgeç performansını iyileştirmek için k ortalama kullanılarak bölütleme yapılmıştır [30].

Literatürde sıkça rastlanan yöntemlerden biri de geliştirilmiş benzerlik testidir (GBT). Temelleri 1980'li yıllara dayanan bu yöntem de birçok varyasyonu ile denenmiş ve literatüre katkı sağlamıştır [31]. İkili hipotez testinde belirli bir eşikten büyük olma durumunda bir hipotez sağlanırken küçük olma durumunda ise diğeri sağlanır. Bu eşik için en uygun değer basit hipotezler için benzerlik testiyle belirlenir. Ancak gerçek hayatta bu hipotezler genellikle bilinmeyen parametreler içerir. İşte bu gibi durumlarda basit hipotezlerin test edildiği benzerlik testine göre bilinmeyen parametreler içerebilecek hipotezlerin test edilmesi için geliştirilmiş benzerlik testi kullanılır. Geliştirilmiş benzerlik testinde bahsi geçen bilinmeyen parametreler en yüksek benzerlik tahminleri ile yer değiştirilir. GBT algoritması da görüntü ve imza arasında benzerlik ararken kovaryans matrisinden faydalanır.

Spektral açı bulucu (SAB), spektral açı eşleyici, spektral açı haritası gibi isimlerle anılan bir başka yöntem de görüntüdeki pikselleri ve referans imzayı çok bantlı uzayda vektörler

olarak kabul eder ve bu vektörler arasındaki açığa göre benzerlik haritası çıkarır. Açı daraldıkça iki vektörün birbirine olan uzaklığı azalır ve benzerlik artar. Bu yöntem basit ve hızlı olmakla beraber gerçek hayat problemlerinde etkili çözümler çıkarabilmektedir. Ancak gürültü oranı ya da homojenlik azaldıkça yöntem başarısı da düşebilmektedir. Literatürde bu yöntemin karşılaştırma ya da hedef tespiti amaçlı kullanıldığı birçok çalışma mevcuttur [32], [33]. Yöntem üzerinde geliştirmeler yapılan örnek bir çalışma [34] da ise spektral imzalara dönme ve öteleme tabanlı bir düzenleme uygulanmaktadır. Çalışmada bu işlemin hem veri uzayı gerçekleştirilmesi hem de çekirdek uzayı gerçekleştirilmesi sağlanmıştır. Buna benzer yaklaşımlar diğer hedef tespit yöntemleri için de uygulanabilir.

Literatürde kullanımına rastlanan yöntemlerden biri de çapraz ilintileme-çapraz korelasyon yöntemidir [35]. Bahsi geçen çalışmada yöntem orta dalga kızılötesi görüntülerde karbondioksit gazı tespiti için kullanılmaktadır. Öncesinde uygulanan veri dönüştürme ve bant seçimi ön işleme adımlarıyla çapraz ilintileme skorlarını iyileştirir. Çapraz ilintilemede iki sinyalin korelasyonuna bakılır ve aradaki korelasyon değeri büyüdükçe benzerlik oranı artar. Genellikle normalizasyon uygulanmış çapraz korelasyon hesaplanır. Çapraz ilintileme yöntemi basit ve hızlı çalışır.

Kullanılan bir başka yöntem olarak spektral bilgi ayrımı (SBA) karşımıza çıkar [36]. SBA, pikselleri referans spektrumlarla eşleştirmek için bir sapma ölçüsü kullanan bir spektral sınıflandırma yöntemidir. Sapma ne kadar küçükse, piksellerin benzer olma olasılığı o kadar yüksektir. Belirtilen maksimum sapma eşliğinden daha büyük bir ölçüme sahip pikseller sınıflandırılmaz. Chay [36] 'ün çalışmasında bahsedilen spektral bilgi sapmasının spektral açı bulucuya karşı avantajları ön plana çıkarılmıştır. Çalışmanın amacı SBA ölçütünün multispektral ve hiperspektral görüntülerdeki pikseller arası benzerlik ve farklılık ölçümleri için spektral açı bulucuya kıyasla daha olasılık temelli bir benzerlik ölçütü olduğunu göstermek ve iki farklı yöntemin performans kıyaslamasını birçok açıdan yapabilmektir. Çalışmada kırmızı toprak ve siyah çalı imzalarının ayrımı temel alınarak spektral açı bulucu ve spektral bilgi ayrımı yöntemleri kıyaslanmıştır. SAB verilerine bakarak spektral imzalar arasında yakınlık-farklılık ayrımını yapabilmek oldukça zor iken, SBA verilerine bakarak kırmızı toprak imzasını, siyah çalı imzasından kolaylıkla ayırabildiği belirtilmiştir.

Pratik uygulamalarda bazı çalışmalar spektral açı bulucu gibi basit yöntemlerin uygun yaklaşımlarla yeteri kadar yüksek başarımlar vereceğini ifade etmekte, bazı çalışmalar ise

çok daha karmaşık çözümlenmelere gitmektedir. Spektral uyum tabanlı yöntemlerin en büyük riski spektral değişkenlik olarak gözükmektedir. Farklı zamanlarda farklı şekillerde yakalanan verilerde oluşacak değişkenlik sınırlı kalması durumunda bazı algoritmalar tarafından karşılanabilir olmakla beraber değişkenliğin çok olması durumunda ek ön-işleme ihtiyacı olabilir. Uzamsal çözünürlüğün düşük olduğu durumlarda piksel içerisinde kalan alan büyük olacağı için ve o alan içindeki nesnelerin imzaları karışacağı için aranan hedefe ait imzayı ayırabilmek ve hedefi tespit edebilmek zorlaşacaktır. Bu noktada spektral ayrıştırma yöntemlerinden faydalanmak gerekecektir. Ek olarak birden fazla yöntemi bir arada kullanarak da daha iyi sonuçlar almak mümkün olabilmektedir [37]. Bu tezde de benzer şekilde farklı yöntemler bir araya getirilerek özgün bir yaklaşım öne çıkarılmıştır.

3.4. Derin Öğrenme Odaklı Yöntemler

Derin öğrenme (aynı zamanda derin yapılandırılmış öğrenme, hiyerarşik öğrenme ya da derin makine öğrenmesi) bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Yani en az bir adet yapay sinir ağının (YSA) kullanıldığı ve birçok algoritma ile bilgisayarın eldeki verilerden yeni veriler elde etmesidir. Derin öğrenme gözetimli, yarı gözetimli veya gözetimsiz olarak gerçekleştirilebilir [38]. Derin yapay sinir ağları pekiştirmeli öğrenme yaklaşımıyla da başarılı sonuçlar vermiştir [39].


Son yıllarda, derin yapay sinir ağları birçok görüntü işleme alanında kullanıldığı gibi hiperspektral görüntü analizi ve sınıflandırma amaçlı da yaygın olarak kullanılmaktadır. [40, 41, 42, 43, 44, 45, 46]. Basit olarak ele alınacak olursa, örneğin sınıflandırma amaçlı kullanımda, sınıflardan eğitim amaçlı örnek spektral imza kümeleri toplanır. Daha sonra toplanan eğitim kümesi kullanılarak daha önce hazırlanmış olan derin yapay sinir ağı eğitilir. Bu eğitim sonrasında test amaçlı verilen bir spektral imzanın hangi sınıfa ait olacağına derin yapay sinir ağı karar verir. Aynı bakış açısı sınıflandırma yerine hedef tespiti için de ele alınabilir. Bu durumda sınıflar sadece hedef ya da hedef ve arka plan olarak belirlenebilir. Derin öğrenme uygulamalarında eğitim kümesinin doğru etiketlenmiş olması ve büyük sayıda veri içermesi oldukça önemlidir. Yetersiz veri sayısı öğrenmenin istenen seviyede gerçekleşmesine engel olur. Ayrıca yanlış etiketlenmiş veriler doğal olarak yanlış öğrenmeye sebep olabilir. Bu yüzden doğru hazırlanmış ve yeterli sayıda veri içeren eğitim kümesine sahip olmak da en az derin öğrenme algoritmasının tasarımı kadar önemli olabilmektedir.

Derin öğrenme algoritmalarında bir diğer önemli etken de tasarlanan ağ yapısı ve parametrelerdir. Hazır olan ağların eğitimi ve parametre güncellemesi bir seçenek olabilir. Bunun yanı sıra kullanılması planlanan yapay sinir ağı probleme özel olarak yeniden de tasarlanabilir. Genellikle spektral bilgi uzun ömürlü kısa-dönem bellek (LSTM) kullanılarak ifade edilirken, ek olarak uzamsal bilgiler evrimsel sinir ağı (CNN) ile ifade edilmektedir [40]. Uzun kısa süreli bellek (Long Short-Term Memory) derin öğrenme alanında kullanılan yapay bir tekrarlayan sinir ağı (RNN) mimarisidir. Standart ileri beslemeli sinir ağlarının aksine, LSTM'nin geri bildirim bağlantıları vardır. Yalnızca tek veri noktalarını (görüntüler gibi) değil, aynı zamanda tüm veri dizilerini (konuşma veya video gibi) işleyebilir. Spektral imza da farklı spektral bantlar için elde edilmiş ve bant sayısı boyutlu bir vektör olarak tanımlanabilir. Bu da hiperspektral görüntü analizi için LSTM kullanımını mantıklı kılar. Buna ek olarak 3 boyutlu evrimsel sinir ağı kullanımı ile de öğrenme algoritmaları geliştirilmektedir.

4. PROBLEM TANIMI VE VERİ KÜMESİ

Yoğun güvenlik önlemleri alınan bölgelerde her türlü tehlikeyi olabildiğince önce tespit etmek ve gerekli aksiyonları gerçekleştirmek adına birçok teknolojiye dayanılarak faydalanılmaktadır. Havaalanları da güvenlik önlemlerinin olabildiğince katı olarak uygulandığı bu alanlara örnek olarak verilebilir. Bu tezin konusu olan problem ise olası tehlikeli kimyasal maddelerin bulaşabilme ihtimaline karşı ayakkabılar üzerinde bu maddelerin tespitine yönelik faaliyetlerdir. Eser miktarda sayılabilecek kimyasal maddelerin hiperspektral analiz yöntemleri ile tespiti amacıyla farklı arka plan malzemeleri üzerine ilgili kimyasal maddeler yerleştirilerek hiperspektral görüntü toplanmıştır.


Bu tezde çalışılan hiperspektral veriler ultraviyole ve yakın kızıl ötesi spektrumda çekilmiştir. İlgili veriler Hollanda merkezli çok uluslu bir firmaya ait geliştirme aşamasında olan bir sensör ile firma tarafından toplanmıştır. Çizgi tarama prensibine göre çalışan sensör konveyör bant yardımı ile hareket ettirilen ve aktif olarak aydınlatılmış nesneye ait hiperspektral görüntü çekmektedir. Çekilen bu görüntüler ile ayakkabı üzerinde eser miktarda bulunan tehlikeli kimyasal madde tespitine yönelik bir veri kümesi oluşturulmuştur. Dört farklı hedef tipi için dört farklı arka plan üzerinde toplanan hiperspektral görüntüler ile çalışılmıştır. Bu arka planlar sırasıyla siyah deri, siyah polyester, kahverengi deri ve gri skai malzemeler olup tahta bir ayakkabı kalıbına (Şekil 8) yapıştırılarak veri toplanmıştır. İlgili arka plan malzemelerine yerleştirilen hedef miktarları oldukça az (500ng ile 10000ng arası) olup genellikle görüntüde kapsadığı alan 2-10 piksel arasındadır. Ayrıca hedef yerleştirilmeden sadece arka plan çekimleri ile boş veri toplanmıştır.



Şekil 8 Hiperspektral görüntüsü çekilen örnek materyal görseli (kimyasal madde kahverengi deri ortasındaki beyaz maddedir.)

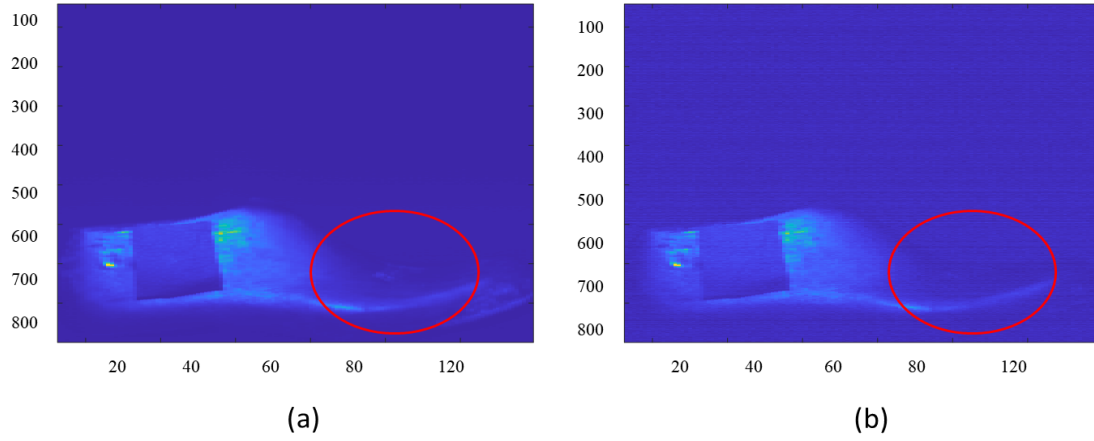
Kamera tarafından yapılan çekimler görüntü girdi verisi olarak kullanılır. Veri “csv” formatında olup $M \times N$ boyutlu matris şeklinde kayıtlıdır. Burada N spektral bant sayısını ifade ederken M ise taramadaki piksel sayısıdır. Kullanılan veriler 548 bantlı olduğu için N sayısı 548’dir. M ise piksel sayısı olduğundan çekim yapılan süreye bağlı olarak değişmektedir. Elde edilen verinin görsel olarak anlamlı hale gelmesi için öncelikle 2 boyutlu (Piksel x Bant) olan verinin 3 boyutlu (Satır x Sütun x Bant) hale getirilmesi gerekmektedir. Bu yapıldıktan sonra istenen bant ya da bant grubu ortalamasına ait tek bantlı görsel sağlanabilir. Ya da seçilecek olan 3 banta ait “Sahte renk” görsel oluşturularak renkli görsel sağlanabilir.

Örnek hiperspektral veriden sağlanan tek bant (Şekil 9) görseli aşağıda sunulmuştur. İlgili görselde görüleceği üzere hedef madde genellikle arka plan malzemesinin ortasına konumlandırılır. Arka plan malzemesi ise tahtadan yapılmış bir ayakkabı kalıbı üzerine yapıştırılır.



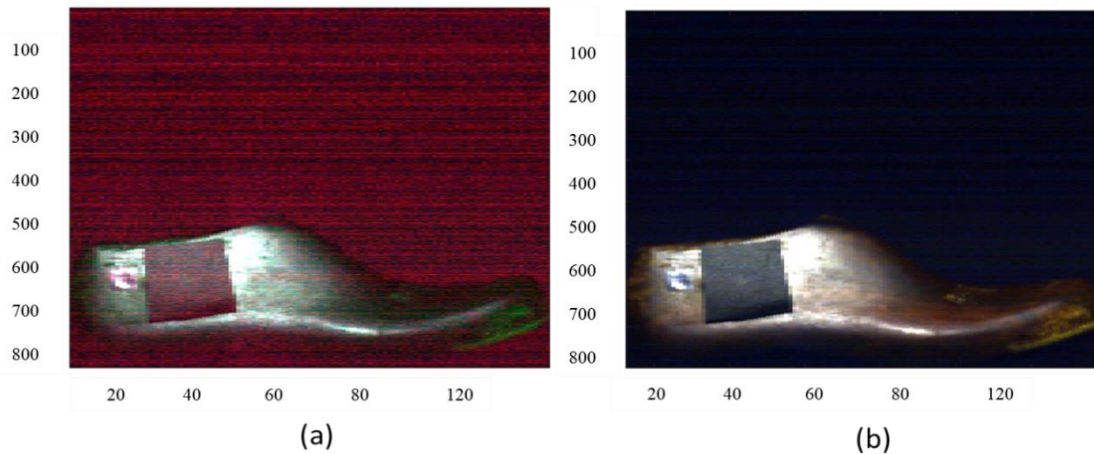
Şekil 9 Örnek tek bant görüntüsü

Şekil 10 ise tek bant ve bant ortalamasının kıyasını göstermektedir. Yuvarlak halkalar içindeki bölge incelendiğinde görüleceği üzere ayakkabı kalıbı üzerindeki bazı bölgeler bant ortalaması verisinde daha belirgin iken tek bant verisinde bu belirginlik yoktur. Bu durumun tersi de mümkündür. Zengin spektral bant bilgisinin farklı spektral aralık ya da bantlarda farklı alanları belirginleştirebileceğine örnek olması açısından anlamlı bir karşılaştırmadır.



Şekil 10 Bant ortalaması ve tek bant görselleri karşılaştırması (a) Bant ortalaması görseli (b) Tek bant görseli

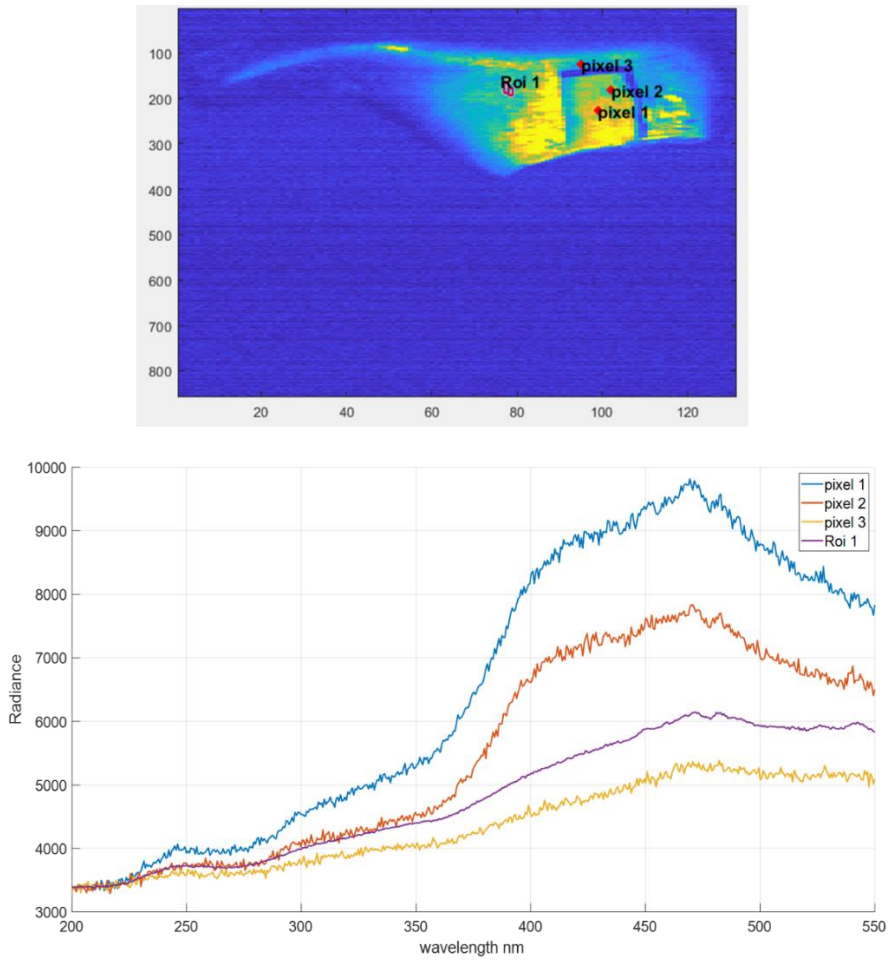
Hiperspektral görüntüde seçilecek herhangi 3 bant ile sahte renk görüntüsü oluşturulabilir. Bu sayede daha önceden anlamlı bulunmuş bantlar öne çıkarılarak daha iyi bir görsel sağlanabilir. Aşağıda (Şekil 11) aynı örnek hiperspektral veriden alınmış 2 farklı sahte renk görseli sunulmuştur. Görüleceği üzere seçilen bantlara göre görseller de değişmekte ve farklı alanlar ön plana çıkabilmektedir. Sağdaki görsel 450, 150 ve 350 numaralı bantlar kullanılarak oluşturulan sahte renk görselidir. Soldaki ise 50, 450 ve 350 numaralı bantlar ile oluşturulmuştur. Seçilen tek bantta bile fark olması durumunda elde edilen görseller birbirinden oldukça farklı olabilmektedir.




Şekil 11 Sahte renk görselleri karşılaştırması (a) 50/450/350 bantları ile elde edilmiştir. (b) 450/150/350 bantları ile elde edilmiştir.

Yukarıda sunulan tek bant, bant ortalaması ya da sahte renk görseli yaratma adımların hepsi görsel kullanım kolaylığı için yapılır. Tespit algoritması spektral imza tabanlı çalıştığı için 2 boyutlu girdi üzerinden çalışır. Oluşturulan bu görseller tespit edilen piksellerin konumunu operatöre göstermek için kullanılır.

Spektral imza hiperspektral görüntülerde piksel ya da piksel grubu ortalaması alınarak elde edilen ve bant sayısı kadar veriden oluşan bilgi vektörüdür. Aşağıda Şekil 12 ile örnek bir hiperspektral veride farklı piksellerden alınan spektral imza görseli sunulmuştur. Örnek bant görselinde görüldüğü üzere 3 farklı piksel ve bir piksel grubu (ROI, “region of interest”) seçilmiştir. Spektral imzaların üst üste çizdirilmiş grafik görseline bakıldığında piksel imzalarına göre piksel grubu ortalaması alınarak oluşturulan imzanın daha yumuşak olduğu görülür. Bu beklenen bir durumdur. Grup büyüdükçe gürültü de azalacaktır. Ancak bu durum spektral imzanın ayırt ediciliğini de olumsuz etkileyebilir. Bu yüzden olabildiğince saf olan piksel ya da piksel grubu ortalaması imzaları toplanmıştır. Bu da genellikle 1-5 arası piksele denk gelmektedir.



Şekil 12 Temsili spektral imza gösterimi



Şekil 13 Yanlış alarm örneği (a) Yanlış alarm alınan bölge kırmızı halka içindeki parlak alandır. (b) Yanlış alarm imzası ile aranan hedef imzasının üst üste gösterimidir.

Veri toplama düzeneği gereği arka plan malzemeleri dikdörtgen şekilde kesilerek tahta ayakkabı kalıbı üzerine yerleştirilmektedir. Bu da malzeme kenarlarını belirgin olarak ortaya çıkarmaktadır. Genellikle bu kenarlardan farklı hedef tipleri için yanlış alarm alınabilmektedir. Örnek bir yanlış alarm görseli Şekil 13 ile sunulmuştur. Görüleceği üzere ilgili yanlış alarm bölgesinden alınan spektral imza ile görüntüde aranan hedef referans imzası birbirine yakın spektral karakter göstermektedir. Bunun gibi yanlış alarmların önüne geçmek adına hedef tespiti ve sınıflandırması için tek bir tespit algoritması kullanmak yerine birden fazla yöntemi bir araya getirerek çok adımlı bir tespit yöntemi geliştirilmiştir. İlgili yöntem Çoklu Hedef Tespiti Yöntemi başlığında sunulmuştur. Ek olarak son işleme adımlarının derin öğrenme yardımı ile gerçekleştirilmesi için bu tez ile geliştirilen yöntem POSTNET Yöntemi başlığında açıklanmıştır. Her iki yöntemde kodlar Firma ile paylaşılmıştır. Firma kendi hazırladığı veri setinde kodları koşturarak sonuçları paylaşmıştır. İlgili çalışma Deneysel ve Sonuç başlığında anlatılmıştır.

5. ÇOKLU HEDEF TESPİTİ YÖNTEMİ

Spektral açılı bulucu, uyumlu süzgeç, genelleştirilmiş benzerlik testi, çapraz ilintileme gibi imza tabanlı hedef tespitine yönelik yöntemlerin tek başına ve herhangi bir ön işleme adımı olmaksızın doğrudan uygulanması başarılı çıktılar vermemiştir. Bazı görüntüler için yeterli görünse de birçoğunda hem yanlış alarm hem de hedefin tespit edilmemesine neden olmuştur. Hızlı çalışan, her görüntü için ayrı imza toplamayı gerektirmeyen, yanlış alarm oranı düşük ve doğru pozitif oranı yüksek bir yöntem ihtiyacı duyulmuştur. Bu noktada öncelikle veriyi doğrultma amaçlı beyazlatma algoritmasının uygulanması ile hedef arka plan ayrımının başarılı bir şekilde yapılabileceği görülmüş ve yanlış alarm sayısı azaltılmıştır. Seçilen temsili imzalar yardımı ile hedef temsil imza kümeleri oluşturulmuştur. Bu sayede her görüntü için ayrı imza toplamaya gerek kalmamıştır. Ayrıca iki adımlı hedef tespit aşaması ve son işleme adımları ile sonuçların doğruluk oranları olabildiğince iyileştirilmeye çalışılmıştır.

Bu tezde önerilen çoklu hedef tespiti metoduna ait akış diyagramı aşağıda (Şekil 14) gösterilmiştir. Diyagram incelendiğinde ilk adımın görüntü ve imza kümesinin bir araya getirilerek tek bir veri matrisi yaratma olduğu görülür. Bu adım uygulanacak ön işleme adımlarından biri olan ve aynı zamanda diyagramda ikinci adım olan beyazlatma işlemi öncesinde gerçekleştirilir. Sonrasında beyazlatma algoritması yardımıyla hiperspektral veri ilk ön işleme adımından geçer. Burada amaç bir çeşit doğrultma işlemi uygulayarak arka plan ve hedef imzalarının ayırt ediciliğini arttırmaktır. Beyazlatma sonrası hiperspektral verideki gürültüyü bastırmak ve imzaları daha genel formlarda temsil edebilmek adına Savitzky Golay filtresi kullanılmaktadır. Bu adım piksel temelli bir işlemdir. Birleştirilmiş veride uygulanması ya da görüntü ve imzalara ayrı ayrı uygulanması fark etmemektedir. Bu adım sonrasında görüntü ve referans imzalar tekrar ayrılmaktadır.



Şekil 14 Çoklu hedef tespiti yöntemi akış diyagramı

Önişleme adımları sonrasında hedef tespiti adımları başlamaktadır. Hedef tespiti iki aşamalı olarak gerçekleştirilir. Bunlardan ilki çapraz ilintileme yöntemi, ikincisi ise spektral bilgi ayrımı yöntemidir. Bu adımlar hedef bazlı uygulanır. Hedef tipleri Tip 1, Tip2, Tip3 ve Tip 4 olarak adlandırılır. Her tip için farklı arka planlardan toplanmış referans imza kümeleri bulunur. Örneğin Tip 1 ele alındığında her piksel için N tane referans imzaya ait çapraz ilintileme skoru üretilir. Bu adım sonrası ilk eşikleme yapılır. Daha önceden belirlenmiş sabit bir eşik değerinden büyük çapraz ilintileme skoruna sahip pikseller seçilir. Diğer piksellerin skorları sıfırlanır ve onlar için ikinci adıma geçilmez. İkinci adıma geçen pikseller için aynı imza kümesi kullanılarak spektral bilgi ayrımı skoru üretilir ve bu skorlardan en yüksek değere sahip olanı Tip 1 skoru olarak atanır. Aynı adımlar tüm hedef tipleri için tekrarlanır. Böylece her piksele ait farklı tip hedefler için hedef sayısınca skor üretilmiş olur.

Hedef tespit skorlarının üretilmesinden sonra son işleme adımlarına geçilir. Bu adımlar son eşikleme, grup piksel sayısı analizi, skor kıyası ve karar adımlarından oluşur. Son eşikleme adımında ilk eşiklemede olduğu gibi belirli bir skordan büyük olan pikseller seçilir ve diğer pikseller sıfırlanır. İlgili spektral bilgi ayrımı skor değerleri hedef özel olup skor haritalarının manuel olarak analizi ile daha önceden belirlenmiştir. Bu adım sonrasında her piksel için hedef tiplerine ait nihai skorlar belirlenmiş olur. Bu skor sıfır

ya da ilgili hedef tipine ait imzalardan elde edilen en yüksek spektral bilgi ayrımı skorudur. Böylece hedef tipi sayısınınca nihai skor haritası elde edilmiş olur. Daha sonra grup piksel sayısı analizi adımına geçilir. Bu adımda her hedef için ilgili skor haritalarında sıfır olmayan piksel grupları için daha önceden belirlenmiş sayıda piksel içermeye şartı aranır. Örneğin piksel sayısı en az 2 olarak seçilen bir hedef için skor haritalarında oluşan tek piksellik sonuçlar sıfırlanır. Gruplarda piksel sayısı kontrol edilirken pikseller arası yatay, dikey ya da çapraz komşuluk kontrol edilir. Bu adımdan sonra artık her hedef tipi için nihai skor haritaları oluşur. Son bir adım olarak hedeflere ait skor haritalarında en yüksek skorlar kıyaslanır ve en yüksek skoru veren hedef tipi ve skor haritası seçilerek hedef tespiti sonlandırılır.

5.1. Görüntü Girdisi


Kamera tarafından yapılan çekimler görüntü girdi verisi olarak kullanılır. Veri “csv” formatında olup $M \times N$ boyutlu matris şeklinde kayıtlıdır. Burada N spektral bant sayısını ifade ederken M ise taramadaki piksel sayısıdır. Kullanılan veriler 548 bantlı olduğu için N sayısı 548’dir. M ise piksel sayısı olduğundan çekim yapılan süreye bağlı olarak değişmektedir.

Görüntü okunduktan sonra daha önceden belirlenmiş bir eşik değerinden daha büyük bir değere sahip pikseller sıfırlanır (5.1.1). Bu adımın gerçekleşmesi için bu şartı herhangi bir bantta sağlaması yeterlidir.

$$mImg(max(mImg, [], 2) > E, :) = 0 \quad (5.1.1)$$

- $mImg$: Hiperspektral görüntü
- E : Eşik değeri

Aşağıda (Şekil 15) bu işlemten önceki ve sonraki durum örnek veri üzerinde gösterilmiştir. Görüleceği üzere yüksek değerli piksellerin sıfırlanması ayakkabı kalıbı üzerindeki bazı bölgeleri etkisiz kılmaktadır. Bu işlemdeki amaç yüksek değere sahip olan fakat hedef olmayan bazı yanlış alarmların önüne geçmektir. İlgili eşik değeri ayarlanabilir olarak tasarlanmıştır. Koşuturulan ve performansı sunulan verilerde 10000 olarak seçilmiş olup istenildiği durumda veri ya da veri kümesine özel olarak etkisiz kılınabilir ya da değiştirilebilir.




Şekil 15 Yüksek değerli piksellerin sıfırlanması (a) Sıfırlama öncesi (b) Sıfırlama sonrası silinmiş piksel grupları yuvarlak daireler içinde siyah olarak görülmektedir.

5.2. Referans İmza Girdisi

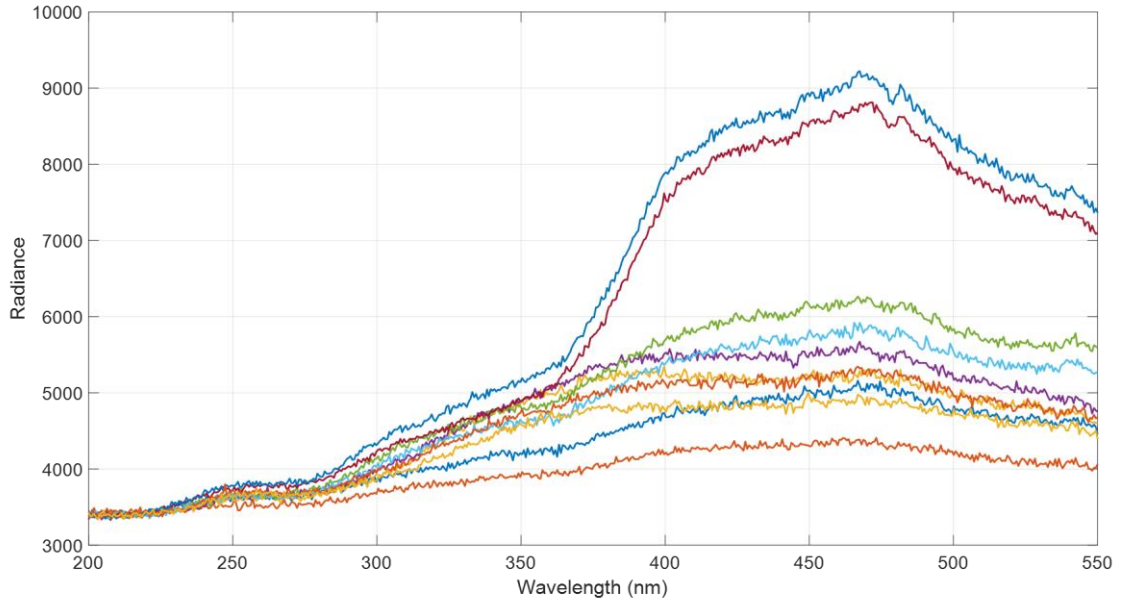
Referans imzalar daha önceden çekilmiş hedef tiplerini içeren ham görüntülerden yukarıda gösterilen örnekteki gibi seçilmiş imzalardan oluşmaktadır. Her hedef tipi için farklı arka planlardan toplanmış imzalardan oluşan bu küme $R \times N$ boyutunda ve “csv” formatında kaydedilmiştir. İmzalar seçilirken gözle analiz yapılarak hedef içeren piksel ya da piksel grupları kullanılmıştır. R bütün hedef tipleri için toplam referans imza sayısını temsil ederken N ise spektral bant sayısını temsil eder. Örneğin 4 hedef tipi için 5’er imza kaydedildiği varsayıldığında R sayısı 20 olacaktır. Bu çalışmada hedef tespit faaliyetleri için sırası ile hedef 1 için 8, hedef 2 için 10, hedef 3 için 8 ve de hedef 4 için 18 olmak üzere toplamda 44 imza toplanmıştır. Bu imzalar her hedef tipi için 3 farklı arka plan malzemesine (siyah deri, kahverengi deri, siyah polyester) yerleştirilmiş 50’şer örnek incelenerek elde edilmiştir. Bu amaçla toplamda 600 hiperspektral veri incelenerek 44 imza çıkarılmıştır.

Aşağıda her hedef tipi için toplanan referans imzalar ayrı grafikler halinde üst üste gösterilmiştir. İmzalar 2 ayrı temel küme olarak çıkarılmıştır. Bunlardan ilkinde (Şekil


16-Şekil 19) normal ham imzalar bulunurken diğesinde (Şekil 20-Şekil 23) ise imzanın alındığı görüntünün ortalamasının imzadan çıkarılması sonrası elde edilen imzalar bulunur. İkinci kümenin çıkarılmasının sebebi beyazlatma algoritması içinde bulunan ortalama çıkarma adımıdır. Referans imzalarından test görüntüsünün ortalaması yerine alındığı görüntünün ortalamasının farkının alınması daha doğru imzalar elde edilmesini sağlamıştır.




Şekil 16 Hedef 1 spektral imzaları (ilk küme)



Şekil 17 Hedef 2 spektral imzaları (ilk küme)



Şekil 18 Hedef 3 spektral imzaları (ilk küme)




Şekil 19 Hedef 4 spektral imzaları (ilk küme)

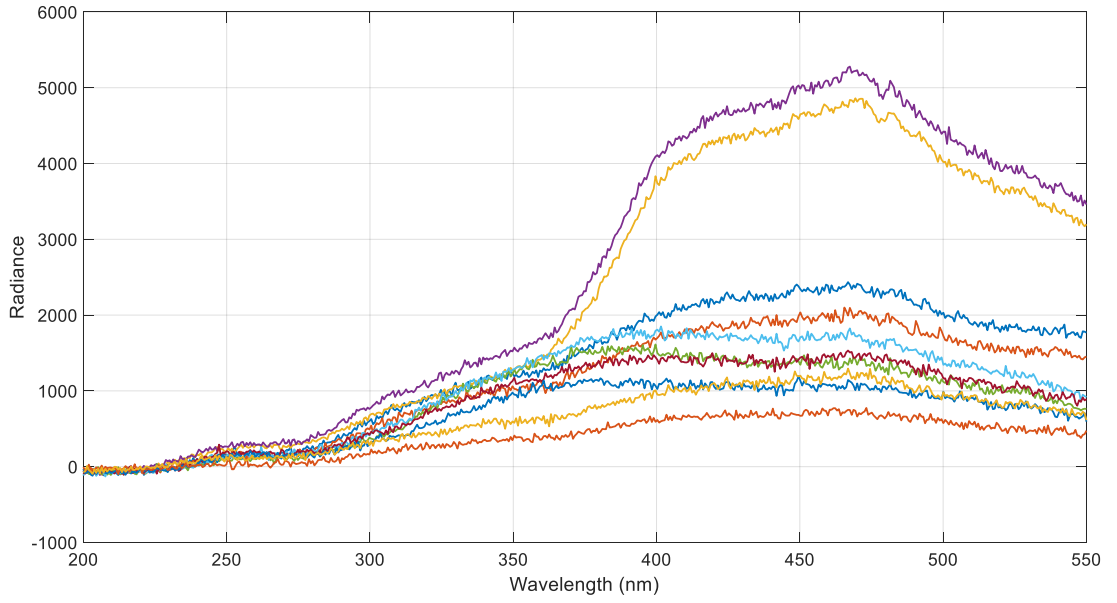
Hedef imzalarının kendi içerisinde farklılık gösterme nedeni farklı arka planlardan toplanmış olmasıyla beraber verilerdeki farklı veri çekim koşullarıdır. Toplanan veriler ham radyans verileri olduğundan ve herhangi bir reflektans ya da benzeri dönüştürme işlemi yapılmadığından ışık, açı, uzaklık vb. etkenler verinin şiddetini doğrudan

etkileyebilmektedir. Veriler firma tarafından sağlandığı için veri çekim koşullarına müdahale şansı olmamıştır. Ancak veri toplama ekibine olabildiğince geri bildirim yapılmaya çalışılmıştır. Ayrıca bir ya da birkaç piksele düşecek kadar küçük hedefler üzerinde çalışıldığı için piksellerdeki saflık oranı azalabilmektedir. Dolayısıyla arka planın hedef imza üzerindeki etkisi yükselebilir. Bunun önüne geçmek adına spektral imzalar olabildiğince saf piksellerden seçilmeye çalışılmıştır.


İkinci küme (Şekil 20-Şekil 23) toplanırken ilgili referans imzadan alındığı görüntünün tüm piksellerine ait ortalama spektral imza çıkarılmıştır. Bu adım sonrası elde edilen imzalar incelendiğinde şiddet olarak birinci kümeye göre daha düşük değerlere sahip oldukları görülür. Ancak bu adımın asıl önemi beyazlatma algoritmasında bulunan ortalama çıkarma adımının daha doğru çalışmasına olanak sağlamasıdır. Yukarıda değinilen nedenlerden ötürü görüntülerde radyans değerleri aynı malzemeye ait olsa bile şiddet olarak değişkenlik gösterebilmektedir. Bu da iki farklı görüntünün ortalama imzasının birbirinden farklı büyüklükte değerlere sahip olmasına neden olur. Bu yüzden ortalama çıkarma adımı bu tip farklılıklar barındıran görüntü ve imza kümelerinin denk gelmesi durumunda doğru çalışmaz. Bu da elde beyazlatma sonrası elde edilen referans imzanın istenmeyen derecede yanlış olmasına neden olur. Bu sebeple ikinci kümenin kullanımı daha yüksek performans sağlamıştır. Bu konu beyazlatma algoritması anlatılırken detaylı olarak örneklendirilmiştir.




Şekil 20 Hedef 1 spektral imzaları (ikinci küme)



Şekil 21 Hedef 2 spektral imzaları (ikinci küme)



Şekil 22 Hedef 3 spektral imzaları (ikinci küme)




Şekil 23 Hedef 4 spektral imzaları (ikinci küme)

5.3. Görüntü ve Referans İmza Birleşimi

Bu adımın yapılma sebebi beyazlatma algoritmasının test görüntüsü ve imza kümesine aynı anda uygulanmasıdır. Diğer bir deyişle gerek görüntü gerekse imza kümesinin aynı beyazlatma matrisi ile çarpılmasıdır. İlk aşamada yapılan ön çalışmalarda spektral imzalar beyazlatılmış olarak toplanmıştır. Bu da her imzanın ve de test görüntüsünün ayrı ayrı beyazlatma matrisleri ile çarpılmasına neden olmaktadır. Bunun yerine aranan

imzaların test görüntüsünün bir parçasıymış gibi varsayılarak ilgili görüntü ile birleştirilerek elde edilen kümenin beyazlatma adımına tabi tutulması daha iyi sonuçlar vermiştir.

İmza veri dizisi, görüntü veri dizisinin sonuna eklenir (Şekil 24). Son dizi boyutu $(M + R) \times N$ 'dir, burada N spektral bant sayısını ifade eder. $M + R$ ise görüntüdeki piksel sayısı ile aranacak referans imza sayısının toplamıdır. Yeni birleşik veri dizisi, $C = M + R$ olduğunda $C \times N$ boyutundadır.



Şekil 24 Görüntü ve referans imza kümesi birleşimi gösterimi


5.4. Beyazlatma Algoritması

Beyazlatma algoritması çoklu hedef tespiti metodunun temel taşlarından biridir. Bu adım görüntü ve referans imzalara uygulanan doğrultma işlemi olarak da adlandırılabilir. Her ne kadar ön işleme adımı olarak görülse de algoritma omurgasının en önemli parçalarından biridir. Bu adım sayesinde hedef ve arka plan ayırt ediciliği belirgin bir şekilde artmakta ve hedef tespiti algoritmalarının performansı yükselmektedir.

Beyazlatma işlemi, öz tabanındaki verileri alır ve ölçeği normalleştirmek için her boyutu öz değere böler. Bu dönüşümün geometrik yorumu, eğer giriş verisi çok değişkenli bir Gauss ise, beyazlatma verisinin sıfır ortalama ve özdeşlik kovaryans matrisine sahip bir Gauss verisi olacağı şeklindedir. Beyazlatma, verilerin kovaryans matrisi birim matris olacak şekilde dönüştürülmesidir. Bu nedenle beyazlatma özellikleri birbiriyle ilişkilendirir. İki adımda incelenebilir:

- Dekorelasyon: Başka bir deyişle, orijinal verilerin en büyük varyansa sahip olduğu eksenlerin koordinat eksenlerine hizalanması için verileri eşleyen bir dönüş işlemidir. Ortaya çıkan kovaryans matrisi köşegendir.
- Ana eksenlerin her biri birim uzunlukta olacak şekilde ölçeklendirme. Veriler, söz konusu eksen boyunca varyansın birden büyük veya küçük olmasına bağlı olarak tek tek eksenler boyunca sıkıştırılır veya uzatılır. Ortaya çıkan kovaryans matrisi

özdeşliktir. Şekil 25'te beyazlatma öncesi ve sonrası veri dağılımı örneği sunulmuştur.



Şekil 25 (a) Orijinal veri dağılımı (b) Dekorelasyon işlemi (c) Beyazlatılmış veri [47]

Bu çalışmada ZCA Beyazlatma algoritması kullanılmaktadır. Beyazlatma algoritması aşağıda verilen eşitliğe göre uygulanmaktadır:

$$Z_{ij} = \sum_{k=1}^N (X_{ik} - \mu_k) \cdot W_{kj} \quad (5.4.1)$$

Parametreler aşağıda verilmiştir:

X_{ik} : Girdi matris (C x N)

$\mu_k = \frac{1}{C} (\sum_{i=1}^C X_{ik})$ Girdi matristen elde edilen ortalama vektör

W_{kj} : Beyazlatma matrisi (N x N)

Beyazlatma matrisi ise aşağıdaki eşitlikler ile yaratılır:

$$W = \sqrt{(C-1)} V \cdot T \cdot V^T \quad (5.4.2)$$

$$T = R^{\frac{1}{2}} \quad (5.4.3)$$

$$R = (D + eps \cdot I)^{-1} \quad (5.4.4)$$

$$I_{ij} = \begin{cases} 1, & \text{if } i = j \\ 0, & \text{if } i \neq j \end{cases} \quad (5.4.5)$$

eps : Sabit değer (örn. 0,0001)

I_{ij} : Birim matris (N x N)

V ve D matrisleri çarpanlarına ayırma amaçlı kullanılan tekil değer ayrışımı (TDA) (5.4.6) ile elde edilmektedir. TDA girdisi olan A matrisi ise (5.4.7) ile elde edilmektedir.

$$A = V \cdot D \cdot U^T \quad (5.4.6)$$

$$A_{ij} = \sum_{k=1}^M (X_{ik} - \mu_k) \cdot (X_{kj} - \mu_k) \quad (5.4.7)$$

X_{ki} : Girdi matrisi (C x N)

$\mu_k = \frac{1}{C} (\sum_{i=1}^C X_{ik})$ Girdi ortalama vektörü


Z_{ij} : Çıktı matrisi (C x N)

(5.4.3) ile gösterilen matris karekökünü alma işlemi Schur ayrışması ile yapılır. Schur ayrışması şu şekildedir: Eğer A, karmaşık girişlere sahip bir $n \times n$ kare matris ise, A ve A'nın kökü aşağıdaki şekilde elde edilebilir. Burada Q ($Q^* = Q^{-1}$) bir birim matris ve U bir üst üçgen matrisidir. A'nın özdeğerleri U'nun çapraz değerleridir.

$$A = QUQ^* \quad (5.4.8)$$

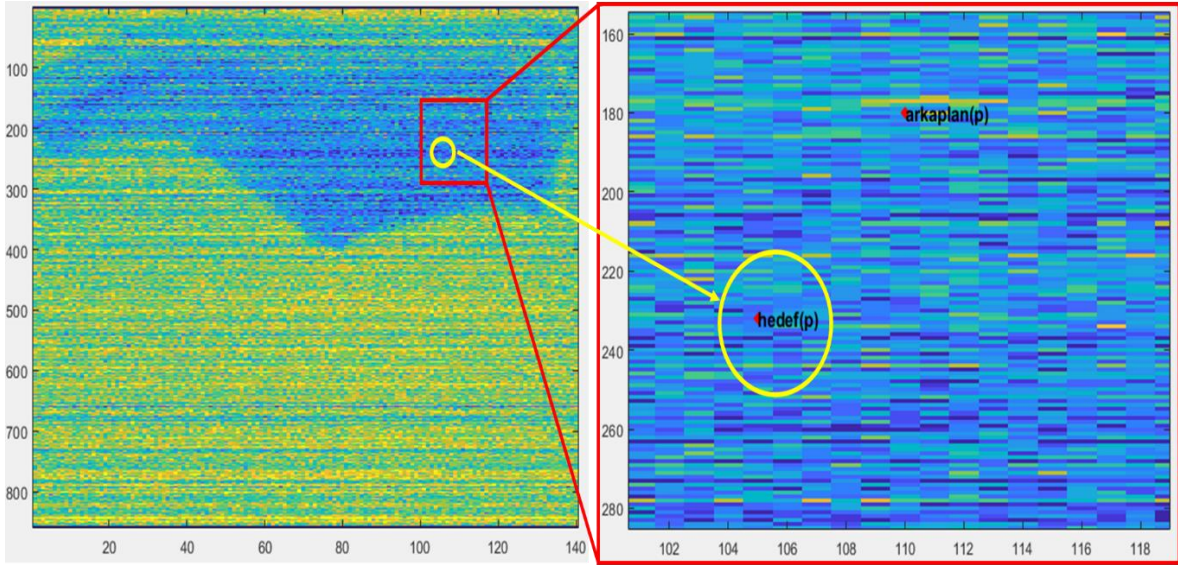
$$A^{\frac{1}{2}} = QU^{\frac{1}{2}}Q^* \quad (5.4.9)$$

Beyazlatma adımında 2 ayrı hiperspektral görüntüden elde edilen örnek beyazlatma matrisleri aşağıda Şekil 26 ile gösterilmiştir. N X N olarak elde edilen bu matrisler beyazlatılacak veri ile çarpılarak adım tamamlanır. Bu çalışmada kullanılan hiperspektral veriler 548 bantlı olduğu için 548x548 boyutunda beyazlatma matrisleri yaratılır.

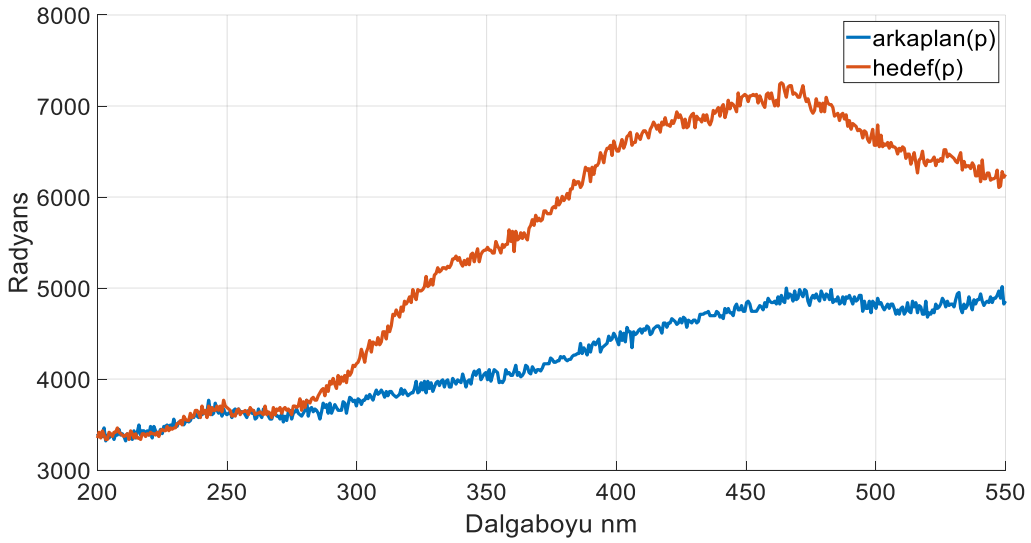


Şekil 26 Örnek beyazlatma matrisleri

Beyazlatma işlemi sonrasında hedefin arka plana göre ayırt ediciliği yükselmektedir. Bu gerek spektral bantlara ait renk haritaları incelendiğinde gerekse imza temelli çalışan hedef tespit yöntemleri ile yapılan denemelerde görülmüştür.




Şekil 27 Ham veri örnek bant (253nm) görüntüsü



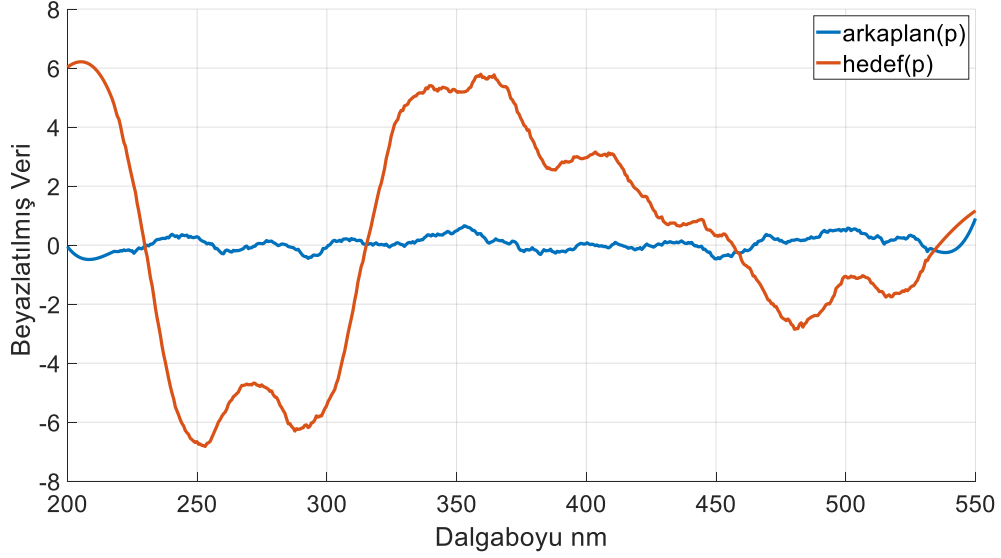
Şekil 28 Ham veriden alınan hedef ve arka plan spektral imzaları

Yukarıda ham radyans hiperspektral veriye ait örnek banttan alınan renk haritası gösterilmiştir (Şekil 27). İlgili görsel incelendiğinde ayakkabı kalıbı ve üzerindeki diğer nesneler bu bantta tek bir renk olarak görünmektedir. Herhangi bir ayırt edicilik yoktur. Soldaki görsel verinin tamamını temsil ederken sağdaki görsel ise dikdörtgen içine alınmış alanın yakınlştırılmış halidir. İlgili görüntüdeki örnek hedef ve arka plan spektral imzaları ise aynı görselin altında sunulmuştur (Şekil 28). İmzalar incelendiğinde örnek olarak

gösterilen 253nm’de imzaların ayırt edici özellik göstermediği görülür. Bununla birlikte ilerleyen bantlarda ise hedef ve arka planın ayırt edilebilir olduğu düşünülebilir. Aşağıda (Şekil 29) ise aynı hiperspektral veriye beyazlatma ve Savitzky-Golay filtresi uygulandıktan sonra elde edilen yine aynı banta ait (253nm) renk haritası sunulmuştur. İlgili görsel incelendiğinde hedef ve arka plan birbirinden kolay bir şekilde ayırt edilebilir. Arka plan sarı renklere sahip iken hedef mavi renkler arka plandan ayrılır. Beyazlatma ve Savitzky-Golay filtresi adımları uygulanmış hiperspektral veriden alınan hedef ve arka plana ait spektral imzalar incelendiğinde iki imzanın birbirinden farklı karakter sergilediği görülür. Arka plan düz bir dağılım gösterirken hedef ise özellikle ultraviyole bantlarda belirgin bir ayırt edicilik sunar.




Şekil 29 Beyazlatılmış veri örnek bant (253nm) görüntüsü



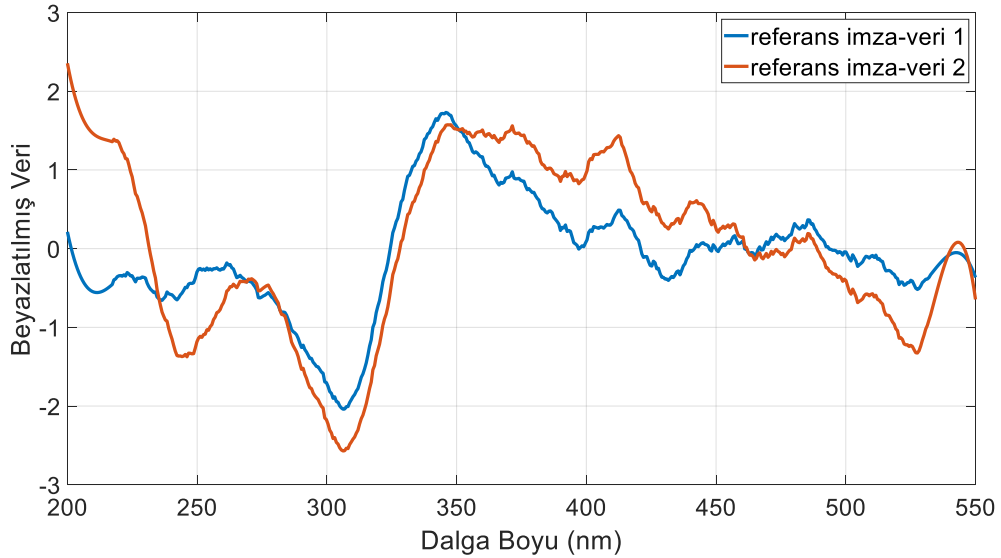
Şekil 30 Beyazlatılmış veriden alınan hedef ve arka plan spektral imzaları

Şekil 28 incelendiğinde tek başına hedef ve arka planın ham veri kullanarak da ayırt edilebilir olduğu kanısı oluşabilir. Çünkü her ne kadar ilk bantlarda imzalar ayırt edilebilir olmasa da ilerleyen bantlarda ayırt edilebilir görünebilir. Ancak unutulmamalıdır ki arka plandan sadece bir piksel imzası karşılaştırılmıştır. Örneğin ham imzalar baz alındığında ayırt ediciliği yüksek gibi görünen bir banta (450nm) ait ham radyans renk haritası ve başka bir banta ait beyazlatılmış veri renk haritası aşağıda Şekil 31 ile sunulmuştur. Soldaki görsel incelendiğinde 450nm'ye ait ham radyans renk haritasında hedef kırmızı halka içinde parlak olarak görünmesine karşın görüntünün birçok farklı yerinde benzer parlaklığa sahip büyük alanlar göze çarpar. Bu alanlar yanlış alarm sebepleri olabilmektedir. Üstelik çalışılan hedeflerin ayırt ediciliği malzeme bakımından ultraviyole bantlarda daha yüksektir. Bununla birlikte 253nm'ye ait beyazlatılmış görselde hedef arka plandan net bir şekilde ayırt edilebilir.



Şekil 31 (a) Ham radyans görseli (450nm) (b) Beyazlatılmış veri görseli (253nm)

Beyazlatma işlemi daha önce de belirtildiği üzere hem test görüntüsüne hem de referans imzalara aynı beyazlatma matrisi kullanılarak uygulanmaktadır. Bu beyazlatma matrisi ise daha önce toplanmış referans imzaların test görüntü ile birleştirilmesi sonucu elde edilen matrise yukarıda bahsi geçen beyazlatma adımları uygulanarak elde edilir. Dikkat edileceği üzere bu durum her test verisine özel olarak referans imza kümesini de dinamik olarak değiştirir. Bu durum aşağıdaki (Şekil 32) spektral imza görseli ile daha iyi anlaşılabilir. Aynı referans imzanın farklı iki test görüntüsü ile beyazlatma işleminden geçmesi sonrasında elde edilen imzalar üst üste sunulmuştur. Görüleceği üzere referans imza aynı olsa da farklı test verileri ile dinamik olarak değişmektedir.

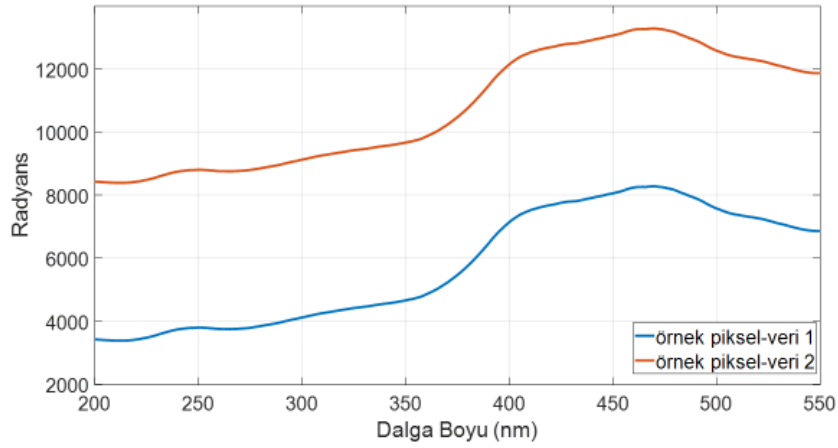


Şekil 32 Aynı referans imzanın farklı iki test verisi ile beyazlatılması

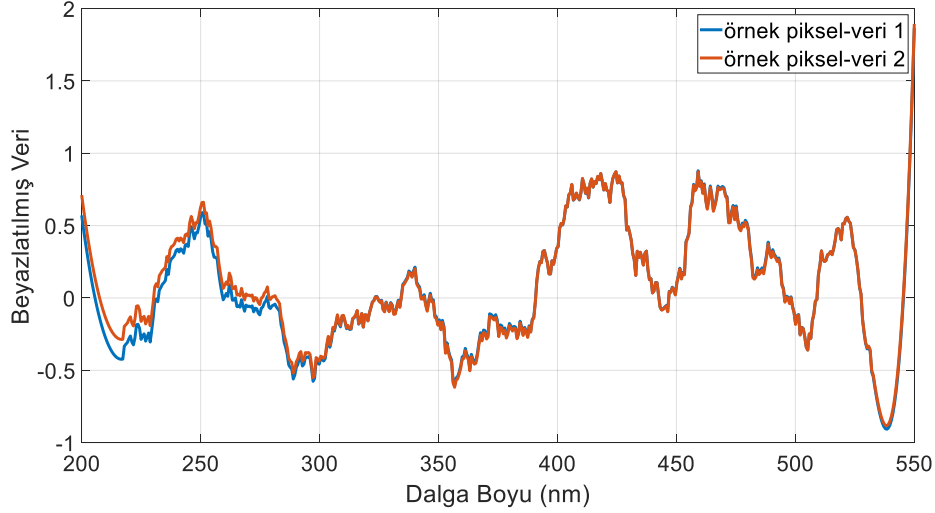
Beyazlatma algoritması içerisinde 5.4.1 nolu eşitlikte görüldüğü üzere veri kümesinin ortalamasının veri kümesinden çıkarılması adımı vardır. Bu adım referans imzaların test

görüntüsüne olduğu gibi entegre edilmesi durumunda bazı imza-test görüntüsü çiftlerinde beyazlatma sonrası uyumsuzluğa neden olabilmektedir. Bu durum örnek bir koşturma ile açıklanmıştır.

Seçilen hiperspektral veri, önce olduğu gibi daha sonra ise tüm piksellerine 5000 değeri eklenerek Şekil 33 ile gösterilmiştir. Bu verilerden ilki veri 1 diğeri ise veri 2 olarak adlandırılmıştır. Spektral karakter değişmez iken şiddetin değişmesinin görüntüden alınan aynı piksel değerlerinin beyazlatılmış hallerine etkisi ise Şekil 34 ile gösterilmiştir. Beklendiği gibi beyazlatılmış imzalar birbirine oldukça yakındır. Aradaki az farkın sebebi ise 5000 değerinin görüntüye entegre edilen referans imzalara eklenmemesi sebebiyle oluşan ortalama vektör farkıdır.

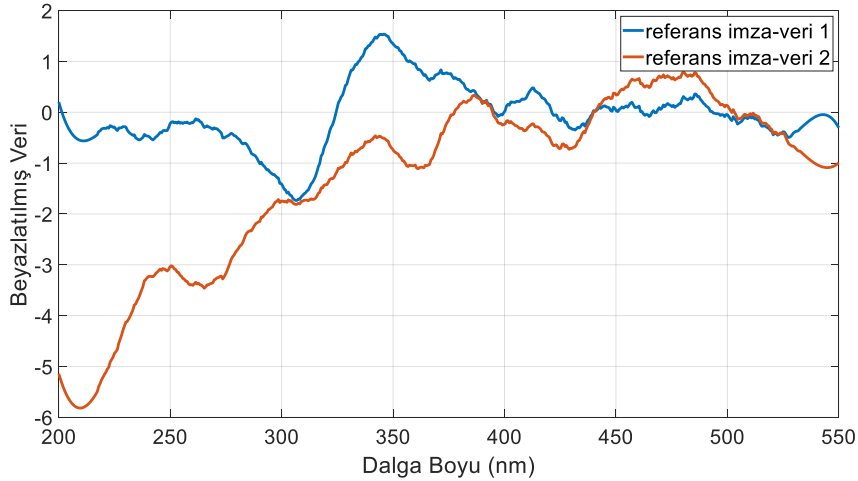


Şekil 33 Aynı piksele ait radyans eğrileri (Veri 1 ve Veri 2)



Şekil 34 Aynı piksele ait beyazlatma eğrileri (Veri 1 ve Veri 2)


Ancak başka bir görüntüden elde edilen referans hedef imzası veri 1 ve veri 2'ye eklenerek yapılan beyazlatma sonrası aynı referans hedef imzasından elde edilen beyazlatılmış imzaların birbirinden oldukça farklı karakter sergilediği görülür. Bunun nedeni veri 2'ye eklenen 5000 değerinin veri 2'nin ortalama imzasını şiddet olarak oldukça yukarı taşımasıdır. Büyüyen bu ortalama imzanın da görece küçük kalan hedef referans imzasından çıkarılması sonucu ortaya çıkan yeni imza hedef imzasından çok farklı olabilmektedir. Bu da beyazlatılmış imzaların birbirinden oldukça farklı olmasına neden olur (Şekil 35).



Şekil 35 Aynı hedef referans imzasına ait beyazlatma eğrileri (Veri 1 ve Veri 2)

Ortaya çıkan bu uyumsuzluğun önüne geçmek için hedef referans imzaları hangi görüntüden alındıysa o görüntünün ortalaması ilgili referans imzadan çıkarılarak referans imza kümesi yaratılır. Test verisinin piksellerinden ise ilgili test verisinin

ortalaması çıkarılır. Diğer adımlar aynı şekilde uygulanarak beyazlatma işlemi sona erer. Aşağıda veri 1 ve veri 2 kullanılarak bu şekilde yapılan işlem sonrası elde edilen hedef referans imzası beyazlatılmış eğrileri sunulmuştur (Şekil 36).




Şekil 36 Aynı hedef referans imzasına ait beyazlatma eğrileri (Veri 1 ve Veri 2)

Görüleceği üzere referans imza veri 1 ve veri 2 ile beyazlatıldığında aynı sonuç alınmaktadır. Bu da test görüntülerinde aydınlatma vb. sebepli olabilecek şiddet farklarının referans imzanın beyazlatma sonrası spektral karakterini değiştirmesini önler.

Bu başlıkta sunulan ve beyazlatma işlemi uygulanmış olduğu belirtilen tüm görseller beyazlatma adımına ek olarak Savitzky-Golay filtresi de uygulanmış verilere aittir. İlgili filtre imzaları yumuşatma amaçlı kullanılmış olup kendi başlığında detaylandırılmıştır.

5.5. Savitzky-Golay Filtresi Uygulama

Savitzky Golay filtresi gürültü giderme ve sinyal yumuşatma amaçlı kullanılmaktadır. Vektör tabanlı uygulanan bir fonksiyon olduğundan beyazlatma algoritması sonrası oluşan girdi matrisin her satırı için ayrı ayrı uygulanır. Savitzky Golay filtresi kullanımında iki önemli parametre bulunmaktadır. Bunlardan birisi uygulanacak olan filtre polinom derecesi, diğeri ise girdi vektörde uygulanacak olan filtre için pencere genişliği seçimidir. Pencere genişliği büyüklüğü uygulanacak olan yumuşatma işleminin baskınlığı ile doğru orantılıdır. Bu çalışmada, yapılan denemeler sonrasında, polinom derecesi 3, pencere genişliği ise 55 olarak seçilmiştir. Örnek bir uygulama Şekil 37 ile gösterilmiştir.




Şekil 37 SGF uygulanmamış ve uygulanmış beyazlatılmış imza eğrileri

SGF uygulanması sayesinde malzemeye ait bilgi korunurken çekim şartları ya da gürültü sebebiyle oluşabilecek farklılıklar önlenir. Bu da görece az sayıda spektral imza ile hedef karakterini temsil etmenin önünü açar.

5.6. Görüntü ve Referans İmza Kümesinin Ayrımı

Başlık 5.3'de belirtilen görüntü ve referans imza kümesinin birleştirilmesi ile elde edilen birleştirilmiş veri kümesine beyazlatma ve Savitzky Golay filtresi uygulaması sonrası ilgili veri kümesinin yeniden parçalarına ayrılması işlemidir. Şekil 38 ile sunulmuştur. Girdi dizi boyutu $(M + R) \times N$ 'dir, burada N spektral bant sayısını ifade eder. $M + R$ ise görüntüdeki piksel sayısı ile aranacak referans imza sayısının toplamıdır. R referans imza sayısını ifade eder iken M ise görüntüdeki piksel sayısını ifade eder.



Şekil 38 Görüntü ve referans imza kümesi ayrımı gösterimi

5.7. Tespit

Bu aşamada referans imza kümesi kullanılarak görüntüde hedef araması yapılır. Gerek görüntü gerek referans imza kümesi ön işleme adımlarından geçmiştir. Tespit 2 aşamalı olarak sağlanır. İlk aşamada çapraz ilintileme yöntemi kullanılır. İkinci aşamada ise ilk

aşamayı geçen aday pikseller spektral bilgi ayrımı yöntemi ile teste tabi tutulur. Tespit adımı her hedef tipi için ayrı olarak uygulanır ve bu adım sonunda ilgili hedef tipleri için skor haritaları oluşur. Bu aşama sonrası ilgili skor haritaları son işleme adımlarına girer olur.

Tespitin iki aşamalı yapılması sayesinde yanlış alarmlar daha iyi elenebilmektedir. Çapraz ilintileme hedef olabilecek pikselleri daha iyi ortaya çıkarabilir iken spektral bilgi ayrımı ise potansiyel tespitler içinde yanlış alarmları daha iyi eleyebilmektedir. Bu sayede iki aşamalı tespit sistemi oluşturularak yanlış alarmlara karşı daha güçlü bir algoritma ortaya çıkarılmaya çalışılmıştır.

Bu aşamada görüntüde spektral imza aramaya dayanan birçok yöntem denenmiştir. Çapraz ilintileme, genelleştirilmiş benzerlik testi, spektral açı bulucu, spektral bilgi sapması ve uyumlu süzgeç gibi birçok yöntemle yapılan denemeler sonunda çapraz ilintileme ve spektral bilgi sapmasının diğerlerine göre daha önce çıktığı görülmüştür.

Tespit adımları için karşılaştırmalı örnek olarak sunulan görseller bütünlük sağlanması açısından hedef içeren aynı test verisi üzerinde koşularak paylaşılmıştır.

5.7.1. İlk Aşama: Çapraz İlintileme

İki aşamalı tespit adımlarının ilki çapraz ilintileme algoritması kullanılarak yapılır. Çapraz ilintileme görece basit ve hızlı çalışan bir benzerlik tespit algoritması olarak kullanılır. Çapraz ilintileme, aynı maksimum ve minimum değerlere sahip metrikler arasında bir korelasyon olup olmadığını tespit etmek için iki farklı zaman serisinin karşılaştırılmasıdır. Bu çalışmada ise spektral derinlik sayesinde elde edilen bilgi zaman serisi gibi ele alınarak zaman eksenine yerine spektral ekseninde korelasyon hesaplanır. Bu değer büyüdükçe hedefe benzerlik artmakla birlikte ilgili skor değeri en yüksek 1 değerini alır. İlgili hedef tipine ait her k'inci referans hedef imzası ve görüntüdeki i'inci piksel arasındaki çapraz ilintileme skoru için aşağıdaki formül kullanılarak hesaplama yapılır:

$$CC_{ik} = \frac{\sum_{j=1}^N (F_{ij} - \bar{F}_i) \cdot (P_{kj} - \bar{P}_k)}{(N - 1)(\sigma_F \cdot \sigma_P)} \quad (5.7.1.1)$$

İlgili parametreler aşağıda tanımlanır:

P_{kj} : k'inci referans hedef imzası

F_{ij} : i'inci pikselin spektral imzası


σ_F ve σ_P : Görüntü ve imzanın standart sapmaları

\bar{F}_i : i'inci pikselin spektral ortalama deęeri


\bar{P}_k : k'inci referans hedef imzasının spektral ortalama deęeri

CC_{ik} : k'inci referans hedef imzası ve i'inci piksele ait apraz ilintileme skoru

Ařaęıda hedef ieren rnek bir hiperspektral veride ilgili hedefe ait imza kmesinin apraz ilintileme yntemi ile aranmasına ait sonu haritaları paylařılmıştır. Őekil 39 sahnenin tamamını sunmaktadır. Őekil 40 ise hedefin olduęu alana (Őekil 39-kırmızı Őekil ierisinde gsterilen alan) yaklařtırılmış sonu haritalarıdır. 5.7.2, 5.7.3 ve 5.7.4 adımlarında aynı rnek veriye ait ilgili adımların ıktıları sunulmuřtur.



Őekil 39 rnek hedef imza kmesinin test grntsnde apraz ilintileme sonuları




Şekil 40 Çapraz ilintileme sonuçlarının yakınlaştırılmış hali

Yakınlaştırılmış sonuç haritalarına (Şekil 40) bakıldığında kırmızı daire içerisinde görülen parlaklıklar hedef olan bölgenin yüksek skor verdiği alanlardır. Sekiz imzanın yedisi ilgili alanı parlatırken birisi (sağ üst) ise belirgin bir tespit sunamamıştır. Bu durum test görüntüsü değişikçe değişebilmektedir. Ancak yöntem gereği her piksel için en yüksek skor seçildiğinden en az bir imzanın ilk eşiği geçecek kadar yüksek skor vermesi ikinci tespit adımı olan spektral bilgi ayırımına geçiş için yeterlidir.

5.7.2. İlk Eşikleme


Çapraz ilintileme skor haritası daha önceden hedef tipine özel olarak belirlenmiş eşik testine tabi tutulur. Bu adım sonrasında ilgili eşik değerinden büyük çapraz ilintileme skoru veren pikseller için spektral bilgi ayırımı skorları çıkarılmak üzere spektral bilgi ayırımı algoritmasına yönlendirilir. İlk eşik değeri parametrik olarak ayarlanabilir olmakla birlikte bu çalışmada tüm hedef tipleri için 0.80 olarak seçilmiştir. İlk eşiğin görece düşük seçilme sebebi pozitif tespitleri olabildiğince kapsamaktır. Bu eşikleme sonrasında elde edilen skor haritası bir sonraki tespit adımı akabinde ayrıca bir eşik testine (son eşikleme) tabi tutulacaktır.

Aşağıda hedef içeren örnek bir hiperspektral veride ilgili hedefe ait imza kümesinin çapraz ilintileme yöntemi ile aranmasına ait sonuç haritalarının ilk eşik testi sonuçları paylaşılmıştır. Şekil 41 sahenin tamamını sunmaktadır. Şekil 42 ise hedefin olduğu alana (Şekil 41-kırmızı şekil içerisinde gösterilen alan) yaklaştırılmış sonuç haritalarıdır.



Şekil 41 Örnek hedef imza kümesinin eşiklenmiş çapraz ilintileme sonuçları

Yakınlaştırılmış sonuç haritalarına (Şekil 42) bakıldığında kırmızı daire içerisinde görülen parlaklıklar eşiği geçen skorlara sahip pikselleri sunar. Sekiz imzanın yedisi eşiği geçen piksellere sahip skor haritaları üretirken birisi (sağ üst) ise eşiği geçen piksel sunamamıştır. Alınan bu sonuçlar, yedi imza için ikinci tespit adımı olan spektral bilgi ayrımı algoritması koşulacağı, ilk eşiği geçemeyen bir imza için ise ikinci tespit adımı koşulmayacağı manasına gelir. Bu durum test görüntüsü değişikçe değişebilmektedir.



Şekil 42 Eşiklenmiş çapraz ilintileme sonuçlarının yakınlaştırılmış halı

5.7.3. İkinci Aşama: Spektral Bilgi Ayrımı

Spektral bilgi ayrımı, pikselleri referans hedef imzaları ile eşleştirmek için bir sapma ölçüsü kullanır. Sapma ile piksellerin benzer olma olasılığı ters orantılıdır. Belirtilen maksimum sapma eşliğinden daha büyük bir ölçüme sahip pikseller sınıflandırılmaz. Spektral bilgi ayrımı olasılık temelli bir sınıflandırma ölçütüdür.

Spektral bilgi ayrımı ilgili skor bilgisini sağlayan eşitlik öncesi yapılan ön işlemler açısından birbirinden ayrılan iki farklı şekilde uygulanmıştır. Her iki yöntem de bu başlık altında anlatılmıştır. Bunlardan ilki SBA-1 ikincisi ise SBA-2 olarak aşağıda detaylandırılmıştır.

SBA-1: Spektral bilgi ayrımı hesaplaması öncesinde referans spektral imzaya ve piksel spektral imzasına bir ofset değeri eklenir (5.7.3.1 ve 5.7.3.2). Bunun yapılmasındaki amaç beyazlatma algoritması sonrası küçük ve negatif değerleri içeren bir değer aralığına düşen spektral bant değerlerini pozitif ve büyük değerler arasına taşımaktır. Spektral bilgi ayrımı logaritma operasyonu içerdiği için negatif sayılara kararsız dönüşler yapmaktadır. Eklenen ofset değeri büyüdükçe skor değeri de benzerlikten bağımsız olarak büyümektedir. Bu çalışmada ofset değeri yapılan denemeler sonrasında 200 olarak seçilmiştir.

$$F_{ij} = (a + F_{ij}) \quad (5.7.3.1)$$


$$P_{kj} = (a + P_{kj}) \quad (5.7.3.2)$$

5.7.3.1 ve 5.7.3.2 formüllerinde kullanılan parametrelerin açıklaması aşağıda verilmiştir:

$$a = 200.$$


P_{kj} : k'ninci referans hedef imzası

F_{ij} : i'ninci pikselin spektral imzası



Şekil 43 Örnek hedef imza kümesinin eşiklenmiş SBA-1 sonuçları

Hedef içeren örnek bir hiperspektral veride ilgili hedefe ait imza kümesinin SBA-1 yöntemi ile aranmasına ait sonuç haritaları paylaşılmıştır. Şekil 43 sahnenin tamamını sunmaktadır. Şekil 44 ise hedefin olduğu alana (Şekil 43-kırmızı şekil içerisinde gösterilen alan) yaklaşılmış sonuç haritalarıdır.



Şekil 44 Eşiklenmiş SBA-1 sonuçlarının yaklaşılmış hali

SBA-2: SBA-1' de yapılan ofset ekleme yerine ilk olarak hedefin ve pikselin spektral imzaların sıfırdan büyük hale getirilir. Bunu yapmak için ilgili spektral imzalardan en küçük bant değeri çıkarılır. Sonrasında en küçük değerın sıfır olmasını

engellemek için bir epsilon değeri ($eps = 2.2204e - 16$) ile toplanır (5.7.3.3, 5.7.3.5). Son olarak L1 normalizasyon uygulanarak piksel ve referans hedef imzalarına yapılan ön adımlar tamamlanmış olur (4.7.3.4, 4.7.3.6).

$$F_{ij} = F_{ij} - \min(F_i) + eps \quad (5.7.3.3)$$

$$F_{ij} = \frac{F_{ij}}{\sum_{j=1}^N (abs(F_{ij}))} \quad (5.7.3.4)$$


$$P_{kj} = P_{kj} - \min(P_k) + eps \quad (5.7.3.5)$$

$$P_{kj} = \frac{P_{kj}}{\sum_{j=1}^N (abs(P_{kj}))} \quad (5.7.3.6)$$

Yukarıda bahsi geçen SBA-1 ve SBA-2 yöntemleri sonrasında spektral bilgi ayrımı uygulaması aynı şekilde devam etmektedir. Buna ilişkin bilgilendirme aşağıda yapılmaktadır. Spektral bilgi ayrımı formülü aşağıda verilmiştir (5.7.3.7). Burada hesaplanan değer ile benzerlik ters orantılıdır. Skor ve benzerliği doğru orantılı hale getirmek için elde edilen sonuç küçük bir epsilon değeri ($eps = 2.2204e - 16$) ile toplanıp 1'e bölünerek spektral bilgi ayrımı skoru sağlanır (4.7.3.8).


$$DVG_{ik} = abs\left(\sum_{j=1}^N (F_{ij} \cdot \log\left(\frac{F_{ij}}{P_{kj}'}\right)) + \sum_{j=1}^N (P_{kj}' \cdot \log\left(\frac{P_{kj}'}{F_{ij}}\right))\right) \quad (5.7.3.7)$$

$$DVG_{ik} = \frac{1}{DVG_{ik} + eps} \quad (5.7.3.8)$$



Şekil 45 Örnek hedef imza kümesinin eşiklenmiş SBA-2 sonuçları


Hedef içeren örnek bir hiperspektral veride ilgili hedefe ait imza kümesinin SBA-2 yöntemi ile aranmasına ait sonuç haritaları paylaşılmıştır. Şekil 45 sahnenin tamamını sunmaktadır. Şekil 46 ise hedefin olduğu alana (Şekil 45-kırmızı şekil içerisinde gösterilen alan) yaklaşılmış sonuç haritalarıdır.



Şekil 46 Eşiklenmiş SBA-2 sonuçlarının yakınlştırılmış hali


Her iki yöntemde de seçilen spektral bilgi ayrımı algoritması ilgili hedef tipine ait bütün referans imzalar için tekrarlanarak i pikseli için referans imza sayısı (k) kadar eleman içeren skor kümesi oluşturulur. Skor kümesinden en yüksek skor seçilerek ilgili hedef tipine ait nihai spektral bilgi ayrımı skoru elde edilir (5.7.3.9).

$$\text{Skor}_i = \max(DVG_{ik}) \quad (5.7.3.9)$$



Şekil 47 SBA-1 nihai skor haritası

Hedef içeren örnek bir hiperspektral veride ilgili hedefe ait SBA-1 ve SBA-2 nihai skor haritaları sırasıyla Şekil 47 ve Şekil 48 olarak sunulmuştur. SBA-2 nihai skor haritasının bu örnek için daha belirgin ve kesintisiz bir sonuç sağladığı görülür.



Şekil 48 SBA-2 nihai skor haritası



Çalışmanın başlarında SBA-1 kullanılmıştır. Elde edilen sonuçları iyileştirme için yapılabilecekler değerlendirilerek piksel ve referans imzayı görece büyük bir ofset ile

toplamak yerine normalizasyon işlemi uygulamanın daha iyi sonuç verebileceği düşünülmüştür. L1, L2 ve 0-1 arasına sıkıştırma gibi farklı normalizasyon adımları denenmiştir. L1 normalizasyon ile devam edilmiş, SBA-2'nin geniş veri kümesinde SBA-1'e göre daha iyi sonuçlar verdiği görülmüştür.

5.7.4. Son Eşikleme


Bu adımda her hedef tipine ait skor haritasında ilgili hedef tipi için daha önce belirlenmiş sabit eşik değerinden büyük olan pikseller aynı skor ile kalır. Eşikten daha küçük piksel skorları ise sıfıra eşitlenir (5.7.4.1). Aşağıda örnek olarak 2 farklı skor haritası için belirlenen eşik değerinden küçük değerlerin sıfırlanması gösterilmiştir (Şekil 49).

$$SkorHaritası_i(SkorHaritası_i < t_i) = 0 \quad (5.7.4.1)$$


	Skor Haritası		Güncel Skor Haritası																																
Hedef 1	<table border="1"> <tr><td>1</td><td>2</td><td>3</td><td>5</td></tr> <tr><td>1</td><td>1</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>4</td><td>0</td></tr> </table>	1	2	3	5	1	1	1	1	0	0	0	0	0	0	4	0	$<2=0$ 	<table border="1"> <tr><td>0</td><td>2</td><td>3</td><td>5</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>4</td><td>0</td></tr> </table>	0	2	3	5	0	0	0	0	0	0	0	0	0	0	4	0
1	2	3	5																																
1	1	1	1																																
0	0	0	0																																
0	0	4	0																																
0	2	3	5																																
0	0	0	0																																
0	0	0	0																																
0	0	4	0																																
Hedef 2	<table border="1"> <tr><td>1</td><td>2</td><td>3</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>7</td><td>1</td></tr> <tr><td>0</td><td>1</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>5</td><td>6</td><td>4</td></tr> </table>	1	2	3	1	1	1	7	1	0	1	0	0	0	5	6	4	$<3=0$ 	<table border="1"> <tr><td>0</td><td>0</td><td>3</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>7</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>5</td><td>6</td><td>4</td></tr> </table>	0	0	3	0	0	0	7	0	0	0	0	0	0	5	6	4
1	2	3	1																																
1	1	7	1																																
0	1	0	0																																
0	5	6	4																																
0	0	3	0																																
0	0	7	0																																
0	0	0	0																																
0	5	6	4																																

Şekil 49 Örnek son eşikleme gösterimi

Aşağıda son eşikleme öncesi dört hedef tipi için elde edilen SBA-2 skor haritaları (Şekil 50) ve ilgili haritaların tamamı sıfır olan alt yarısının daha belirgin görsel sunmak adına çıkarıldığı halleri (Şekil 51) sunulmuştur. Her skor haritası için en küçük ve en yüksek skorlar Şekil 50 açıklamasında sunulmuştur.




Şekil 50 SBA-2 skor haritaları (a) Hedef tipi 1, en düşük skor: 4.0081, en yüksek skor: 10.2351 (b) Hedef tipi 2, en düşük skor: 2.1297, en yüksek skor:18.3786 (c) Hedef tipi 3, en düşük skor: 6.1283, en yüksek skor:69.9211 (d) Hedef tipi 4, en düşük skor: 3.6834, en yüksek skor:17.9633




Şekil 51 Sonuçların daha yakın görünmesi için kırılmış SBA-2 skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4

Son eşikleme sonrası 4 hedef tipi için elde edilen nihai skor haritaları (Şekil 52) ve ilgili haritaların tamamı sıfır olan alt yarısının daha belirgin görsel sunmak adına çıkarıldığı

halleri (Şekil 53) sunulmuştur. Her skor haritasının üzerinde ilgili haritanın en küçük ve en yüksek skorları da gösterilmiştir.



Şekil 52 Son eşikleme sonrası elde edilen nihai skor haritaları (a) Hedef tipi 1, en düşük skor: 10.2351, en yüksek skor: 10.2351 (b) Hedef tipi 2, en düşük skor: 10.1603, en yüksek skor:18.3786 (c) Hedef tipi 3, en düşük skor: 33.683, en yüksek skor:69.9211 (d) Hedef tipi 4, en düşük skor: 10.0741, en yüksek skor:17.9633



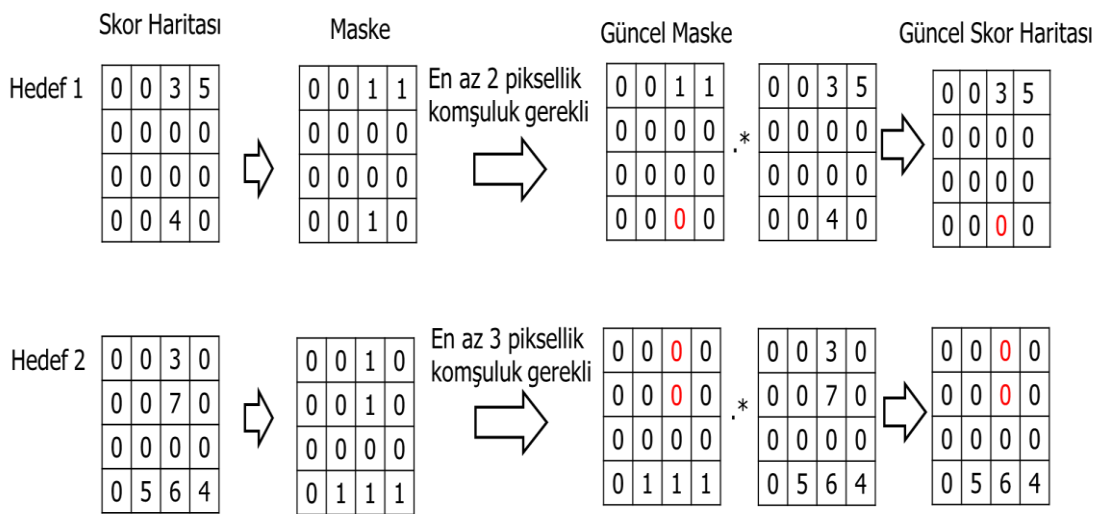
Şekil 53 Sonuçların daha yakın görünmesi için son eşikten geçirme sonrası kırılmış nihai skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4

Görüleceği üzere son eşikleme öncesinde kenarlardan gelen yanlış alarmların birçoğu son eşikleme ile giderilmiştir. En küçük skor değerleri ise doğal olarak değişmiştir. Her hedef tipi için ayrı olarak belirlenen eşik değerinden küçük skora sahip pikseller sıfırlanmıştır.

5.8. Grup Piksel Sayısına Göre Eşikleme


Bu adımda belirli bir piksel sayısından daha az sayıda piksel içeren hedef adayları öbeklerin dikkate alınmaması amaçlanır. Bu amaçla bu adımda oluşturulan maske haritası ile skor haritası çarpılarak son skor haritalarına ulaşılır. Maske haritası “0”ve “1” değerlerinden oluşur. Daha önce belirlenmiş eşik değerinden daha az piksel içeren gruplar “0”, ilgili eşik değerine eşit veya daha fazla sayıda piksel içeren gruplar ise “1” değerine sahip olur. Elde edilen bu maske ile skor haritası çarpıldığında istenen sayıdan daha az piksel içeren grupların skorları sıfırlanmış olur.

Bu adım uzamsal bir işlem gerektirdiği için buraya kadar vektör olarak tutulan sonuç haritaları 2 boyutlu matrislere dönüştürülür. Örneğin piksel sayısı M olan bir görüntü için i numaralı hedef tipine ait M X 1 boyutlu bir skor vektörü bulunur. Öncelikle bu vektör ilgili görüntünün satır ve sütun sayısı boyutlarında ve “0” veya “1” değerlerinden oluşan bir maskeye dönüştürülür. Daha sonra bu maske MATLAB fonksiyonu olan “bwareaopen.m” fonksiyonu yardımıyla belirli bir sayıdan az sayıda 1 değeri içeren piksel gruplarının sıfırlandığı bir maskeye dönüştürülür. Son olarak da elde edilen maske ile skor haritası çarpılarak grup piksel analizi işlemi tamamlanır. Aşağıda örnek bir hedef tipi için yapılan işlemler adım adım sıralanmıştır.




Şekil 54 Örnek grup piksel sayısına göre eşikleme

Grup piksel sayısına göre eşikleme sonrası 4 hedef tipi için elde edilen nihai skor haritaları (Şekil 55) ve ilgili haritaların tamamı sıfır olan alt yarısının daha belirgin görsel sunmak adına çıkarıldığı halleri (Şekil 56) sunulmuştur. Her skor haritasının üzerinde ilgili haritanın en küçük ve en yüksek skorları da gösterilmiştir. Görüleceği üzere bu eşikleme sonrası hedef 1 için skor haritası sıfırlanmıştır. Diğer 3 hedef ise en yüksek skor olarak birbiri ile yarışacak ve nihai karar verilecektir.



Şekil 55 Grup piksel sayısına göre eşikleme sonrası nihai skor haritaları (a) Hedef tipi 1, en düşük skor: 0, en yüksek skor: 0 (b) Hedef tipi 2, en düşük skor: 10.8615, en yüksek skor:18.3786 (c) Hedef tipi 3, en düşük skor: 33.683, en yüksek skor:69.9211 (d) Hedef tipi 4, en düşük skor: 10.7705, en yüksek skor:17.9633



Şekil 56 Sonuçların daha yakın görünmesi için grup piksel sayısına göre eşikleme sonrası 4 hedef tipi için elde edilen kırpılmış nihai skor haritaları (a) Hedef tipi 1 (b) Hedef tipi 2 (c) Hedef tipi 3 (d) Hedef tipi 4

5.9. Skor Kıyaslama ve Karar

Hedef var ya da yok kararının verildiği aşamadır. Hedef var ise hangi hedef tipinin seçildiği aşama da bu aşamadır. Hedef tipleri için skor haritalarının sıfırdan büyük değer içerip içermemesi kontrol edilir. Eğer bütün hedef tipleri için elde edilen güncel skor haritaları sadece 0 değerli skorlar içeriyorsa “Karar: Hedef yok” kararı alınır. Aksi durumda hangi hedef tipi en yüksek skoru içeriyorsa ilgili hedef için “Karar: Hedef N” kararı alınır. Burada N ilgili hedef numarasını temsil eder. Karşılaştırma yapılırken tek piksel skoru temel alınarak karşılaştırma yapılır. Örnek bir akış aşağıda verilmiştir (Şekil 57).

Güncel Skor Haritası

Hedef 1

0	0	3	5
0	0	0	0
0	0	0	0
0	0	0	0

En büyük
değer 5.



Karar: Hedef 2

Hedef 2

0	0	0	0
0	0	0	0
0	0	0	0
0	5	6	4

En büyük
değer 6.

Şekil 57 Örnek karar akışı

Örneğin, Şekil 55 referans alındığında ilgili test verisi için en yüksek skoru veren hedef 3 olduğundan dolayı nihai karar “Hedef 3 tespit edildi.” olarak verilir.

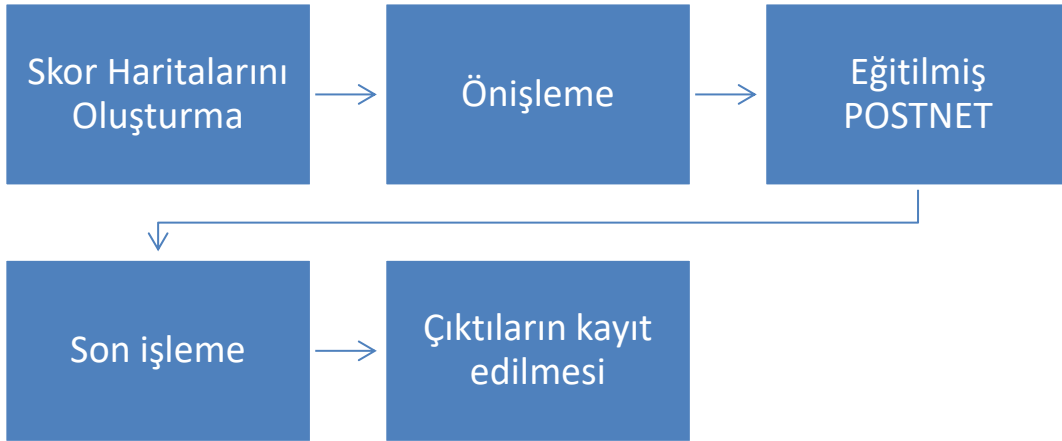
6. POSTNET YÖNTEMİ

POSTNET yöntemi temelde Çoklu Hedef Tespiti Yöntemi başlığında anlatılan tespit yöntemleri sonucu elde edilen skor haritalarında yapılacak son işleme adımlarının derin öğrenme ile gerçekleştirilmesine dayanır. Bunu yapabilmek için öncelikle eğitim verisi elle etiketlenir. Daha sonra eğitim kümesindeki her görüntü için skor haritaları oluşturulur. Oluşturulan skor haritaları POSTNET ile eğitilir. Eğitim adımı tamamlandıktan sonra her test verisi için skor haritaları oluşturulur ve eğitilmiş POSTNET yardımıyla test gerçekleşir.

Çoklu Hedef Tespiti başlığında anlatılan tespit adımları benzer şekilde uygulanır. Eğitim ve test akış diyagramları aşağıda sırasıyla Şekil 58 ve Şekil 59 ile sunulmuştur:



Şekil 58 POSTNET eğitim akış diyagramı



Şekil 59 POSTNET test diyagramı

POSTNET eğitimi için öncelikle hedef içeren görüntüler elle etiketlenerek yer gerçeklik haritaları oluşturulmuştur. Her bir hiperspektral veri için elle yapılan bu işlem görece uzun süre aldığından dolayı POSTNET Hedef 1, Hedef 3 ve Hedef 4 tipleri için eğitilmiş ve test edilmiştir. Sırasıyla Hedef 1, Hedef 3 ve Hedef 4 için 144, 145 ve 134 adet hiperspektral görüntü eğitim kümesinde kullanılmıştır. Ancak gerek hedef barındıran

piksel sayısının görüntü başı yaklaşık olarak 2-10 piksel arası olması gerekse kullanılan görüntü sayısının azlığı nedeni ile yer gerçeklik haritaları 16x16 piksel boyutlarında parçalara ayrılarak eğitim kümesi büyütülmüştür. Bu adım 5.1.3 Önileme başlığında daha detaylı anlatılmaktadır.

6.1. Skor Haritalarını Oluşturma

Skor haritaları oluşturulurken Çoklu Hedef Tespiti başlığında izlenen adımlar tekrarlanır. Ancak Çapraz ilintileme, SBA-1 ve SBA-2 yöntemlerinden birisini seçmek yerine her üçü için de skor haritaları oluşturulur. Böylece her hedef tipi için 3 kanal olmak üzere 3 hedef tipi için toplamda 9 kanaldan oluşan skor haritası sağlanır. Son kanal olan onuncu kanala ise eğitimde kullanılmak üzere yer doğruluk haritası eklenir. Böylece $M \times N$ boyutlarında piksele sahip bir görüntü için $M \times N \times 10$ boyutlarında skor haritası yaratılmış olur. İzlenen adımların açıklaması daha önce Çoklu Hedef Tespiti başlığında verilmiş olup akış diyagramı aşağıda (Şekil 60) paylaşılmıştır.




Şekil 60 POSTNET eğitimi için skor haritalarını oluşturma akış diyagramı

6.2. Ön İşleme

Ön işleme adımının yapılmasındaki amaç az olan eğitim verisini çoğaltmaktır. Bunun için her bir görüntüden olabildiğince çok 16x16'lık parçaların oluşturulması amaçlanır. Bu yapılırken her bir parçanın en az 1 piksel dahi olsa hedef içermesine dikkat edilir. Aynı şekilde 16x16'lık olan ve içerisinde hedef içermeyen parçalar da boş görüntü olarak seçilir. Boş görüntü kümesine çapraz ilintileme skoru görece yüksek (>0.7) olan ancak yanlış alarm olabilecek kenar vb. pikselleri de içerecek 16x16'lık parçalar da ayrıca

eklenir. Bu yapılırken hiçbir boş görüntü parçasında hedef içeren piksel bulunmamasına dikkat edilir.

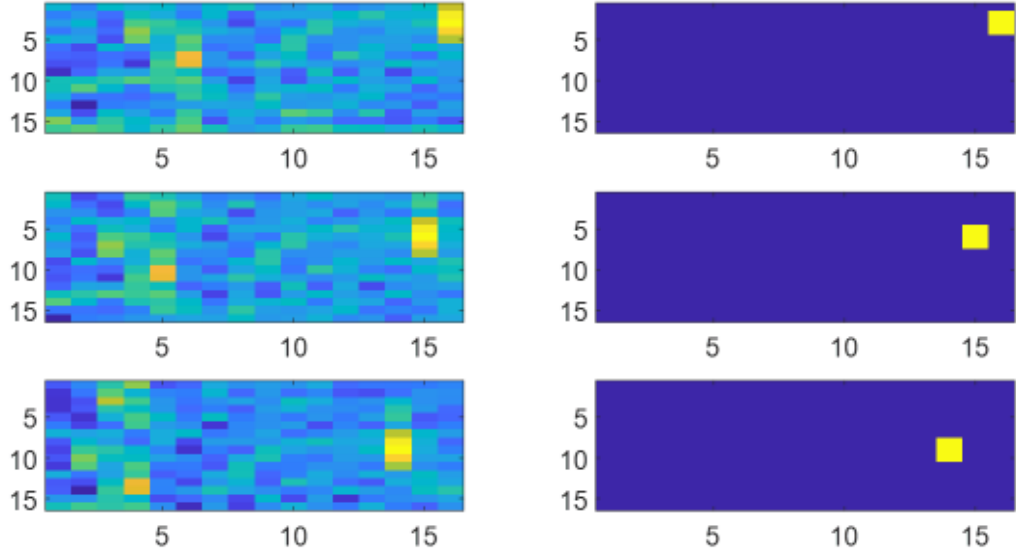
Aşağıda örnek bir yer doğruluk haritası kullanılarak 16x16'lık parçaların seçildiği alanlar gösterilmiştir (Şekil 61). İlk olarak solda hedef olarak işaretlenmiş pikseller sarı olarak gösterilmiştir. Ortada ise hedef içeren 16x16'lık parçaları içeren alan açık mavi olarak gösterilmiştir. Bu alan 32x32'lik bir birim matrisin yer doğruluk haritası ile konvolüsyonu ile elde edilir. Alanın ortasındaki sarı pikseller ise hedef olarak işaretlenen piksellerdir. En sağda turkuaz ile gösterilen alan ise hedef içermeyen 16x16'lık parçaların alındığı alandır. 256x64'lük birim matrisin yer doğruluk haritası ile konvolüsyonu sonrası hedef içeren parçaların seçildiği alan (ortadaki açık mavi alan) maskelenerek elde edilir. Görüleceği üzere hedef içermeyen parçaların seçileceği alan görece çok daha büyüktür. Bu yüzden bu alandan olası tüm 16x16'lık parçaların onda birlik bir kümesi seçilir. Ayrıca yeşil renk ile gösterilen alan ise yüksek çapraz ilintileme skoru (>0.7) veren ancak hedef olmayan pikselin merkeze konarak elde edildiği 16x16'lık parçayı temsil eder. Bu parçaların eğitim kümesinde olmasına olası yanlış alarmlara karşı daha gürbüz bir eğitim sağlamak adına özellikle dikkat edilir.



Şekil 61 Yer doğruluk haritası (solda), hedef pikselleri içerebilecek 16x16'lık parçaları kapsayan en geniş küme(ortada, açık mavi), hedef içermeyen 16x16'lık parçaların seçildiği alan (sağda, turkuaz ve yeşil) gösterimi

Yer doğruluk haritası kullanılarak 16x16'lık skor haritası parçaların elde edilmesinin örnek bir gösterimi aşağıda (Şekil 62) paylaşılmıştır. Görselin sol tarafında çapraz ilintileme skor haritasından elde edilen 16x16'lık parçalar, sağ tarafında ise ilgili

16x16'lık parçalara ait yer doğruluk maskesi verilmiştir. Anlaşılacağı üzere bu sayede tek bir skor haritasından içerisinde hedef barındıran çok sayıda küçük parça elde edilerek eğitim setine ait veri sayısı anlamlı şekilde arttırılmıştır.



Şekil 62 Örnek 16x16 parçalar ve ilgili yer doğruluk maskeleri

İlgili parçaların sınırları kullanılarak skor haritaları da eşdeğer parçalara bölünmüş ve eğitim kümesi oluşturulmuştur. Tablo 1'de eğitim kümesinde oluşturulan parça sayıları verilmiştir.

Tablo 1 POSTNET eğitim kümesi veri sayısı

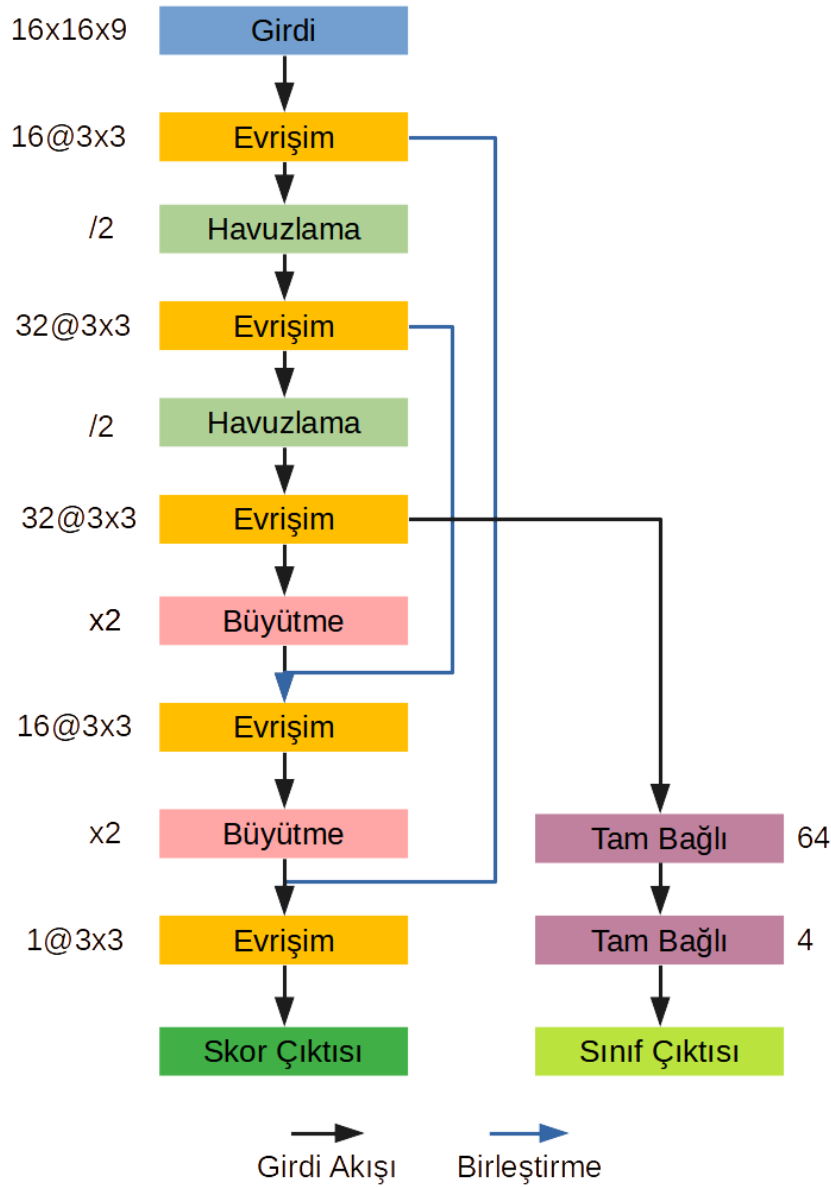
Hedef	Görüntü sayısı	Dolu parça sayısı	Boş parça sayısı
Hedef 1	144	42531	26181
Hedef 3	145	44021	27864
Hedef 4	134	38277	22841

6.3. POSTNET Modeli ve Eğitimi

POSTNET kurgusu iki farklı çıktı verecek şekilde tasarlanmıştır. Modelin şeması Şekil 63 ile paylaşılmıştır. Öncelikle önışleme sonrası elde edilen 16x16x9 boyutlarındaki girdi matrisler evrişim adımından geçirilerek 16 tane 3x3x9 boyutlu filtre öğrenilir. Her bir filtrenin oluşturduğu 16x16'lık aktivasyon haritası kümelenecek 16x16x16'lık çıktıyı

oluşturur. Daha sonra en yüksek havuzlama (max pooling) ile boyut yarı yarıya küçültülür ve $8 \times 8 \times 16$ 'luk matris çıktısı elde edilir. Bir sonraki evrişim adımı sonrasında elde edilen $8 \times 8 \times 32$ 'lik çıktı yeniden en yüksek havuzlama ile $4 \times 4 \times 32$ 'lik matrise dönüştürülür. Bu adım sonrası kanal sayısı değiştirilmeden yeniden evrişim adımı gerçekleştirilerek $4 \times 4 \times 32$ 'lik çıktı elde edilir. Daha sonra yapay sinir ağı iki farklı koldan ilerler. Birinci kol skorları üretirken ikinci kol ise sınıf bilgisini üretir.

Skor üretilirken $4 \times 4 \times 32$ 'lik girdi, büyütme işlemi ile $8 \times 8 \times 32$ 'lik matrise dönüştürülür. Oluşturulan 32 kanallı çıktı ikinci evrişim adımı çıktısı olan 32 kanal ile birleştirilerek 64 kanallı çıktı elde edilir. Böylece ilk aşamada öğrenilen daha temel filtrelerin çıktıları ile daha sonra öğrenilen karmaşık filtrelerin çıktıları bir araya getirilir. Daha sonra evrişim adımı ile kanal sayısı 64'ten 16'ya düşürülür ve boyut yeniden büyütülerek ağ girdisi olan 16×16 boyutuna yeniden yükseltilir. Bu çıktı ilk evrişim katmanının çıktısı olan 16 kanal ile birleştirilerek $16 \times 16 \times 32$ 'lik matris elde edilir. Son olarak bu matris 1 filtreli evrişim ile $16 \times 16 \times 1$ boyutlarında skor haritasına dönüştürülür.



Şekil 63 POSTNET akış diyagramı


Sınıflandırma için 4x4x32'lik girdi düzleştirilerek 512'lik vektöre dönüştürülür. Bu vektör 64'lük tam bağlı katmana verilir. Bu katmanın çıktısı ise 4'lük tam bağlı katman ve softmax fonksiyonu ile sınıf çıktısı elde edilir. Sınıf ağının son katmanı harici diğer bütün evrişim ve tam bağlı katmanlar için eğitimin hızlı olması için düzeltilmiş doğrusal aktivasyon fonksiyonu (ReLU) kullanılır. Evrişim katmanlarında çıktı boyutunda düşme olmaması için sıfır ile dolgulama (padding) gerçekleştirilir ve peş peşe gelen piksellerin küme olarak anlamlandırılması için adım sayısı (stride) 1 olarak seçilir.

Model eğitiminde iyileştirme yöntemi olarak eğitim süresini kısaltması ve öğrenme oranını kendi içinde dinamik olarak iyileştirdiği için Adam iyileştirici [48] seçilmiştir.


Öğrenme oranı başlangıç olarak $1e-3$ seçilmiştir. Skor haritalamasında hata üretmek için ortalama kare hatası (MSE, mean squared error) fonksiyonu kullanılmıştır. Sınıflandırma için ise kategorik çapraz entropi hata (categorical cross-entropy) fonksiyonu kullanılmıştır. Eğitim erken durdurma kullanılarak 12 epokta bitirilmiştir.

Veri kümesindeki sınıf yanlılığını engellemek için eğitim kümesine her hedef tipinden eşit sayıda veri alınmıştır. Bu sayı seçilirken en az sayıya sahip olan Hedef 4 veri sayısı (38277) temel alınmıştır. Eğitim kümesi her bir hedef tipinden bu sayının %70'ine (26793) denk gelecek kadar veri seçilerek oluşturulmuştur. Eğitim kümesinde %10'u doğrulama için kullanılmak üzere toplamda 107172 tane $16 \times 16 \times 9$ 'luk veri parçası kullanılmıştır. Kalan verinin tamamı teste ayrılmıştır. Eğitim esnasında veriler karılarak daha verimli öğrenme sağlanmıştır. Eğitim esnasında yığın boyutu ise birtakım denemeler sonrasında 16 olarak seçilmiştir.

Modelin test setinde bulunan 16×16 'lık girdilerden rastgele seçilen 2 veriye ait çıktıları ilgili verinin yer doğruluk haritası ile aşağıda (Şekil 64 ve Şekil 65) paylaşılmıştır.



Şekil 64 16×16 'lık veri için yer doğruluk haritası (solda) ve POSTNET çıktısı (sağda) -1



Şekil 65 16x16'lık veri için yer doğruluk haritası (solda) ve POSTNET çıktısı (sağda) -2

7. DENEYLER VE SONUÇ

Çoklu hedef tespiti (ÇHT) yöntemi dört farklı arka plan ve dört farklı hedef tipi için, POSTNET yöntemi ise dört farklı arka plan ve üç farklı hedef tipi için Firma tarafından bağımsız olarak denenmiş ve elde edilen sonuçlar paylaşılmıştır. Hedeflerin ilgili arka plan malzemesine eser miktarda (~5000ng) yerleştirilmesine özen gösterilmiştir. Elde edilen sonuçlar Tablo 2 ve Tablo 3 ile sunulmuştur. Bu sonuçlar haricinde ilgili yöntemlerin geliştirme aşamasında farklı veri kümelerinde de performans değerleri alınmıştır. Ancak her iki yöntemin karşılaştırıldığı ortak veri kümesi olması açısından bu sonuçların paylaşılması uygun bulunmuştur. Hedef içeren toplam 226, hedef içermeyen toplam 259 hiperspektral görüntüden oluşan veri kümesinde elde edilen performanslar ÇHT ve POSTNET için ayrı tablolar halinde verilmiş ve sonuçlar kıyaslanmıştır.

Tespit oranı hesaplanırken yer doğruluk haritası içerisinde bulunan hedef ilgi alanından en az bir piksellik tespit şartı aranır. Bu sağlandığı durumda ilgili görüntü için tespit başarılı sayılır. İçinde hedef barındırmayan, sadece ilgili arka plana ait görüntülerde bir piksel bile olsa tespit olduğunda ise ilgili görüntüde yanlış alarm verilmiş sayılır. Özetle hedef alanından en az bir piksellik tespit başarımları için yeterli iken boş görüntülerde ise başarı şartı olarak hiçbir pikselde tespit sağlanmaması aranır. Bu sebeple ilgili tespit ve yanlış alarm metrikleri piksel bazlı olması yerine görüntü bazlı olarak çıkarılır. Metriğin bu şekilde seçilmesinde hedefin oldukça az piksel içeren alana yayılması sebebiyle hedef ve arka plan piksel sayısının oldukça uyumsuz olması da etkilidir. Ayrıca ortaya çıkacak ürün düşünüldüğünde başarı olarak beklenen şey hedef içermeyen ayakkabı için boş dönerken hedef içeren ayakkabı için tespit yapılan yer ve hedefin çıktığı olarak dönülmesidir. Hedef tespitine ek olarak ilgili hedefin tipinin de teşhisi sağlanacak şekilde sonuçlar alınmıştır.

Tablo 2 Çoklu Hedef Tespiti (ÇHT) Performans Tablosu

Hedefli (~5000ng) Arka Plan Kombinasyonu	ÇHT Algoritması Kararları					Toplam Veri Sayısı
	Hedef 1	Hedef 2	Hedef 3	Hedef 4	Tespit Yok	
Hedef 1 -Siyah Deri	15	0	0	0	0	15
Hedef 1 -Siyah Polyester	11	0	0	3	1	15
Hedef 1 -Kahverengi Deri	13	0	0	2	0	15
Hedef 1 -Gri Skai	4	0	0	1	10	15
Hedef 2 -Siyah Deri	0	16	0	0	0	16
Hedef 2 -Siyah Polyester	0	14	0	0	1	15
Hedef 2 -Kahverengi Deri	0	15	0	0	0	15
Hedef 2 -Gri Skai	1	0	0	0	14	15
Hedef 3 -Siyah Deri	0	0	15	0	0	15
Hedef 3 -Siyah Polyester	0	0	14	0	1	15
Hedef 3 -Kahverengi Deri	0	0	15	0	0	15
Hedef 3 -Gri Skai	1	0	12	0	2	15
Hedef 4 -Siyah Deri	0	0	2	13	0	15
Hedef 4 -Siyah Polyester	0	0	0	2	13	15
Hedef 4 -Kahverengi Deri	0	0	0	15	0	15
Tespit Oranı (%)	71,67	73,77	93,33	66,67	*	
Tespit Oranı (Gri Skai çıkarılmış %)	86,67	97,83	97,78	66,67	*	
Boş Arka Plan Kombinasyonu	ÇHT Algoritması Kararları					Toplam Veri Sayısı
	Hedef 1	Hedef 2	Hedef 3	Hedef 4	Tespit Yok	
Boş Siyah Deri	0	0	0	0	61	61
Boş Siyah Polyester	1	0	1	8	51	61
Boş Kahverengi Deri	0	11	7	0	58	76
Boş Gri Skai	5	0	16	0	40	61
Yanlış Alarm Oranı (%)	2,32	4,25	9,27	3,09	**	
* Tespit yapılamayan dolu veriler için yanlış negatif oranlarıdır. Gri skai çıkarılmamış yanlış negatif oranı:18,00%, gri skai çıkarılmış yanlış negatif oranı: 8,83%						
** Tespit yapılamayan boş veriler için doğru negatif oranı: 81,08%						

Tablo 2 incelendiğinde ÇHT yöntemi ile 4 farklı hedef tipi için 4 farklı arka plana ait dolu (içinde hedef barındıran) ve boş (içinde hedef barındırmayan, sadece arka plana ait görüntüler) görüntülerde elde edilen tespit ve yanlış alarm oranları görülür. Başarımlar incelendiğinde deri arka planlara ait sonuçlar polyester ve “skai” gibi suni malzemelere göre daha iyi sonuçlar alındığı görülür. Bunda ilgili malzemelerin görece kaygan olması sebebiyle hedefi üstlerinde tutmalarında yaşanan sorunların ve elde edilen spektral imzalarda parlak olmaları sebebiyle bölgesel saturasyon gibi olumsuzlukların etkili

olduğu düşünülmektedir. “Gri Skai” arka planı hesaba katılmadığında hedef tespiti ve teşhisinin tip 1, 2 ve 3 için sırası ile %86.67, %97.83 ve %97.78 olarak sağlandığı görülür. Tip 4 için ise polyester arka planına ait başarımlar %66.67 ile görece düşük kalmıştır. Ancak bunda hedef 4 içeren polyester veri kümesinin hazırlanması esnasında bazı görüntülerde arka plan malzemesine has kayganlık vb sebeplerle hedefin arka planda tutunamamasının etkili olduğu düşünülmektedir. Çünkü aynı veri kümesi içinde bazı örnekler için başarımlar çok iyi iken bazı örneklerde başarımlar sağlanamamıştır. Boş görüntülerde ise yanlış alarm oranları sırasıyla %2.32, %4.25, %9.27 ve %3.09 olarak hesaplanmıştır.

Tablo 3 POSTNET Performans Tablosu

Hedefli(~5000ng) Arka Plan Kombinasyonu	POSTNET Algoritması Kararları				Toplam Veri Sayısı
	Hedef 1	Hedef 3	Hedef 4	Tespit Yok	
Hedef 1 -Siyah Deri	15	0	0	0	15
Hedef 1 -Siyah Polyester	5	0	9	1	15
Hedef 1 -Kahverengi Deri	15	0	0	0	15
Hedef 1 -Gri Skai	5	1	0	9	15
Hedef 3 -Siyah Deri	0	14	1	0	15
Hedef 3 -Siyah Polyester	0	15	0	0	15
Hedef 3 -Kahverengi Deri	0	15	0	0	15
Hedef 3 -Gri Skai	0	9	0	6	15
Hedef 4 -Siyah Deri	0	0	13	2	15
Hedef 4 -Siyah Polyester	0	0	8	7	15
Hedef 4 -Kahverengi Deri	0	0	12	3	15
Tespit Oranı (%)	66,67	88,33	73,33	*	
Tespit Oranı (Gri Skai çıkarılmış %)	77,78	97,78	73,33	*	
Boş Arka Plan Kombinasyonu	POSTNET Algoritması Kararları				Toplam Veri Sayısı
	Hedef 1	Hedef 3	Hedef 4	Tespit Yok	
Boş Siyah Deri	1	3	0	57	61
Boş Siyah Polyester	1	0	2	58	61
Boş Kahverengi Deri	0	0	0	76	76
Boş Gri Skai	5	0	2	54	61
Yanlış Alarm Oranı (%)	2,7	1,16	1,54	**	
* Tespit yapılamayan dolu veriler için yanlış negatif oranlarıdır. Gri Skai çıkarılmamış yanlış negatif oranı:16,97%, gri skai çıkarılmış yanlış negatif oranı:9,63%					
** Tespit yapılamayan boş veriler için doğru negatif oranı: 94,59%					

Tablo 3 incelendiğinde 3 farklı hedef tipi için 4 farklı arka plana ait dolu ve boş görüntülerde elde edilen tespit ve yanlış alarm oranları görülür. Aynı şekilde polyester ve “skai” arka planları için başarımın görece düşük kaldığı görülür. “Gri Skai” arka planı hesaba katılmadığında hedef tespiti ve teşhisinin tip 1, 3 ve 4 için sırası ile %77.78, %97.78 ve %73.33 olarak sağlandığı görülür. Boş görüntülerde ise yanlış alarm oranları sırasıyla %2.7, %1.16 ve %1.54 olarak hesaplanmıştır.

Sonuçlar karşılıklı olarak kıyaslandığında POSTNET yöntemi ÇHT yöntemine göre yanlış alarm oranı açısından daha iyi performans sergilemiştir. Hedef tespiti açısından ise ÇHT yönteminin başarımı daha iyidir. Bununla birlikte POSTNET yöntemi gelişime açıktır. Mevcut durumda daha önceden elde edilmiş skor haritalarını kullanarak çıktı üreten bu yöntem doğrudan hiperspektral görüntüleri girdi olarak sonuç üretecek şekilde güncellenebilir.

8. DEĞERLENDİRME

Hiperspektral görüntüler ile elde edilen spektral bilgi malzeme ayırımında, hedef tespitinde ve teşhisinde önemli avantajlar sağlar. Bu tezde hiperspektral görüntülerde nanogram seviyesinde kimyasal maddelerin siyah deri, kahverengi deri, siyah polyester, gri skai gibi farklı arka planlara sahip sahnelerde tespitine yönelik çalışmalar yapılmış ve iki ayrı özgün yaklaşım ortaya çıkarılmıştır. Dört farklı hedef tipi için tespit ve teşhise yönelik olarak yapılan bu çalışmada literatürde bulunan ön işleme, hedef tespiti ve son işleme adımları incelenmiş, veri kümesi üzerinde denenmiş ve gerekli görülen güncellemeler yapılarak gürbüz iki yöntem elde edilmiştir.

Öncelikle ham radyans verileri ile yapılan çalışmaların tespit ve teşhisi istenen kimyasal maddelerin arka plan materyali ile ayırımı için istenen seviyede başarımlı sağlamadığı görülmüştür. Bunun üzerinde bu ayırımı daha iyi sağlayabilmek adına ham verilerde çalışmak yerine beyazlatma algoritması ile veri dönüştürülerek çalışmalara devam edilmiştir. Ayrıca Savitzky Golay filtresi kullanılarak gürültü giderme işlemi de yapılmıştır. Tespit öncesi yapılan bu ön işleme adımları kimyasal maddeler ve arka plan malzemelerine ait spektral imzaların ayırımına fark edilir düzeyde fayda sağlamıştır. Bu da ön işlemenin hedef tespiti ve teşhisi için ne kadar önemli olduğunu göstermiştir.

Hedef tespiti için daha önceden aynı sensör ile elde edilmiş hiperspektral görüntülerden elde edilen spektral imzalar kullanılmıştır. Bu seçimle daha sonra benzer koşullarda çekilecek olan görüntülerde elde edilecek spektral imzalar ile yakınlığın azami olması amaçlanmıştır. Çok daha az sayıda referans hedef imzası ile ilgili hedef tipine ait spektral karakteristiğın olabildiğince iyi bir şekilde temsil edilmesi sağlanmıştır. Dört farklı hedef tipi için 600 hiperspektral veri incelenerek 44 referans imza çıkarılmış ve bu imza kümesi kullanılarak tespit ve teşhis gerçekleştirilmiştir.

Çoklu hedef tespiti yönteminde, ön işleme adımlarından sonra çapraz ilintileme yöntemi ile skor haritaları çıkarılmıştır. Deneysel olarak belirlenen ve hedef tipine özel olarak seçilen ilk eşik değerinden yüksek skor veren pikseller için bir sonraki adımda spektral bilgi ayırımı yöntemi ile yeniden skorlar hesaplanmış ve son eşik değerinden geçirilmiştir. Daha sonra hedef olarak öngörülen piksel kümeleri asgari piksel sayısı şartı ile elenmiştir. Böylece sonuçlar daha gürbüz hale getirilmiştir. Bu yöntem ve kodları paketlenerek görüntüleri sağlayan firma ile paylaşılmış ve firma tarafından Dört hedef tipi ve dört farklı arka plan (siyah deri, kahverengi deri, siyah polyester, gri skai) için alınan sonuçlar

paylaşmıştır. Alınan sonuçlar değerlendirildiğinde oldukça parlak bir malzeme olan gri skai tespit oranlarının görece düşük olduğu görülmüştür. Bunda malzeme kaynaklı olarak oluşan bölgesel saturasyonların etkili olduğu düşünülmektedir.

POSTNET yöntemi, özetle ÇHT içinde kullanılan son işleme adımlarının bir derin öğrenme algoritması yardımı ile yapılması fikrinden yola çıkarak geliştirilmiştir. Skor haritalarını eşiklemek ve farklı yöntemlerin sonuçlarını ardışık değerlendirmek yerine ilgili sonuçların bir bütün olarak değerlendirilmesi ve derin öğrenme ile yorumlanarak hedef tespiti ve teşhisi hedeflenmiştir. Çapraz ilintileme ve spektral bilgi ayrımı skor haritaları birleştirilerek oluşturulan skor kümesi ardışık evrişim adımlarından geçirilerek skor ve sınıf ayrımı sağlanmaktadır. POSTNET ile üç farklı hedef tipi ve dört farklı arka plana ait sonuçlar alınmış ve paylaşmıştır.

ÇHT ve POSTNET performansları karşılaştırıldığında yanlış alarm oranı olarak POSTNET yönteminin, tespit oranı olarak ise ÇHT yönteminin öne çıktığı görülmüştür. Bununla birlikte POSTNET yöntemi gelişime daha açıktır. Gerek mevcut yöntemde kullanılan öğrenme adımlarında yapılabilecek farklı denemeler gerekse skor haritaları yerine hiperspektral görüntülerin doğrudan kullanılması gibi yaklaşımlar denenebilir.

Bu tezde yapılan çalışma ile hiperspektral görüntüleme teknolojisi ve görüntü işleme algoritmalarının eser miktarda kimyasal malzeme tespiti problemi için etkin bir şekilde kullanılabileceği görülmüştür.

KAYNAKLAR

- [1] Anonim, Işık, <https://tr.wikipedia.org/wiki/Işık> (Erişim Tarihi: 7 Aralık 2021)
- [2] K. Tan, H. Wang, L. Chen, Q. Du, P. Du, C. Pan, Estimation of the spatial distribution of heavy metal in agricultural soils using airborne hyperspectral imaging and random forest, Journal of Hazardous Materials Volume 382, **2020**.
- [3] Anonim, Hiperspektral uygulamalar, <https://www.specim.fi/3-essential-remote-sensing-applications-in-vnir/> (Erişim tarihi: 7 Aralık 2021)
- [4] V. Bárta, F. Racek, J. Krejčí, NATO hyperspectral measurement of natural background, SPIE-Security-Defence, **2018**.
- [5] B. Baugh, G. Hamann, Advanced Geospatial Products, <http://www.sensorsmag.com/sensors-mag/introduction-swir-12051> (Erişim tarihi: 7 Aralık 2021)
- [6] Anonim, infrared theory, <https://www.opto-e.com/resources/infrared-theory> (Erişim Tarihi: 7 Aralık 2021)
- [7] N. Gupta, V. Voloshinov, Hyperspectral imager, from ultraviolet to visible, with a KDP acousto-optic tunable filter, APPLIED OPTICS Vol. 43, No. 13, **2004**.
- [8] V. Voloshinov and N. Gupta, “Tunable acousto-optic filters for monitoring of atmospheric ozone,” in Instrumentation for Air Pollution and Global Atmospheric Monitoring, J. O. Jensen, ed., Proc. SPIE 4574, p. 162–173, **2002**.
- [9] G.C. Tang, J.T. Chen, A. Katz, E.J. Celmer, R.W. Krumm, and R.R. Alfano, “Ultraviolet-visible acousto-optic tunable spectroscopic imager for medical diagnosis,” J. Biomed. Opt. 3, 80–84, **1998**.
- [10] Anonim, hiperspektral sensör teknolojileri, <https://www.vision-systems.com/cameras-accessories/article/14181365/hyperspectral-imaging-sensor-and-camera-requirements> (Erişim Tarihi: 7 Aralık 2021)
- [11] NEO Firması HYSPEX hiperspektral kamera kullanıcı kitapçığı, **2014**.
- [12] I.S. Reed and X. Yu, “Adaptive multiband cfar detection of an optical pattern with unknown spectral distribution,” IEEE ASSP, vol. 38, no. 10, pp. 1760–1770, **1990**.

- [13] H. Kwon, S.Z. Der, and N.M. Nasrabadi, "Adaptive anomaly detection using subspace separation for hyperspectral imagery," *Optical Engineering*, vol. 42, no. 11, pp. 3342-3351, **2003**.
- [14] T. Veracini, S. Mateolli, M. Diani, G. Corsini, "Fully unsupervised learning of Gaussian mixtures for anomaly detection in hyperspectral imagery", in *Proc. International Conference on Intelligent System Design and Applications (ISDA '09)*, **2009**.
- [15] H. Kwon and N. Nasrabadi "Kernel RX-algorithm: A nonlinear anomaly detector for hyperspectral imagery", *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 2, pp.388 -397, **2005**.
- [16] A. Banerjee, P. Burlina and C. Diehl "A support vector method for anomaly detection in hyperspectral imagery", *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 8, pp.2282 -2291, **2006**.
- [17] F. Chaudhry, et al. "Pixel purity index-based algorithms for endmember extraction from hyperspectral imagery." *Recent advances in hyperspectral signal and image processing 37.2*, **2006**.
- [18] C.I. Chang, C.C Wu, and H.M. Chen. "Random pixel purity index." *IEEE Geoscience and Remote Sensing Letters 7.2*, **2009**.
- [19] A. Plaza, C.I. Chang "Impact of Initialization on Design of Endmember Extraction Algorithms" *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 11, **2006**.
- [20] M.E. Winter, "N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data," *Proc. SPIE*, vol. 3753, pp. 266–275, **1999**.
- [21] A. Plaza, P. Martinez, R. Perez, and J. Plaza, "Spatial/spectral endmember extraction by multidimensional morphological operations," *IEEE Trans. Geosci. Remote Sensing*, vol. 40, pp. 2025–2041, Sept., **2002**.
- [22] J.M.P. Nascimento, J.M.B Dias "Does Independent Component Analysis Play a Role" *IEEE Trans. on Geoscience and Remote Sensing*, vol. 43, no. 1, pp. 175-186, January, **2005**.
- [23] L. Miao and Q. Hairong. "Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization." *IEEE Transactions on Geoscience and Remote Sensing 45.3*, **2007**.

- [24] H. Ren and C. Chein-I. "Automatic spectral target recognition in hyperspectral imagery." *IEEE Transactions on Aerospace and Electronic Systems* 39.4, **2003**.
- [25] A. Zare and P. Gader "Sparsity promoting iterated constrained endmember detection in hyperspectral imagery." *IEEE Geoscience and Remote Sensing Letters* 4(3): 446, **2007**.
- [26] S.E. Yuksel "Hiperspektral Görüntülerde Son Elemanların Geliştirilmiş Kısıtlı Optimizasyonla Bulunması." *IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, **2014**.
- [27] S.E. Yuksel, S. Kucuk and P.D. Gader, "SPICEE: An Extension of SPICE for Sparse Endmember Estimation in Hyperspectral Imagery," in *IEEE Geoscience and Remote Sensing Letters*, vol. 13, no. 12, pp. 1910-1914, **2016**.
- [28] X.Yu, I.S. Reed, and A.D. Stocker, "Comparative performance analysis of adaptive multispectral detectors," *IEEE Trans. Signal Processing*, vol. 41, pp. 2639–2656, Aug. **1993**.
- [29] C.E. Cafer, et al. "Improved covariance matrices for point target detection in hyperspectral data," *Optical Engineering*, Vol. 47, No. 7, **2008**.
- [30] C.C. Funk, J. Theiler, D.A. Roberts and C.C. Borel, "Clustering to Improve Matched Filter Detection of Weak Gas Plumes in Hyperspectral Thermal Imagery", in *Proceedings of IEEE Geoscience and Remote Sensing Symposium*, vol. 39, pp. 1410-1420, **2001**.
- [31] E.J. Kelly, "An Adaptive Detection Algorithm," *IEEE Trans. Aerosp. Electron. Syst.* 22 (1), pp. 115–127, **1986**.
- [32] C. Vaiphasa, A.K. Skidmore, W.F. Boer, T. Vaiphasa, "A hyperspectral band selector for plant species discrimination," *ISPRS J. Photogramm. Remote Sens.*, vol. 62, no. 3, pp. 225–235, Aug. **2007**.
- [33] Jin, X.; Paswaters, S. & Cline, H. A comparative study of target detection algorithms for hyperspectral imagery *SPIE*, 73341, **2009**.
- [34] Y. Gu, et al. Kernel-based regularized-angle spectral matching for target detection in hyperspectral imagery. *Pattern Recognition Letters*, **2011**.

- [35] S. Ozturk, et al. "A Novel 2-Stage Approach For Co₂ Gas Detection Using Hyperspectral Imagery." 2018 9th Workshop on Hyperspectral Image and Signal "Processing: Evolution in Remote Sensing (WHISPERS). IEEE, **2018**.
- [36] C.I Chang, "Spectral information divergence for hyperspectral image analysis," IEEE 1999 International Geoscience and Remote Sensing Symp., Hamburg, Germany, pp. 509-511, 28 June-2 July, **1999**.
- [37] S.E. Yuksel, A. Karakaya, "Fusion of Target Detection Algorithms in Hyperspectral Images" International Journal of Intelligent Systems and Applications in Engineering, 4(4), 103-110, **2016**.
- [38] Y. Bengio, et al. "Deep Learning". Nature. 521 (7553). ss. 436-444, **2015**.
- [39] V. Francois-Lavet, "An Introduction to Deep Reinforcement Learning". Foundations and Trends in Machine Learning. 11 (3-4). ss. 219-354, **2018**.
- [40] Y. Xu, L. Zhang, B. Du, and F. Zhang, "Spectral-spatial unified networks for hyperspectral image classification," IEEE Transactions on Geoscience and Remote Sensing, no. 99, pp. 1-17, **2018**.
- [41] Z. Zhong, J. Li, Z. Luo, and M. Chapman, "Spectral-spatial residual network for hyperspectral image classification: A 3-d deep learning framework," IEEE Transactions on Geoscience and Remote Sensing, vol. 56, no. 2, pp. 847-858, **2018**.
- [42] G. Cheng, Z. Li, J. Han, X. Yao, and L. Guo, "Exploring hierarchical convolutional features for hyperspectral image classification," IEEE Transactions on Geoscience and Remote Sensing, no. 99, pp. 1-11, **2018**.
- [43] E. Bati, A. Çalışkan, A. Koz, A. A. Alatan, Hyperspectral anomaly detection method based on auto-encoder. In: Image and Signal Processing for Remote Sensing XXI. International Society for Optics and Photonics, p. 96430N., **2015**.
- [44] O.B. Özdemir, H. Soydan, Y. Yardımcı Çetin and H.Ş. Düzgün, "Neural Network Based Pavement Condition Assessment with Hyperspectral Images". Remote Sensing, 12(23), 3931, **2020**.
- [45] K. G. Toker and S.E. Yuksel, "Deep canonical correlation analysis for hyperspectral image classification", SPIE Remote Sensing International Symposium, France, **2019**.

- [46] M. Salman, S.E. Yuksel, "Hyperspectral Data Classification using Deep Convolutional Neural Networks", IEEE Signal Processing and Communications Applications Conference (SIU), Zonguldak, May, **2016**.
- [47] Anonim, Whitening theorem,
https://www.projectrhea.org/rhea/index.php/ECE662_Whitening_and_Coloring_Transforms_S14_MH (Erişim tarihi: **7 Aralık 2021**)
- [48] D.P. Kingma, et al. "A method for stochastic optimization". arXiv preprint arXiv:1412.6980, **2014**.