

HİPERSPEKTRAL TERMAL GÖRÜNTÜLERDE HEDEF TESPİTİ

TARGET DETECTION IN HYPERSPECTRAL THERMAL IMAGES

METEHAN YALÇIN

DOÇ. DR. SENİHA ESEN YÜKSEL ERDEM

Tez Danışmanı

DOÇ. DR. ALPER KOZ

Eş Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

için Öngördüğü YÜKSEK LİSANS TEZİ

olarak hazırlanmıştır.

MAYIS 2023

ÖZET

HİPERSPEKTRAL TERMAL GÖRÜNTÜLERDE HEDEF TESPİTİ

METEHAN YALÇIN

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği

Danışman: Doç. Dr. Seniha Esen YÜKSEL ERDEM

Eş Danışman: Doç. Dr. Alper KOZ

MAYIS 2023, 181 sayfa

Bu tez, hiperspektral termal görüntüleri kullanarak hedef tespit yöntemlerini araştırmaktadır. Hiperspektral termal görüntüler, elektromanyetik spektrumun uzun dalga boyu kızılötesi bölgesinden toplanan verileri içeren görüntülerdir. Bu görüntülerin hedeflerin malzeme özelliklerine ilişkin ayrıntılı spektral bilgi sağlaması hedef tespitinde faydalıdır. Ancak, hedeflerin bulunduğu ortamın hava koşullarının değişmesi uzun dalga kızılötesi (LWIR) hiperspektral görüntülerde (HSG) hedefin yeniden saptanmasını zorlaştırmaktadır. Buradan yola çıkarak önerilen radyans verileri üzerinde sahne transferi yöntemi, hedefin zor tespit edilebildiği görüntüleri, hedefin ayırt ediciliği daha yüksek görüntülere dönüştürerek daha zor koşullarda tespit edilebilmesini sağlamıştır. Ayrıca radyans verisi üzerinde derin öğrenme tabanlı modellerle de hedef tespit çalışmaları gerçekleştirilmiş ve uzun kısa-süreli hafıza (LSTM) tabanlı modelin en iyi sonuçları verdiği görülmüştür. Ek olarak, radyans verisi üzerinde ve radyans verisine sıcaklık-salıcılık dönüşümü (TES) uygulanarak elde edilen salıcılık (emissiviy) verileri üzerinde imza tabanlı eşleştirme yöntemleri ile yapılan hedef tespit çalışmaları neticesinde salıcılık verisinin bir miktar daha iyi performans gösterdiği görülmüştür. Cisimlerin termal eylemsizlik ve ısı sığalarından kaynaklanan karakteristik ışıma özellikleri sebebiyle gün içerisindeki ısınma ve soğuma profilleri birbirinden farklı

olmaktadır. Materyallerin zamansal ışıma karakteristiklerinden faydalanabilmek için önerilen yöntemde cisimlerin sıcaklık profilleri üzerinde, önerilen bir diğer yöntemde ise radyans verilerinin birleştirilmeleri ile oluşturulan zamansal LWIR HSG'ler üzerinde hedef tespiti gerçekleştirilmiştir. Son olarak LWIR HSG'ler üzerinde boyut düşürme teknikleri uygulanarak boyut azaltılmış ve hedeflerin tespitinde önemli olan dalga boyları belirlenmiştir. Nesnelerden yayılan ışıma ile nesnelerle aynı sıcaklıktaki siyah cisim ışıması arasındaki farktan yola çıkarak yapılan hata analizinde hedef nesneleri ayırt edici dalga boylarının bant seçim teknikleri ile bulunan dalga boylarına benzer olduğu gözlemlenmiştir.

Keywords: hyperspectral görüntüleme, hedef tespiti, radyasyon, uzun dalga kızılötesi, sahne üretimi, derin öğrenme, termal ışıma,

ABSTRACT

TARGET DETECTION IN HYPERSPECTRAL THERMAL IMAGERY

METEHAN YALÇIN

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Seniha Esen YÜKSEL ERDEM

Co-Advisor: Assoc. Prof. Alper KOZ

MAY 2023, 181 pages

This thesis explores target detection methods using hyperspectral thermal images. Hyperspectral thermal images contain data collected from the long wavelength infrared region of the electromagnetic spectrum. These images provide detailed spectral information about the material properties of the targets, which is useful in target detection. However, changes in the weather conditions of the environment where the targets are located make it challenging to detect the target in long-wave infrared (LWIR) hyperspectral images (HSI). Based on this observation, a scene transfer method is proposed in this thesis which transforms the radiance data in the images where the target is difficult to detect, into the images with higher discrimination and hence, enables the detection of targets in more difficult conditions. In addition, target detection studies are carried out with deep learning-based models on radiance data and it is observed that the long-short-term memory (LSTM) based model gives the best results. Also, as a result of target detection studies performed with signature-based matching methods on the radiance data and on the emissivity data obtained by applying temperature-emissivity transform (TES) to the radiance data, it is observed that the emissivity data perform slightly better. The heating and cooling profiles of the objects during the day are different from each other due to the characteristic radiation properties arising from

the thermal inertia and heat capacity of the objects. In order to benefit from the temporal radiation characteristics of the materials, target detection is performed on the temperature profiles of the objects in the proposed method, and on the temporal LWIR HSI's created by combining the radiance data in another proposed method. Finally, dimension reduction techniques are applied on LWIR HSI's, and the wavelengths that are important in detecting targets are determined. In the error analysis based on the difference between the radiation emitted from the objects and the black body radiation at the same temperature as the objects, it is observed that the wavelengths for distinguishing the target objects are similar to the wavelengths found by band selection techniques.

Keywords: hyperspectral imaging, target detection, radiation, long wave infrared, scene generation, deep learning, thermal radiation

TEŞEKKÜR

Birlikte çalışmaktan gurur duyduğum değerli akademik danışmanım Doç. Dr. Seniha Esen Yüksel Erdem'e en içten teşekkürlerimi borç bilirim. Bana rehberlik ettiğiniz, araştırma sürecinde yol gösterdiğiniz ve her yaşadığım sorunda bana karşı gösterdiğiniz sonsuz sabır için minnettarım. Sizin bilgi ve deneyimlerinizden faydalanma fırsatına sahip olmaktan dolayı her zaman gurur duyacağım.

Tezin başından sonuna kadar her adımda bana yol gösteren, deneyimi ve yardımseverliği ile öğrenme sürecimde büyük katkıları olan ve kendisiyle çalışmaktan gurur ve kıvanç duyduğum değerli eş danışmanım Doç. Dr. Alper Koz'a teşekkürlerimi sunarım.

Tez çalışmalarımnda bana hep moral ve destek veren, sabırla beni bir an olsun yalnız bırakmayan ve bu uzun ve zorlu yolculukta başarılı olmamda en büyük pay sahibi sevgili eşim Gizem'e sonsuz teşekkür ederim.

Deneyim ve bilgilerine ulaşma fırsatını bulmaktan dolayı gurur duyduğum, kısa sürede kendilerinden çok kıymetli bilgiler öğrendiğim değerli jüri üyelerine,

Hayatım boyunca beni her zaman destekleyen, sevgisini asla esirgemeyen ve bugünlere gelmem için büyük emekler veren sevgili annem Ayla, babam Hasan ve kardeşlerim Merve ve Furkan'a,

Tez sürecinde maddi manevi desteklerini esirgemeyen Simel, Şakir ve Sinem Kartal'a,

İyi, kötü her günümde yanımda olan, tez sürecinde hep kıymetli fikirlerine başvurduğum sevgili dostum Gündüz Özkul'a,

Son olarak bu süreçte hep yanımda olan değerli arkadaşlarım Engin Gürhan, Ali Can Koç, Duygu Kaymak ve bütün yakın arkadaşlarıma sonsuz teşekkürler...

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
TABLolar	ix
ŞEKİLLER	x
KISALTMALAR	xv
1. GİRİŞ	1
1.1. Tezin Amacı ve Katkıları	4
1.2. Tezin Akışı	6
2. LİTERATÜRDEKİ ÇALIŞMALAR VE İLGİLİ TEORİK KAVRAMLAR	8
2.1. LWIR Hiperspektral Görüntülerde Hedef Tespiti	9
2.1.1. SPICE Veri Kümesinde Hedef Yeniden Tespit Çalışmaları	23
2.2. İmza Tabanlı Eşleştirme Algoritmaları	26
2.3. Hiperspektral Görüntülerde Derin Öğrenme Tabanlı Hedef Tespit Yöntemleri .	26
2.3.1. Sadece Spektral Bilgi Kullanan Derin Öğrenme Yöntemleri	27
2.3.2. Sadece Uzamsal Bilgi Kullanan Derin Öğrenme Yöntemleri	28
2.3.3. Spektral-Uzamsal Bilgi Kullanan Derin Öğrenme Yöntemleri	29
2.3.4. Çekişmeli Üretici Ağlar Kullanan Derin Öğrenme Yöntemleri	31
2.3.5. Derin Yapay Sinir Ağları ve Temel Kavramlar	31
2.3.5.1. CNN tabanlı modeller	32
2.3.5.2. Evrişim katmanları	33
2.3.5.3. Havuzlama katmanları	34
2.3.5.4. Tamamen Bağlı Katmanlar	35
2.3.5.5. Aktivasyon Fonksiyonları	35
2.3.5.6. Kayıp Fonksiyonları	36

2.3.5.7. Tekrarlayan Sinir Ağları.....	37
2.3.5.8. Uzun Kısa-Süreli Hafıza	38
2.3.5.9. Çekişmeli Üretici Ağlar	38
2.4. Hiperspektral Görüntülerde Boyut Azaltma Yöntemleri.....	41
2.4.1. Bant Seçim Teknikleri.....	43
2.4.1.1. Yinelemeli Öznitelik Eleme.....	43
2.4.1.2. Boruta ile Öznitelik Seçimi	44
2.4.2. Boyut Azaltma Teknikleri.....	45
2.4.2.1. Temel Bileşenler Analizi	45
2.5. Çekişmeli Üretici Ağlar ile HSG Üretimi	45
3. ÖNERİLEN YENİDEN HEDEF SAPTAMA YÖNTEMLERİ.....	47
3.1. Atmosferik Düzeltme ve Sıcaklık-Salıcılık Dönüşümleri.....	47
3.2. Radyans Verisi Üzerinde Hedef Tespiti	51
3.3. Parlaklık Sıcaklığı Verisi Üzerinde Hedef Tespiti	54
3.4. Sahne Transfer Yöntemi Kullanılarak Hedef Tespiti	61
3.5. Uzun Kısa-Süreli Hafıza ile Hedef Tespiti.....	66
3.6. Zamansal LWIR HSG üzerinde Hedef Tespiti.....	68
3.7. Deneysel Karşılaştırmalarda Kullanılan Derin Öğrenme Tabanlı Hedef Tespit Yöntemleri	73
3.7.1. Bağlamsal Derin CNN ile Hiperspektral Sınıflandırma	73
3.7.2. Uzaktan Algılama Görüntü Sınıflandırmasına Üç Boyutlu Derin Öğrenme Yaklaşımı	74
3.7.3. Hiperspektral Görüntü Sınıflandırması için Çok Ölçekli 3 Boyutlu Derin CNN	74
3.7.4. SpectralNET: Hiperspektral Görüntü Sınıflandırması için Uzamsal-Spektral WaveletCNN	75
3.7.5. HybridSN: Hiperspektral Görüntü Sınıflandırması için 3D-2D CNN Özellik Hiyerarşisini Keşfetme	76
4. UZUN DALGA BOYU HİPERSPEKTRAL GÖRÜNTÜ VERİ KÜMESİ	77
4.1. SPICE Veri Kümesi	77

4.2. Veri Kümesinde Karşılaşılan Zorluklar	84
5. DENEYLER ve GÖZLEMLER	86
5.1. Deneylerin Akışı	86
5.2. Değerlendirme Metrikleri	87
5.3. Spektral İmza Seçimi	89
5.4. İmza Tabanlı Eşleştirme Yöntemleri ile Salıcılık Verisi Üzerinde Hedef Tespiti	97
5.5. İmza Tabanlı Eşleştirme Yöntemleri ile Radyans Verisi Üzerinde Hedef Tespiti	101
5.5.1. Saat Farkının Hedef Tespitine Etkisi	101
5.5.2. Mevsimsel Farklılıkların Hedef Tespitine Etkisi.....	104
5.5.3. Gün Farkının Hedef Tespitine Etkisi	105
5.6. Parlaklık Sıcaklığı Verisi Üzerinde Hedef Tespiti	109
5.6.1. Tespit Algoritması ve Örnekleme Sıklığı Seçimi	109
5.6.2. Sıcaklık Profilleri ile Hedef Tespiti.....	111
5.7. Sahne Transfer Yöntemi Kullanılarak Hedef Tespiti	112
5.8. Uzun Kısa-Süreli Hafıza Tabanlı Model ile Hedef Tespiti	116
5.8.1. Günlük Örnekleme Sıklığının Eğitim Performansına Etkisi	116
5.8.2. Gün Farkının Hedef Tespitine Etkisi	118
5.9. Zamansal Hiperspektral Görüntüleri Kullanarak İmza Eşleştirme Yöntemleri ile Hedef Tespiti	122
5.9.1. Örnekleme Sıklığı Seçimi.....	122
5.9.2. Referans ve Test Günleri Arasındaki Zaman Farkı Etkisi	124
5.9.3. Gün İçerisindeki Sıcaklık Değişiminin Hedef Tespitine Etkisi	126
5.10. Zamansal Hiperspektral Görüntüleri kullanarak Derin Öğrenme ile Hedef Tespiti	127
5.10.1. Örnekleme Periyodunun Hedef Tespitine Etkisi	127
5.11. Derin Öğrenme Yöntemleri ile Hedef Tespiti	130
5.11.1. Deney Hiperparametreleri	131
5.11.2. Test Sonuçları.....	132
5.12. Boyut Azaltma ve Bant Seçiminin Hedef Tespitine Etkisi.....	136
6. ÇIKARIMLAR.....	141

TABLÖLAR

	<u>Sayfa</u>
Tablo 2.1 Elektromanyetik Spektrumlar ve Dalga Boyları	9
Tablo 4.1 Hiperspektral kameranın özellikleri	80
Tablo 5.1 Önerilen tespit yöntemleri diagramı.....	87
Tablo 5.2 01.05.2013 tarihinde 24 adet küple eğitilmiş LSTM modeli ile farklı günlerdeki test sonuçları	121
Tablo 5.3 Bağlamsal derin CNN ile hiperspektral sınıflandırma.....	132
Tablo 5.4 Uzaktan algılama görüntü sınıflandırmasına 3-boyutlu derin öğrenme yaklaşımı.....	133
Tablo 5.5 Hiperspektral görüntü sınıflandırması için çok ölçekli 3 boyutlu derin CNN	133
Tablo 5.6 SpectralNET: Hiperspektral görüntü sınıflandırması için Uzamsal-Spektral WaveletCNN	134
Tablo 5.7 HybridSN: Hiperspektral görüntü sınıflandırması için 3D-2D CNN özellik hiyerarşisini keşfetme	134
Tablo 5.8 Modellerin birbirleri ile karşılaştırmaları	135
Tablo 5.9 Modellerin zaman dilimlerine göre performans değerlendirmeleri	136

ŞEKİLLER

	<u>Sayfa</u>
Şekil 2.1	Atmosferik emilim [1] 10
Şekil 2.2	SPICE veri kümesindeki materyallerin radyans spektrumları 11
Şekil 2.3	Gürültülü bantlardan arındırılmış materyal spektrumları 12
Şekil 2.4	2, 5, 10 piksel bloğu boyutlarında (N_t) RIAD (Range-Invariant Anomaly Detector) yönteminin radyans, salıcılık ve parlaklık sıcaklığı verileri üzerindeki performansı [2] 14
Şekil 2.5	ISAC yöntemiyle elde edilmiş materyal salıcılıkları (01.05.2013-11:48) [3] 14
Şekil 2.6	Sol üst: Radyans Görüntüsü. Sağ Üst: Parlaklık Sıcaklığı. Sol alt: Bağlı Salıcılık. Sağ Alt: Normalleştirilmiş Bağlı (Relative) Salıcılık [4] 15
Şekil 2.7	Temel ısı transferi yöntemleri [5] 17
Şekil 2.8	Elektromanyetik spektrum üzerinde Planck [6] ve Wien [7] eğrileri [1, 8] 18
Şekil 2.9	Hedef 1 üzerinde seçilmiş noktalar 21
Şekil 2.10	Hedef 1 üzerinden seçilmiş noktaların spektrumları 21
Şekil 2.11	Materyallerin gün içerisindeki sıcaklık değişimleri 22
Şekil 2.12	Tank0 hedefinin QTES yöntemi aracılığı ile hesaplanan salıcılıklarının günlük değişimi [3] 24
Şekil 2.13	Tank0 hedefinin QTES yöntemi aracılığı ile hesaplanan salıcılıklarının günlük değişimi [3] 24
Şekil 2.14	İstiflenmiş Otokodlayıcı (SAE) modeli mimarisi [9] 28
Şekil 2.15	Evrişim tabanlı sınıflandırıcı modeli LeNet-5 mimarisi [10] 32
Şekil 2.16	(a) SPICE test sahnesi. (b) SPICE test sahnesinde evrişim operasyonu sonucu 33
Şekil 2.17	Üç boyutlu evrişim [11] 34

Şekil 2.18	Aktivasyon haritası (sol), maksimum havuzlama (sağ üst) ve ortalama havuzlama (sağ alt) örneği	35
Şekil 2.19	Aktivasyon fonksiyonları [12]	36
Şekil 2.20	Tekrarlayan sinir ağları	37
Şekil 2.21	Uzun kısa-süreli hafıza modülü	38
Şekil 2.22	Üretici çekişmeli ağlar genel şeması	39
Şekil 3.1	Sensöre ulaşan ışıma $L_s(\lambda)$ ve siyah cisim ışıması $B(T, \lambda)$ dağılımı ..	50
Şekil 3.2	Sahneye yerleştirilmiş tank hedeflerinin farklı hava koşullarındaki radyans imzaları	53
Şekil 3.3	Sahnedeki atmosfer etkisi.....	54
Şekil 3.4	Parlaklık sıcaklığı kestirimi örneği	57
Şekil 3.5	Parlaklık sıcaklığı haritası	58
Şekil 3.6	Siyah cisim ışımasına en yakın Planck eğrisi kestirimi	59
Şekil 3.7	Nesnelerin Planck siyah cisim ışıma eğrilerinden sapmaları.....	60
Şekil 3.8	Sahne transfer yöntemi.....	61
Şekil 3.9	Üretici ağ	64
Şekil 3.10	Ayrıştırıcı ağ.....	65
Şekil 3.11	LSTM modülleri birleşimi ile elde edilen HSG sınıflandırıcı yapısı ...	68
Şekil 3.12	Zamansal LWIR HSG’lerde materyal spektrumlarının standart sapma ve ortalama değerleri	69
Şekil 3.13	Materyallerin gün içindeki radyans ortalamaları	70
Şekil 3.14	Zamansal LWIR HSG örneği (4 HSG birleşimi)	71
Şekil 3.15	Zamansal LWIR HSG’lerde materyal spektrumlarının standart sapma ve ortalama değerleri	72
Şekil 3.16	Lee ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [13].....	73
Şekil 3.17	Hamida ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [14] ..	74
Şekil 3.18	He ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [15].....	75
Şekil 3.19	SpectralNET HSG sınıflandırıcı mimarisi [16]	76
Şekil 3.20	HybridSN HSG sınıflandırıcı mimarisi [17]	76
Şekil 4.1	Görüntüleme alanı Google Haritalar görüntüsü [18]	78

Şekil 4.2	SPICE veri kümesi sahne örnekleri	79
Şekil 4.3	Etiketlenmiş sahne ve etiketleme aracı.....	81
Şekil 4.4	Hiperspektral görüntülerin kalibrasyon kayıtları	82
Şekil 4.5	Sahne görüntüsü ve materyallerin radyansları [19].....	82
Şekil 4.6	Cisimlerin spektral imzalarının mesafeye göre değişimi [19]	83
Şekil 4.7	Farklı tarihlerde alınmış görüntülerdeki piksel kaymaları	84
Şekil 4.8	Kalibrasyon sırasında bozulmuş görüntü ve kalibrasyon kayıtları.....	85
Şekil 4.9	Temiz görüntü ve kalibrasyon kayıtları	85
Şekil 5.1	Jaccard indeksi gösterimi	89
Şekil 5.2	Bant sayısının azaltılmasının hedef tespitine etkisi.....	90
Şekil 5.3	Gürültülü bantlardan arındırılmış sahne görüntüsü (HSG spektral ortalaması).....	90
Şekil 5.4	Hedeflerin tavanlarından referans imza alınan noktalar	91
Şekil 5.5	Hedeflerin tavanlarında belirlenmiş noktalardan alınan referans spektrumlar	91
Şekil 5.6	Hedeflerin ortalarından referans spektrum alınan noktalar.....	92
Şekil 5.7	Hedeflerin ortalarında belirlenmiş noktalardan alınan referans spektrumlar	92
Şekil 5.8	Hedef 1 üzerinde seçilmiş noktalar.....	93
Şekil 5.9	Hedef 1 üzerinden seçilmiş noktaların spektrumları	94
Şekil 5.10	Hedef 2 üzerinde seçilmiş noktalar.....	94
Şekil 5.11	Hedef 2 üzerinden seçilmiş noktaların spektrumları	95
Şekil 5.12	Hedef 3 üzerinde seçilmiş noktalar.....	95
Şekil 5.13	Hedef 3 üzerinden seçilmiş noktaların spektrumları	96
Şekil 5.14	Referans imza seçiminin tespit performansına etkisi.....	97
Şekil 5.15	Salıcılık dönüşümü sonucunda elde edilen materyal salıcılık spektrumları	98
Şekil 5.16	Salıcılık spektrumları kullanılarak yapılan hedef tespit sonuçları	99
Şekil 5.17	Salıcılık ve radyans imzaları kullanılarak yapılan testlerin görselleştirilmesi	100

Şekil 5.18	11:58 referans imzası ile 2 Mayıs tarihindeki yeniden tespit performansı.....	102
Şekil 5.19	14:58 referans imzası ile 2 Mayıs tarihindeki yeniden tespit performansı.....	103
Şekil 5.20	Farklı mevsimlerden alınan referans imzaların performansları: (a) Sonbahar; (b) Yaz; (c) İlkbahar; ve (d) Kış.....	104
Şekil 5.21	Farklı mevsimlerde elde edilen meteorolojik veriler	105
Şekil 5.22	Hava sıcaklığının hedef tespiti etkisi-referans imza 00:00	106
Şekil 5.23	Nemin hedef tespiti etkisi-referans imza 08:57	107
Şekil 5.24	Hava sıcaklığı, nem ve güneşlenmenin hedef yeniden tespiti etkisi .	108
Şekil 5.25	Etiketlenmiş sahne ve etiketleme aracı.....	110
Şekil 5.26	Sıcaklık profilleri kullanılarak hedef tespit görselleştirmesi	111
Şekil 5.27	Doğruluk haritası ve test sonuçları görselleştirmeleri	112
Şekil 5.28	Test sahnesinin referans sahneye dönüştürülmesi örnekleri.....	113
Şekil 5.29	Hedefe ait referans, test ve transfer spektral imzaları	114
Şekil 5.30	Sahne transferi ile hedef tespit performansının iyileştirilmesi çalışmasında kullanılan test görüntüleri ve transfer edilmiş test görüntüleri.	115
Şekil 5.31	He [15] çalışmasının test görüntüsü ve transfer edilmiş test görüntüsü üzerindeki hedef tespit performansı.	116
Şekil 5.32	Farklı sayıda HSG ile eğitilen modellerin belirli saatlerdeki performansları	117
Şekil 5.33	Farklı sayıda HSG ile eğitilen modellerin günlük ortalama performansları	118
Şekil 5.34	01.05.2013 tarihinde saat başı alınan 24 adet HSG ile eğitilmiş LSTM modelinin 02.05.2013 alınan HSG'lerde test sonuçları	119
Şekil 5.35	02.05.2013 tarihinde 24 adet küple eğitilmiş LSTM modeli ile farklı günlerdeki test sonuçları	120
Şekil 5.36	Örnekleme sıklığının hedef tespit performansına etkisi	123

Şekil 5.37	Zamansal LWIR HSG’ler üzerinde bütün hedeflerin yeniden tespiti sonuçları	124
Şekil 5.38	Zamansal LWIR HSG’ler üzerinde 0° hedefin yeniden tespit sonuçları	125
Şekil 5.39	Referans imza alındığı mevsimin yeniden tespit performansına etkisi .	126
Şekil 5.40	A set of four subfigures.	128
Şekil 5.41	Eğitim verisinin artırılmasının performansa etkisi (3 HSG ile eğitim) .	129
Şekil 5.42	Eğitim verisinin artırılmasının performansa etkisi(11 HSG ile eğitim)	130
Şekil 5.43	ACE sınıflandırıcı kullanarak çeşitli boyut azaltma ve bant seçme yöntemleri sonuçları	137
Şekil 5.44	Uyum filtresi (MF) kullanarak çeşitli boyut azaltma ve bant seçme yöntemleri sonuçları	138
Şekil 5.45	Boruta yöntemi ile seçilmiş dalga boyları	139
Şekil 5.46	RFE yöntemi ile seçilmiş dalga boyları	140

KISALTMALAR

ACE	: Adaptive Coherence Estimator
SAM	: Spectral Angle Mapper
MF	: Matched Filter
LWIR	: Long Wave InfraRed
MWIR	: Mid Wave InfraRed
SWIR	: Short Wave InfraRed
HSG	: HiperSpektral Görüntü
ROC	: Receiver Operating Characteristic
GAN	: Generative Adversarial Networks
LSTM	: Long Short-Term Memory
VNIR	: Very Near InfraRed
ISAC	: In-scene Atmospheri Compensation
QTES	: Quick Temperature Emissivity Seperation
AETES	: Alpha Emissivity Temperature Emissivity Seperation
TES	: Temperature Emissivity Seperation
Temas	: Conduction
Konveksiyon	: Convection
Radyasyon	: Radiation
Isı kapasitesi	: Heat Capacity
Termal Eylemsizlik	: Thermal Inertia
Termal İletkenlik	: Thermal Conductivity
DBF	: Deep Belief Network
MDB	: Multi-Domain Battle
SAE	: Stack Auto Encoder
SVM	: Support Vector Machine
LR	: Logistic Regression

1D-CNN	: 1-Dimensional Convolutional Neural Networks
2D-CNN	: 2-Dimensional Convolutional Neural Networks
3D-CNN	: 3-Dimensional Convolutional Neural Networks
PCA	: Principle Component Analysis
GNN	: Graph Neural Network
FCL	: Fully Connected Layers
MSE	: Mean Squared Error
HybridSN	: Hybrid Spectral Convolutional Neural Network
SPICE	: Spectral and Polarimetric Imagery Collection Experiment
ARL	: The U.S. Army Research Laboratory
ARDEC	: US Army Armament Research, Development and Engineering Center
AFIT	: US Air Force Institute of Technology
FFT	: Fast Fourier Transform
AUC	: Area Under Curve
TPR	: True Positive Rate
FPR	: False Positive Rate
DTC	: Decision Tree Classifier
RFC	: Random Forest Classifier
UFS	: Univariate Feature Selection
MSE	: Mean Squared Error
RF Random Forest	
UMAP	: Unified Manifold Approximation and Projection
Salıcılık	: Emissivity
İletkenlik	: Transmittance
İğreti tanımlanmış	: Ill-Posed
Pürüzsüz	: Smooth
Dönüştürücü	: Transformer

1. GİRİŞ

Uzaktan algılama, nesnelerin özelliklerini ölçmek veya bir ortamın durumunu tespit etmek için bir cihaz kullanarak belirli bir mesafeden veri toplama yöntemidir. Bu yöntemler genellikle radar, kızılötesi kamera, spektrometre, lidar, SAR gibi görüntüleme yöntemleri kullanılarak nesnelerin ve ortamların görüntülenmesini sağlamaktadır.

Günlük hayatımızda sıkça kullandığımız kamera ve fotoğraf makineleri elektromanyetik spektrumun görünür bölgesinde cisimlerin yansıttıkları enerjiyi algılayarak nesnelerin görüntülenmesini sağlarlar. Bu yöntemler genellikle coğrafi bilgi sistemleri gibi uzaktan algılama görevlerinde sıkça kullanılmaktadır.

Radar ve lidar görüntüleme yöntemleri ise, kendi gönderdikleri elektromanyetik enerjinin nesnelerin yüzeylerinden dönüşünü yakalayıp kullanan aktif algılama sistemleridir. Bu yöntemler günümüzde hava trafik kontrolü, uzay araştırmaları ve askeri amaçlarla kullanılmaktadır. Ayrıca lidar ile görüntüleme sistemleri sürücüsüz otomobil sistemlerinde yol takibi ve üç boyutlu haritalandırma görevlerini gerçekleştirebilmek için kullanılmaktadır.

Hiperspektral görüntüleme, bir cismin yüzeyinden yansıyan enerjinin farklı dalga boylarında yakalanarak sahneye ait uzamsal bilginin yanı sıra, her piksele ait spektrum bilgisinin de kaydedildiği görüntüleme sistemidir. Bu görüntüleme sistemi, cisimlerin spektrum bilgilerini de içerdiği için materyal özelliklerini tespit etmek için kullanılmaktadır. Bu çalışmada elektromanyetik spektrumun uzun dalga kızılötesi (LWIR) bölgesinden alınmış hiperspektral görüntülerle (HSG'lerle) oluşturulmuş Spektral ve Polarimetrik Görüntü Toplama Deneyi (SPICE) veri kümesi [19] kullanılmaktadır. Bu veri kümesi, elektromanyetik spektrumun $7.48 \mu\text{m} - 12.45 \mu\text{m}$ dalga boyu aralığında, her piksele ait 165 farklı dalga boyunda radyans bilgileri içeren hiperspektral küplerden oluşmaktadır.

Kısa dalga kızılötesi bant (SWIR) ve görünür ve kısa dalga kızılötesi bant (VNIR) görünür ışık bandından daha düşük frekanslara sahip olup, dalga boyları 400 nm 'den $1 \mu\text{m}$ 'ye kadar uzamaktadır. Bu görüntülemelerde hem gündüz gözetlemesi yapılabilen hem de yakın

kızılötesi bant kullanarak elde edilen NDVI indeksi ile bitkilerin sağlık durumu kontrol edilebilmektedir [20].

Elektromanyetik spektrumun 3 μm - 5 μm dalga boyu aralığını ifade eden orta dalga kızılötesi bant (MWIR) bölgesinde yapılan görüntülemeler çoğunlukla gaz sızıntısı tespiti gibi uygulamalarda kullanılmaktadır. Ayrıca termal bölgenin hem ısı hem de yansıma özelliklerini taşıyan bir elektromanyetik bölge olmasından dolayı savunma sistemlerinde de kullanılmaktadır [21].

Uzun dalga kızılötesi sensörler, 7.5 μm - 14 μm aralığında cisimlerin yaydığı enerjiyi algılayabilen sensörlerdir. Bu elektromanyetik spektrum aralığı, cismin sahip olduğu sıcaklık neticesiyle üretilen enerji tarafından domine edilmekte olup termal kızılötesi bant olarak da bilinmektedir. Kızılötesi sensörlere sahip sistemler pek çok alanda kullanılmakta olup, coğrafi bilgi sistemleri, hava durumu tahminleri, uzay araştırmaları, yeryüzü toprak özelliklerinin ölçümü, ormanların ve bitkilerin sağlık durumunun takibi, insan vücut sıcaklığı ölçümü, yeryüzündeki gözle görülemeyecek kimyasalların tespiti gibi pek çok alanda kullanılabilmektedir. Ayrıca bu sensörler sıcaklığa duyarlı olduğundan gece görüntüleme sistemleri için oldukça elverişlidir [22].

Uzun dalga hiperspektral görüntüler (LWIR HSG) kullanılarak hedef tespiti yapılan pek çok uygulama mevcuttur. Yoğun bilgi içeriğinden faydalanılarak yapılan hedef tespitlerinin tutarlılığı da yüksek olmaktadır. Fakat bilgi içeriğinin zenginliği beraberinde zorluklar da getirmektedir. Görüntüleme uzamsal çözünürlüğünün yüksek olmadığı durumda pikseller arasında karışım sıkça olmaktadır. Örneğin, uydu ile yapılan dünya görüntülemesinde tek bir piksel içerisinde birçok nesne girebilmektedir. Bina, araba ve ağaç aynı piksele düşebilmekte ve bu da tek bir spektrum içerisinde birden çok materyalden gelmiş ışıınım bilgisinin karışmasına sebep olarak hedef tespitini zorlaştırmaktadır. Bu çalışmada görüntüler 542 metre uzaklıktaki bir kuleden alınmış olup, uydu görüntülemesine kıyasla daha az spektral karışım içermektedir.

LWIR HSG üzerinden hedef tespitindeki bir başka zorluk atmosfer etkisinin yoğun olmasıdır. Atmosferdeki su bileşeni nedeniyle elektromanyetik spektrumun bazı dalga

boyu aralıklarında (5 - 8 μm) baskınlığı artmakta, uzaktan algılama performansını olumsuz etkilemektedir. Su bantlarının haricinde görüntü kalitesini düşüren birçok etki bulunmaktadır. Bu çalışmada 165 bandın hepsi birden kullanılmamış olup SPICE veri kümesini toplayan araştırmacıların da [19] bahsettiği şekilde bant azaltılması yapılmıştır. Ayrıca bant sayısının azaltılması ile ilgili deneyler yapılmış ve boyut azaltımının hedef tespiti üzerindeki olumlu etkisi gözlenmiştir. Hedef tespit algoritmalarından olan Uyarlanabilir Tutarlılık Tahmincisi (ACE) [23] ve Uyum Filtresi (MF) [24] kullanılarak tespit yapılmış ve ilgili performanslar alıcı işletim karakteristiği (ROC) eğrileri üzerinden değerlendirilmiştir. Yapılan deneylerde, hiperspektral görüntülerde gürültülü bantların çıkarılmasının hedef tespitine olumlu katkılarda bulunduğu gözlenmiştir.

HSG’lerde hedef tespiti yapmaktaki bir diğer zorluk cisimlerin yaymış oldukları elektromanyetik ışımanın, farklı mesafelerdeki hedefler için farklı görüntülenmesidir [19]. Cisme yakın bir yerden alınmış spektra ile uzaktaki cismin spektrumu arasında fark bulunmaktadır. Bunun sebepleri arasında, cisimden yayılan ışımanın mesafe arttıkça ortam ile etkileşiminin artması ve sinyalin gürültüye oranının (SNR) mesafe ile azalması gösterilebilir. Bu durum, spektra eşleştirme tabanlı hedef tespit yöntemleri için sorun oluşturmakta, hangi nesnenin spektrasının kullanılması gerektiği konusunda tereddüt yaratmaktadır. Ayrıca yapılan deneylerde hedef imza spektrumu hedef üzerindeki farklı noktalardan seçilerek hedef tespit çalışmaları yapılmış ve imzanın seçildiği noktaların hedef tespit performansını değiştirdiği gözlenmiştir. Ayrıca LWIR HSG’lerde cisimlerin yaymış oldukları ışımalar, hava sıcaklığı, güneşlenme, rüzgar etkisi, bulutluluk, nem oranı gibi birçok etkenden etkilenmekte olup hedef tespit performansına olumsuz etki edebilmektedir.

Bu tezde LWIR HSG üzerinde hedef tespiti için aşağıda belirtilen yöntemler önerilmiş ve deneylerle performansları incelenmiştir.

- Salıcılık verisi üzerinde hedef tespiti
- Radyans verisi üzerinde imza tabanlı yöntemlerle hedef tespiti
- Parlaklık sıcaklığı verisi üzerinde hedef tespiti

- Sahne transferi yöntemi ile hedef tespiti
- Zamansal HSG üzerinde hedef tespiti
- Derin öğrenme yöntemleri kullanılarak hedef tespiti
- Bant seçimi ve bant sayısı azaltma yöntemlerinin tespiti etkisi

Önerilen yöntemler, askeri hedef tespiti, maden sahasında mineral haritalama gibi uygulamalarda önem arz etmektedir. Örnek olarak, bilinen bir maden sahasının belirli periyotlarda LWIR görüntüleri alındıktan sonra elde edilen görüntü setleri kullanılarak tek görüntü ve görüntü setleri ile hedef tespiti gerçekleştirilebilir. Bir günlük sıcaklık profili bilinen mineral, sonraki günlerde de tespit edilebilir. Ayrıca gün içerisinde belirli periyotlarla elde edilen LWIR HSG'ler derin öğrenme tabanlı hedef tespit modellerinin eğitiminde kullanılabilir. Aynı zamanda bu görüntülerden askeri hedeflerin günlük ısıtım ve sıcaklık profilleri çıkarılarak bu hedeflerin sonraki günlerde tespiti sağlanabilir. Çeşitli hava koşullarında gözlemlenen askeri alandan alınan LWIR HSG'ler ile öğrenilmiş sahne üretimi modeli, hava şartlarının olumsuz olduğu koşullarda alınan LWIR görüntülerde kullanılarak bu görüntülerin olumlu hava şartlarına çevrilmesi ile hedef tespitinin iyileştirilmesi sağlanabilir.

1.1. Tezin Amacı ve Katkıları

Farklı zamanlarda alınan LWIR HSG'ler sahne aynı olsa bile spektral farklılıklar gösterebilmekte, bir görüntüde yeri bilinen bir cismin farklı bir HSG'de tespit edilebilirliği hava koşuluna göre zorlaşabilmektedir. Bu sebeple tezde farklı hava koşulları ve zaman aralıklarında elde edilmiş LWIR HSG'lerde hedef yeniden tespiti amaçlanmaktadır. Bir gün görüntüsünden alınan, hedef cisme ait spektral imza, bir başka günde imza tabanlı eşleştirme yöntemleri kullanılarak aratıldığında, günler arasında atmosferik farklılıklar arttığında tespit performansının düştüğü görülmüştür [25]. Hava koşullarının oluşturduğu performans düşümünü azaltabilmek için, hedef tespiti yapılacak sahne, hangi hava koşulunda olursa olsun, referans imzanın alındığı hava koşullarına transfer edilmeye çalışılmıştır. Bu görevi

gerçekleştirebilmek için Çekişmeli Üretici Ağlar (GAN [26]) tabanlı yöntemler kullanılarak hiperspektral sahneler istenilen hava koşuluna transfer edilmiş, referans imza ile transfer edilen sahne üzerinde hedef tespiti yapılmaya çalışılmış ve sahne transferinin hedef tespiti üzerindeki etkisi incelenmiştir.

Materyallerin spektral imzaları arasında doğal olarak farklılıklar bulunduğu gibi, hava koşullarına verdikleri tepkiler de cisimleri birbirinden ayırt edebilmemizi sağlayabilmektedir. Bu sebeple tezde cisimlerin ışınlamalarının çevre koşullarındaki değişime göre gösterdikleri zamansal tepkileri temel alan yeni bir yöntem önerilmiştir. Hiperspektral küpler birbirine ardı sıra birleştirilerek zamansal hiperspektral görüntüler elde edilmiş, bu büyütülmüş küplerden alınan referans spektral imzalar başka sahnelerde eşleştirme tabanlı tespit yöntemleri kullanılarak aratılmıştır. Tezimizde önerdiğimiz bir diğer yöntem ise bu zamansal küpleri kullanarak Uzun Kısa-Süreli Hafıza (LSTM) tekrarlayan derin öğrenme ağı eğitilerek hedef tespit gerçekleştirilebilmiş, bu yöntemin en iyi tespit performansını gösterdiği gözlemlenmiştir.

Derin öğrenme yöntemleri sahneler üzerinde anlamsal bölütleme problemlerinde sıkça kullanılmaktadır. Hiperspektral görüntüler üzerinde de birçok örneği bulunan bu derin öğrenme ağları, hedef tespit başarımlarını, eşleştirme tabanlı yöntemlere göre yukarılara taşımıştır. Fakat veri kümesi azlığı sebebiyle bu yöntemlerin LWIR HSG'ler üzerinde literatürdeki çalışma miktarı kısıtlanmaktadır. Literatüre bu modellerin LWIR HSG'ler üzerindeki etkilerinin incelenmesi yönünde katkıda bulunabilmek için belli derin öğrenme yöntemleri uygulanmış ve başarımları incelenmiştir.

LWIR bölgede ışınlamalarından parlaklık sıcaklığı dönüşümü uygulanarak cisimlerin parlaklık sıcaklıkları bulunmuş ve [25]'te sunulduğu gibi gün içerisindeki belirli periyodlarda elde edilmiş sıcaklık haritalarının birleştirilmesiyle oluşturulmuş sıcaklık küpleri üzerinde imza tabanlı yöntemler kullanılarak hedef tespit performansları incelenmiştir. Cisimlerin gün içerisindeki ısınma ve soğuma profillerinden yola çıkılarak önerilen bu yöntemle birlikte, bir gün boyunca gözlemlenmiş bir hedeften çıkarılan sıcaklık profili kullanılarak ileri bir tarihteki bir günden elde edilen sıcaklık profilleri arasından hedef tespit edilebilmiştir.

Tezde yapılan bir diğer çalışmada LWIR HSG'lerdeki atmosferik etkileri temizleyebilmek ve radyans verisinden salıcılık (emissivity) verisini elde edebilmek için sahne içi atmosferik düzeltme (ISAC) [27] yöntemi kullanılmıştır. Bu çalışma aracılığı ile sahnedeki cisimlerin salıcılıkları aracılığı ile tespit edilebilirlikleri incelenmiştir.

Son olarak HSG'lerin yüksek spektral çözünürlüğe sahip olmalarına karşın bazı bantların öneminin düşük olabileceği düşünülmektedir. Bu sebeple bu çalışmada, hedef yeniden tespiti için en önemli bantlar belirlenmiş ve bu bantlar üzerinde hedefin yeniden saptanması gerçekleştirilmiştir. Bant seçimi yapılırken, cismin yaptığı ışıma ile bu ışımaya en yakın siyah cisim ışıması arasındaki sapmalardan yola çıkılarak cisimlerin özneliliklerinin daha ayırt edici olduğu dalga boyu aralıkları bulunmuştur. Ayrıca boyut azaltma yöntemleri de kullanılmış, bant seçimi teknikleri ile birlikte kıyaslanmıştır.

1.2. Tezin Akışı

Bölüm 1.1.'de LWIR hiperspektral görüntüler üzerinde hedef tespiti için geliştirilmiş yöntemlerden bahsedilmiştir.

Bölüm 2.'de SPICE veri kümesi üzerinde yapılan çalışmalardan bahsedilmiş, LWIR hiperspektral görüntüler hakkında genel bir bilgilendirme yapılmıştır. Ayrıca literatürde bu alanda yapılmış çalışmalar özetlenmiştir.

Bölüm 3.'te önerilen hedef tespit yöntemleri anlatılmıştır. Önerilen tespitler 5 ayrı başlık altında incelenmiştir. İlk olarak Bölüm 3.1.'de LWIR HSG'lerde sıcaklık-salıcılık dönüşümü (TES) yönteminden ve ilgili teorik kavramlardan bahsedilmiştir. Bölüm 3.2.'de LWIR hiperspektral görüntüler üzerinde eşleştirme yöntemleri kullanılarak yapılan hedef tespit çalışmaları verilmiştir. Bunun akabinde Bölüm 3.3.'te LWIR hiperspektral görüntüler üzerinde sıcaklık dönüşüm yöntemleri kullanılarak çıkarılan parlaklık sıcaklıklarının birleşimi ile elde edilen sıcaklık küpleri üzerinde yapılan, eşleştirme yöntemleri tabanlı hedef tespit çalışmaları anlatılmaktadır. Ek olarak yine bu bölümde, cisimlerinden yayılan ışımalar ile cisimlerin sıcaklıkları sebebiyle sahip oldukları siyah cisim ışımaları arasındaki farktan yola çıkarak hata analizi yapılmıştır. Bölüm 3.4.'te sahne transferi yöntemi uygulanarak

hedef tespitine katkı sağlanması amaçlanmıştır. Bölüm 3.5.'te ise radyans verisi üzerinde hedef tespiti yapabilmek için oluşturulan LSTM modeli anlatılmıştır. Bölüm 3.6.'da LWIR hiperspektral küpleri zamansal olarak sıralı şekilde birleştirilerek radyans küpleri elde edilmiş ve bu küpler üzerinde eşleştirme ve zaman serisi sınıflandırıcı derin öğrenme yöntemi kullanılarak hedef tespiti çalışmaları anlatılmıştır. Bölüm 3.7.'de ise karşılaştırma amaçlı olarak kullanılan derin öğrenme yöntemlerinden bahsedilmiştir.

Bölüm 4.'te deneylerin yapıldığı SPICE veri kümesi ile ilgili detaylı analizler ve bilgiler verilmektedir. Bu bölümde, SPICE veri kümesi oluşturulurken kullanılan hiperspektral kamera ve özelliklerinden, sahnede bulunan materyallerden, görüntülerin alındığı bölgenin hava koşullarının algılanabilmesi için kullanılan meteorolojik ölçümlerden bahsedilmiştir. Ayrıca veri kümesi elde edilirken karşılaşılan zorluklara da değinilmiştir.

Bölüm 5.'te ise Bölüm 3.'te önerilen hedef tespit yöntemlerinin veri kümesinde uygulanma şekli ve elde edilen sonuçlar gösterilmiştir. Bölüm 5.1.'de tezdeki deneylerin akışı verilmektedir. Bölüm 5.2.'de ise yapılan deneylerde kullanılan değerlendirme metrikleri anlatılmaktadır. Bölüm 5.3.'de hedefler üzerinden referans imzanın alınacağı noktaların belirlenmesi için çalışmalar yapılmıştır. İmza tabanlı eşleştirme yöntemleri aracılığıyla Bölüm 5.4.'te LWIR HSG'lerde radyans verileri üzerinde sıcaklık-salıcılık dönüşümünü uygulanarak elde edilen salıcılık (emissivity) verisi üzerinde, Bölüm 5.5.'te radyans verileri üzerinde, Bölüm 5.6.'da sıcaklık profilleri üzerinde, Bölüm 5.9.'da ise zamansal LWIR HSG'ler üzerinde hedef tespiti gerçekleştirilmiştir. Bölüm 5.7.'de Bölüm 3.4.'te anlatılan görüntüden görüntüye transfer yöntemi kullanılarak, olumsuz hava koşullarındaki test görüntüleri daha olumlu koşullara transfer edilmiş ve üzerinde Bölüm 3.7.1.'de anlatılan yöntem kullanılarak hedef tespiti gerçekleştirilmiştir. LSTM derin öğrenme yöntemi kullanılarak Bölüm 5.8.'de radyans verisi üzerinde, Bölüm 5.10.'da ise zamansal LWIR HSG verisi üzerinde hedef tespit çalışmaları yapılmıştır. Bölüm 5.11.'de karşılaştırma amaçlı olarak kullanılan Bölüm 3.7.'de anlatılan derin öğrenme yöntemleri ile hedef tespiti gerçekleştirilmiş ve performansları incelenmiştir.

Ayrıca Bölüm 2.4.'te anlatılan yöntemler kullanılarak HSG'lerde boyut düşürmenin etkisi

Bölüm 5.12.'de test edilmiş ve yöntemler karşılaştırılmıştır. Bu yöntemler neticesinde, SPICE veri kümesindeki tank hedeflerinin tespitinde önemli olabilecek bant aralıkları belirlenmiştir.

Son olarak da Bölüm 6.'da LWIR görüntülerde hedef tespiti için yapılmış bütün deney sonuçları neticesinde elde edilen çıkarımlar sunulmuştur.

2. LİTERATÜRDEKİ ÇALIŞMALAR VE İLGİLİ TEORİK KAVRAMLAR

Hiperspektral görüntüler, genellikle düşük uzamsal çözünürlüğe sahip olmalarına karşın, yüksek spektral çözünürlüğe sahip olduklarından, materyallerin spektral karakteristikleri ile ayırt edebilmemizi sağlayabilmektedir. Bu nedenle hiperspektral görüntüleme hedef tespit problemlerinde kullanılmaya elverişli bir görüntüleme çeşididir.

LWIR bölgede yayılan radyasyonu ölçen sensörler aracılığıyla, cisimlerin malzeme özellikleri, güneşlenme geçmişleri, çevreyle temasları gibi etkenlerle değişen enerjilerini gösteren görüntüler üretilir. Bu sayede LWIR bölgede yapılan görüntüleme ile gece gündüz değişim, anomali, materyal ve nesne tespiti yapılabilmektedir [2, 24, 28–33].

LWIR HSG üzerinde hedef tespiti yapabilmek için ACE, Spektral Açık Haritalayıcı (SAM), Uyum Filtresi (MF) gibi spektral imza tabanlı eşleştirme yöntemleri [23, 24, 34] kullanıldığı gibi derin öğrenme ağları [16, 17, 35, 36] da kullanılmaktadır. Bölüm 2.2.'de tezde kullanılmış eşleştirme yöntemleri, Bölüm 2.3.'te derin öğrenme tabanlı yöntemlerin teorik altyapılarına ve literatür taramasına yer verilmiştir. Bölüm 2.4.'te hiperspektral görüntülerde boyut azaltma yöntemleri, Bölüm 2.5.'te hiperspektral sahne transferi için kullanılan çekişmeli üretken ağlardan ve literatürdeki sahne üretme yöntemlerinden bahsedilmiştir.

2.1. LWIR Hiperspektral Görüntülerde Hedef Tespiti

Uzaktan algılama, belirli bir mesafeye konulmuş görüntüleme cihazları ile, nesnelerden yayılan dalga boylarına göre elektromanyetik enerjilerin tespiti ve anlamlandırılması işlemidir. Dünya içerisinde bulunan yüksek ısıya sahip magma ile oluşan iç ısı akışı, yüzeydeki materyallerin iç enerjileri sebebiyle sahip oldukları salıcılıkları (emissivity) ve en önemlisi güneşten gelen ısıyı yansıtmaıları sebebiyle cisimler termal enerji yaymaktadır. 0°K derecenin üzerindeki her cisim ısı radyasyonu yayar. Bu yayılan enerjinin miktarı, sıcaklığa ve dalga boyuna göre değişmektedir.


Görünür bölge ışınları yaklaşık olarak 400 nm - 700 nm aralığında yayılmakta iken, Tablo 2.1’de görüldüğü gibi kızılötesi ışınlar bu dalga boyundan daha yukarıda başlamaktadır. Kızılötesi bölge ilk olarak Görünür Yakın Kızılötesi (VNIR) ve Yakın Kızılötesi (NIR) bandı ile başlamaktadır. Bu iki benzer karakterdeki bant 400 nm-700 nm ve 700 nm-1000 nm aralığında olmakta olup görünür bölgeye en yakın kızılötesi bölgede bulunmaktadır. Bu bölgede ışıklar görünür bölgeye göre daha az yansımaktadır. Bu bant genellikle multispektral görüntülerde, görünür bölge kanallarıyla birlikte kullanılır ve bitkilerin sağlık durumlarını kontrol eden çalışmalarda fayda sağlamaktadır [37].

Tablo 2.1 Elektromanyetik Spektrumlar ve Dalga Boyları

Elektromanyetik Spektrumlar ve Dalga Boyları	
Bant Adı	Dalga Boyu (μm)
Görünür Bölge	0.4 - 0.7
NIR	0.7 - 1
SWIR	1 - 2.5
MWIR	3 - 5
LWIR	7.5 - 14


Kesin olarak belirlenmiş veya fiziksel olarak tanımlı termal kızılötesi bölge bulunmamaktadır. Sabins’e [1] göre cisimlerin termal karakteristikleri 3 μm ve 14 μm aralığında gözlemlenebilmektedir. Şekil 2.1’de görüldüğü üzere atmosfer etkisi ile bazı

dalga boyu aralıklarında iletkenlik (transmittance) çok düşmekte ve bu bant aralıklarında görüntüleme güçlükle yapılabilmektedir.




Şekil 2.1 Atmosferik emilim [1]

3 μm - 5 μm aralığı MWIR ve 8 μm - 14 μm LWIR aralıkları atmosfer soğurması az olduğu için görüntülemeye elverişli iken, 5 μm - 8 μm aralığı atmosferik emilim çok yüksek olduğu için termal görüntülemeye elverişsizdir. Bu çalışmada kullanılan SPICE veri kümesi 7.408 μm - 12.449 μm dalga boyu aralıklarından görüntüleme yapmaktadır. Yaptığımız çalışmalarda bazı LWIR bölgesi içerisinde bulunan dalga boylarında karışıklık (clutter) seviyesinin yüksek olduğu gözlenmiştir. Bu karışıklığa görüntüleme cihazından kaynaklanan gürültü, atmosferik etkenler gibi sebepler neden olabilmektedir. SPICE veri kümesinde görüntü alımına 7.48 μm dalga boyundan başlanmıştır. Şekil 2.1’de görüleceği üzere 7.48 μm ile 8.28 μm dalga boyları arasında atmosferik emilimin yüksek olduğu görülmektedir. Bu sebeple, SPICE veri kümesi yazarlarının da bahsettiği gibi bant sayısı azaltılmış ve hedef tespiti performansı üzerindeki etkisi incelenmiştir [38]. Meola’nın [38] yaptığı çalışmada ilk ve son 30 bant elenmişken bizim çalışmamızda farklı bant eleme teknikleri irdelenmiş, ayrıca 8.17 μm - 11.5 μm aralığına indirgenerek 108 bant üzerinde çalışılmıştır. Materyal spektrumları ve gözle görünür şekilde ilk ve son dalga boylarında bulunan gürültülü bölgeler Şekil 2.2’de gözlemlenebilmektedir.



Şekil 2.2 SPICE veri kümesindeki materyallerin radyans spektrumları






Şekil 2.3 Gürültülü bantlardan arındırılmış materyal spektrumları

Şekil 2.2’de gözlenen sinyal karışıklığı yüksek bantlar elenmiş ve Şekil 2.3’de görülen dalga boyu aralığındaki veriler kullanılmıştır. Gürültülü bantların elimine edilmesi amacıyla Bölüm 2.4.’de küçük bir deney tertip edilmiş ve başarımları artırılmıştır.


Salıcılık (emissivity), fiziksel olarak materyal yüzeyinden yayılan enerjinin aynı sıcaklıktaki siyah cisim ışımasına oranı olarak tanımlanmaktadır. LWIR bölgesinde cisimlerin yaymış oldukları enerji hem sahip oldukları sıcaklık hem de salıcılıkları aracılığı ile yayılan enerjinin birleşiminden oluşmaktadır. Cisimlerin salıcılığı yüzey durumları, görüntüleme açıları, sıcaklık ve dalga boyuna göre değişiklik göstermektedir [39, 40]. Ayrıca cisimlerin üzerlerine yapılan kaplamaların da salıcılıklarını değiştirdiği, metallerde daha istikrarlı salıcılığa sahip olma eğilimine eriştikleri gözlenmiştir [39].

LWIR HSG’ler üzerinde materyal sınıflandırması yapılırken uygulanan sıcaklık-salıcılık dönüşümü için bütünleşik olarak atmosferik düzeltme ve salıcılık dönüşümü uygulanan [27, 41, 42] yöntemler bulunmakta ve elde edilen salıcılık üzerinde materyal sınıflandırması yapan çalışmalara sıklıkla rastlanmaktadır [4, 43, 44]. Fakat sıcaklık-salıcılık dönüşümü, sıcaklık ve atmosferin etkileşimi sebebiyle zorludur [5]. Sıcaklık ve salıcılık kestirimi her piksel için N bant değerinden $N+1$ kadar değer (N bant sayısı kadar salıcılık ve sıcaklık) kestirilmesi gerektiğinden iğreti tanımlanmış bir problem teşkil etmektedir. Ayrıca dönüşüm yöntemleri salıcılık eğrilerinin pürüzsüz (smooth) geçişli olduğunu varsayar fakat gerçekte böyle olmaması hatalara neden olmaktadır.


Borel ve arkadaşlarının [2] SPICE veri kümesinde yaptığı çalışmada sıcaklık-salıcılık dönüşümü, Hızlı Sıcaklık-Salıcılık Dönüşümü (QTES) [45] yöntemi uygulanarak elde edilmiş ve radyans, parlaklık sıcaklığı ve salıcılık değerleri kullanılarak hedef tespit başarımları incelenmiştir. Şekil 2.4’de görüldüğü üzere hedef tespit başarısının radyans, salıcılık ve parlaklık sıcaklığı karşılaştırıldığında, en düşük salıcılık verisi üzerinde olduğu görülmüş, sebebinin de tankların salıcılıklarının arka plan materyalleri ile benzeşmesi olarak yorumlanmıştır.

Data unit: N_t	2	5	10
RIAD applied to radiance (measured in microflicks)			
RIAD applied to emissivity			
RIAD applied to brightness temperature (measured in °C)			

Şekil 2.4 2, 5, 10 piksel bloğu boyutlarında (N_t) RIAD (Range-Invariant Anomaly Detector) yönteminin radyans, salıcılık ve parlaklık sıcaklığı verileri üzerindeki performansı [2]



Şekil 2.5 ISAC yöntemiyle elde edilmiş materyal salıcılıkları (01.05.2013-11:48) [3]




Şekil 2.6 Sol üst: Radyans Görüntüsü. Sağ Üst: Parlaklık Sıcaklığı. Sol alt: Bağıl Salıcılık. Sağ Alt: Normalleştirilmiş Bağıl (Relative) Salıcılık [4]

SPICE veri kümesi üzerinde yapılmış bir diğer sıcaklık-salıcılık temelli çalışmada [3] Sahne İçi Atmosferik Düzeltme (In-scene atmospheric compensation, ISAC), QTES, Alpha Salıcılık-Sıcaklık Dönüşümü (Alpha TES) ve ENVI uygulaması tabanlı yöntemler ile sıcaklık-salıcılık dönüşümleri uygulanmış ve doğası incelenmiştir. Şekil 2.5'te 4 farklı sınıfın salıcılık grafikleri gösterilmekte ve farklı materyallerin salıcılıkları arasında belirgin bir fark göze çarpmamaktadır. Şekil 2.6'da sol üst köşede ilk ve son 30 dalga boyunun elenmesi ile elde edilen HSG'nin radyans ortalaması görüntüsü, sağ üst köşede 10.102 μm dalga boyu kullanılarak hesaplanmış parlaklık sıcaklığı haritası, sol altta HSG'den sıcaklık-salıcılık dönüşümü ile elde edilen salıcılık değerlerinin ortalama görüntüsü ve sağ altta da bağıl salıcılığın histogram ile normalizasyon yöntemi kullanılarak normalize edilmiş hali gösterilmektedir. Şekil 2.5 ve Şekil 2.6'den görüleceği üzere materyallerin salıcılık spektrumlarında büyük farklılıklar gözükmemektedir. Ayrıca [3] çalışmasında tank hedefinin 24 saatlik salıcılık grafiğine bakıldığında tutarlı bir dönüşüm yapılamadığı görülmüştür. SPICE veri kümesinde radyans verisinden farklı yöntemler kullanılarak elde edilen salıcılığın materyaller arasında ayırım için kabul edilecek spektral farklılıklara sahip olmadığına ve farklı zaman aralıklarında bir cismin salıcılığının açıklanamayacak düzeyde değişkenlik göstermesi materyal ayırt ediminde yetersiz olduğu kanısına ulaştırmıştır [3].

Benzer şekilde bir diğer çalışmada [32] LWIR HSG'lerde sıcaklık-salıcılık dönüşümü (TES) uygulanmış ve hem radyans hem de farklı yöntemlerle elde edilmiş salıcılık verileri üzerinde mineral sınıflandırması yapılmıştır. Çalışma neticesinde atmosferik düzeltmeye gerek kalmadan radyans verileri ile gece ve gündüz spektral öznitelikler karşılaştırılarak minerallerin daha iyi ayrıştırılabildiği gözlenmiştir.


R. H. Fowler'ın [46] ortaya koymuş olduğu gibi termodinamiğin üç temel yasası bulunmaktadır. Birinci yasa temel denge yasasıdır. Eğer iki sistem kendi aralarında ısı dengede ise, bu sistemden biriyle ısı dengede olan bir dış sistem diğer sistem ile de ısı dengededir. İkinci yasa enerjinin korunumu yasasıdır. Üçüncü yasa ısı transferinin yüksek sıcaklıktan düşük sıcaklığa olduğundan bahseder. Burada ısı transfer yasaları devreye girmektedir. Cisimlerin sıcaklık farklılıklarından dolayı yaptıkları enerji transfer olayına ısı transferi denir.



Şekil 2.7 Temel ısı transferi yöntemleri [5]

Cisimler arasında ısı transferi yöntemlerinden bazıları şunlardır:

- **Temas (Conduction)** : Birbirine temas halinde olan cisimler arasında moleküler düzeyde ısı aktarımı şeklinde gerçekleşir.
- **Konveksiyon (Convection)**: Sıcaklık merkezinden akıp giden hava veya sıvı beraberinde ısı enerjisini de taşır.
- **Radyasyon (Radiation)**: 0°K 'in üzerindeki her cisim ısı radyasyonu yayar. Bu yayılan enerjinin büyüklüğü, sıcaklığa ve dalga boyuna bağlıdır. 0°K 'in üzerindeki her cisim ısı radyasyonu yaymaktadır. Bu yayılan enerjinin miktarı sıcaklığına ve dalga boyuna bağlıdır. Bunu Şekil 2.8 Plank eğrisinden görebilmekteyiz.



Şekil 2.8 Elektromanyetik spektrum üzerinde Planck [6] ve Wien [7] eğrileri [1, 8]

Siyah cisim ışıması, sabit sıcaklıktaki bir nesnenin bileşiminden ve şeklinden bağımsız olarak sadece sahip olduğu sıcaklık aracılığı ile yaptığı ışımaya denir. Bu ışıma farklı dalga boylarında farklı şiddetlerde gerçekleşmektedir. Planck [6] yasası, siyah cisim ışımasını tanımlayan temel bir kavramdır. Bu yasa siyah cisim ışımasının, radyasyonun frekansı ve yayan nesnenin sıcaklığı ile orantılı olduğunu belirtmektedir. Cismin sıcaklığı arttıkça, her dalga boyunda yaptığı ışmanın şiddeti artacağı belirtilmektedir. Denklem 1’de gösterilen Planck eşitliğinde $B(\lambda, T)$ siyah cisim ışımasını, λ dalga boyunu, T Kelvin cinsinden sıcaklığı, h Planck sabitini, c ışık hızını ve k_B Boltzmann sabitini ifade etmektedir.

$$B(\lambda, T) = \frac{2hc^2}{\lambda^5} \frac{1}{e^{\left(\frac{hc}{\lambda k_B T}\right)} - 1} \quad (1)$$

Siyah cisim ışıması için Planck denkleminde başka yaklaşımlar da bulunmaktadır. Wien’in yer değiştirme yasası olarak da bilinen Wien yasası [7], siyah cisim radyasyonunun maksimum olduğu dalga boyu ile siyah cismin sıcaklığı arasındaki ilişkiyi tanımlamaktadır.

Bir siyah cismin sıcaklığı arttıkça, radyasyon spektrumunun tepe noktasının daha kısa dalga boylarına doğru kaydığı ve radyasyon yoğunluğunun tüm dalga boylarında arttığı anlamına gelmektedir ve Denklem 2’de ifade edilmektedir. Eşitliğin sağında kalan 0.2898 değerine Wien sabiti denilmektedir. Ayrıca Wien, $e^{\frac{hc}{\lambda k_B T}} \gg 1$ varsayımından yola çıkarak siyah cisim ışımasını Denklem 3’deki gibi sadeleştirmiştir.

$$\lambda_{max} \times T = 0.2898 cmK \quad (2)$$

$$B(\lambda, T) = \frac{2hc^2}{\lambda^5} e^{-\left(\frac{hc}{\lambda k_B T}\right)} \quad (3)$$


Şekil 2.8’de görülen siyah cisim ışıması grafiğinde görüldüğü üzere 0 °K derece üzerindeki her cisim termal radyasyon yaymaktadır. Burada mavi ile işaretlenmiş alan görünür ışık bölgesini ifade etmektedir. Aynı zamanda taranarak gösterilmiş alan da termal bölgeyi ifade etmektedir. Kahverengi işaretli alan Planck denklemlerini, yeşil çizgi ise Wien kuralını temsil etmektedir. Dünya ortam sıcaklığında 300°K (26.85°C) sıcaklığında yayılan en yüksek radyasyon yaklaşık 10 µm dalga boyunda çevresindedir. Bu sebeptendir ki çoğu tek kanallı LWIR sensör bu bantta yayılan radyasyonu algılayabilecek şekilde üretilmektedir.

Siyah cisim ideal koşullardaki durumları ifade etmekle birlikte mükemmel siyah cisime erişim her zaman mümkün olmamaktadır. Gri cisim ışıması, mükemmel bir siyah cisim olmayan, ancak yine de siyah cisme benzer bir şekilde radyasyon yayan bir nesne tarafından yayılan bir tür termal radyasyondur. Üzerine gelen tüm radyasyonu emen ve gelen radyasyondan bağımsız bir şekilde radyasyon yayan bir siyah cismin aksine, gri cisim gelen radyasyonun bir kısmını emmekte ve emilen radyasyonla orantılı radyasyon yaymaktadır. SPICE sahnesinde bulunan nesneler arasında siyah cisim olarak belirtilen nesne mükemmel bir siyah cisim olmamakla birlikte üzeri siyah bir tuvalle kaplanmış siyah cisimdir. İdeal bir siyah cismin salıcılık (emissivity) değerinin 1 olması beklenirken yapılan çalışmalarda bu cismin salıcılığının 1 olmadığı ve değişken olduğu gözlenmektedir. Fakat siyah cisme


yakın bir şekilde sahnede bulunan tanklar ile birlikte en çok ısınan ve soğuyan nesne konumundadır.

SPICE veri kümesinde görüntü alınan sahnede ince bir alüminyum plaka bulunmaktadır. Bu nesne sahneye mükemmel yansıtıcı bulundurmak adına yerleştirilmiştir. Fakat bu cismin sıcaklığının gün içerisinde değişebildiği gözlenmektedir. Bu cismin sıcaklığının değişkenlik göstermesinin sebebinin sensör gürültüsü, atmosferik yol radyansı ve hava sıcaklığı değişimi olduğu düşünülmektedir. Hava sıcaklığı -2°C 'den 21°C 'ye yükseldiğinde alüminyum plakanın sıcaklığında da bir miktar değişim gözlemlenmektedir. Ayrıca yapılan çalışmalarda [2] alüminyum plakanın yaydığı ışınımın, MODTRAN [47] modeli ile modellendiğinde atmosferik düşen radyansa (atmospheric downwelling radiance) çok yakın olduğu gözlemlenmiş ve bu sebeple alüminyum plakanın mükemmel yakın bir yansıtıcı olduğu çıkarımına varılmıştır.

SPICE veri kümesindeki araçların spektral imzalarında hava durumlarına göre farklılıklar oluşmaktadır. Bu farklılıkları yukarıda değindiğimiz ısı transferi yöntemleri bazında incelediğimizde radyasyon, temas ve konveksiyon yoluyla ısı transfer yöntemlerine örnekler görülmektedir. **Temas**, metal cisimlerde, **konveksiyon**, rüzgarlı hava koşullarında, **radyasyon** ise güneşli havada koşullarında etkili olmaktadır. Hedef cisimler metal olmakla birlikte toprakla temas eden alt bölgelerinde farklı ısınma ve soğuma davranışı gözlenmektedir. Rüzgarlı günlerde de değişkenlik gösteren spektral imza bulunmakla birlikte gün içerisinde en çok etki eden etken güneşlenmedir.




Şekil 2.9 Hedef 1 üzerinde seçilmiş noktalar



Şekil 2.10 Hedef 1 üzerinden seçilmiş noktaların spektrumları

Bahsedilen ısı transfer yöntemleri arasında radyasyon cisimlerin ısınmasında en etkili olanıdır. Şekil 2.10 ve Şekil 2.9'da hedef sahnesinde bulunan hedef araçlarından alınan radyasyon spektral imzaları verilmiştir. Cisim üzerinden farklı noktalardan alınan imzaların farklı olduğu görülmüş, bunların da sebebinin güneşlenme olduğu kanısına varılmıştır. Bu sebeple tez içerisinde hedeflerden referans imza alırken, imzalar güneşlenmeye daha müsait olan tavan bölgesinden seçilmiştir.



Şekil 2.11 Materyallerin gün içerisindeki sıcaklık değişimleri

Şekil 2.11'de cisimlerin gün içerisindeki sıcaklık değişimleri gösterilmektedir. Sahnenin termal doğasını doğrular şekilde SPICE test sahnesindeki kum, çayır, orman sınıflarının gün içerisindeki enerji değişimleri görülmektedir. Şekil 2.11 de görüldüğü gibi cisimlerin gün içerisindeki sıcaklık marjınları materyal özelliklerine göre farklılık göstermekte, gün içerisinde toprak, orman ve çayıra göre daha geniş aralıklarda hareket etmektedir. Keza cisimlerin öz ısılarından dolayı elde ettikleri sıcaklıklar ve bu sıcaklıklara erişim hızlarının farklı olduğu, toprağın metalden daha yavaş ısınıp soğuduğu görülmüştür.

Cisimlerin genel olarak sahip oldukları termodinamik özellikler arasında şunlar gösterilebilir:

- **Termal İletkenlik:** Sıcaklık değişimine bağlı olarak belirli bir yüzeyin içine dik olarak ısı transfer etme kapasitesidir. Termal iletkenlik arttıkça cisim ısıyı daha hızlı iletdebilmektedir.


- **Isı kapasitesi:** Bir derece sıcaklık artışına bağlı olarak meydana gelen ısı artış miktarıdır.
- **Termal Eylemsizlik:** Isıtma ve soğutmada cismin sıcaklık değişimine gösterdiği direnci ifade eder. Isı değişimlerinde sıcaklık değişimleri minimum olur.

Metallerin termal eylemsizlikleri düşük olduğu için gün içerisindeki ısı değişimleri daha hızlı olabilmekte bu da çevrelerine göre daha hızlı ısınıp soğuyabilmelerine yol açmaktadır. Tezde önerilen hedef tespit yöntemlerinden birinde metallerin bu doğasından kaynaklı imza farklılığından faydalanılmıştır.


2.1.1. SPICE Veri Kümesinde Hedef Yeniden Tespit Çalışmaları

Romano ve arkadaşları [48] SPICE veri kümesi içerisindeki insan yapımı nesneleri tespit edebilmek amacıyla iki değişkenli tespit yöntemi önermişlerdir. Cisimler için insan yapımı ve insan yapımı değil kararının Bayes karar kuralı ile verildiği bu yöntemde günlük bazda yapılan testlerde cisimlerin farklı açılarda bulunmalarının ve aydınlanmanın gün içerisindeki değişiminin tespiti olumsuz etki etmediği gözlenmiştir. Çalışmada SPICE veri kümesinin ilk toplandığı 2010 senesi verileri kullanılmakta olup bu veriler tezimizde kullanılmamıştır. Ayrıca farklı bir yaklaşım olarak bir diğer çalışmalarında morfoloji uygulayarak anomali tespiti yöntemi önermişlerdir [49].

SPICE veri kümesi üzerindeki bir diğer çalışmada Rosario ve arkadaşları [2, 29, 45] çalışmalarının ilk aşamasında ham verinin işleme ve kalibrasyon sürecini ve radyans verilerinden sıcaklık-salıcılık dönüşümü (TES) sürecinin nasıl yapıldığından bahsedilmiş, ikinci kısmında ise elde edilen parlaklık sıcaklığı, radyans ve salıcılık verileri üzerinde Reed-Xiaoli tabanlı anomali tespit yöntemi ve sonuçlarını paylaşmışlardır. Yaptıkları çalışmaların sonucunda, hedef yeniden tespit performanslarının yüksekte düşüğe sırasıyla parlaklık sıcaklığı, radyans ve salıcılık verileri üzerinde elde edildiği görülmüştür. Salıcılık verilerinde tespit performansının düşük olmasının sebebinin tankın salıcılığının arka plan



Şekil 2.12 Tank0 hedefinin QTES yöntemi aracılığı ile hesaplanan salıcılıklarının günlük değişimi [3]



Şekil 2.13 Tank0 hedefinin QTES yöntemi aracılığı ile hesaplanan salıcılıklarının günlük değişimi [3]

piksellerle benzeşmesi olduğu düşünülmektedir. Şekil 2.4'den de görüleceği gibi salıcılığın hedef tespitinde salıcılığın kullanımı hatalı tespit miktarını arttırmaktadır.

Nirmalan ve arkadaşları [4] Mayıs ayının ardışık iki gününü içerecek bir şekilde ACE [34], MF[34] ve SAM[34] tespit yöntemlerinin performansını incelemişler ve MF ile en

iyi sonuçları aldıklarını gözlemlemişlerdir. Yapılan bu çalışmada SPICE veri kümesi üzerinde gürültü analizi yapılmış ve sahne üzerinden hesaplanan gürültü ile kamera üreticisinin sağladığı gürültü analizlerinin uyuştuğunu gözlenmiştir. Ayrıca aynı çalışmada farklı sıcaklık-salıcılık dönüşüm yöntemleri radyans verilerine uygulanmış, elde edilen salıcılık verileri üzerinden hedef tespit çalışmaları gerçekleştirilmiştir. 1 Mayıs 2013, Saat 11:58'de alınan HSG'ye QTES sıcaklık-salıcılık dönüşümü uygulanmış ve 4 farklı materyalin salıcılıkları Şekil 2.12'de gösterilmiştir. Ayrıca belirlenen bir hedefin bir günlük salıcılık grafiği Şekil 2.13'te gösterilmektedir. Şekil 2.13'te hedefin salıcılık spektrumunun gün içerisinde geniş bir aralıkta değiştiği görülmektedir. Çalışmada [3] hedef materyalin salıcılık spektrumunun değişken ve geniş bir aralıkta tahmin edilmesinden dolayı salıcılık tahminlerinin kesin olmadığı belirtilmektedir.

Belenoğlu ve arkadaşlarının çalışmasında [50] ise cisimlerin günlük sıcaklık profillerinden faydalanılarak bir tespit yöntemi önerilmiştir. Mayıs tarihinden alınmış HSG'lerden gün içerisindeki parlaklık sıcaklıkları kestirilerek belirli saat aralıkları ile birleştirilmeleri ile sıcaklık küpleri elde edilmiş ve bu sıcaklık profilleri üzerinde eşleştirme yöntemleri ile hedef yeniden tespiti gerçekleştirilmiştir. Bu yöntemin umut vadeci olduğu görülmektedir.

HSG'ler üzerindeki gereksiz bantlardan kurtulmak için boyut azaltma yöntemleri kullanılmakta ve performansta dramatik bir düşme yaşanmaktadır. Fakat SPICE veri kümesine PCA uygulanması neticesinde yanlış alarmin arttığı görülmektedir [38]. Aynı çalışmada ACE'nin atmosferik değişimlere göre daha güvenilir sonuçlar verdiği görülmüştür. PCA yoluyla boyut azaltmanın, arka plan dağılımının ortalamasını ve varyansını artırarak tespit performansını potansiyel olarak azaltabildiği analiz edilmiştir. Bu durumda bile sensörden kaynaklanan gürültünün PCA ile bant azaltma sayesinde engellenebileceği öngörülmektedir. Çalışmamızda PCA ile birlikte farklı bant azaltma yöntemleri incelenmiş ve bant azaltmanın performansa etkisinin olumlu olabildiği gözlemlenmiştir.

Geçtiğimiz yıllarda derin öğrenme yöntemlerinin sınıflandırma uygulamalarının başarımını artırması, araştırmacıların SPICE sahnesi için de derin öğrenme kullanmasını teşvik etmiştir

[30, 31]. Rauss'un yaptığı çalışmada Derin İnanç Ağları (DBF) [30] SPICE kümesinde Mayıs ayının ilk gün verileri ile eğitilip performansı incelenmiştir.

LWIR HSG'lerin diğer görüntülemelerden en önemli farkı, değişen hava koşullarında yeniden tespit performanslarının dramatik olarak düşmesidir. Patrick ve arkadaşlarının çalışmasında [31] bu duruma Çok-Alanlı Savaş (Multi Domain Battle - MDB) denilmiş ve farklı hava koşullarında toplanmış SPICE veri kümesinde İstiflenmiş Öz-kodlayıcı (SAE) eğitilerek model performansı incelenmiştir. Çalışmada dikkat çekilen noktalardan biri 9.5 µm çevresinde bir öznetelik olduğu ve bunun ozon varlığından kaynaklanmış olabileceğidir.

2.2. İmza Tabanlı Eşleştirme Algoritmaları

İmza tabanlı eşleştirme algoritmaları, referans HSG'deki hedef pikselin spektral imzası kullanılarak, bir başka HSG'de hedefin aranmasına dayanmaktadır. Bu modeller arka-plan dağılımını modelleyerek hedefleri arka-plandan olasılıksal olarak ayırt etmeye çalışır. HSG sınıflandırma imza tabanlı eşleştirme yöntemleri karşılaştırma çalışmasında ve tezimize benzer çalışmalarda ACE [34]'nin en iyi sonucu verdiği görülmüştür [24, 37, 51, 52]. Bu sebeple tezdeki çalışmalarımızda ACE eşleştirme yöntemi kullanılacaktır. Ayrıca parlaklık sıcaklığı üzerinden hedef tespit çalışmalarında Uyum Filtresi (Matched Filter) kullanılmaktadır. ACE algoritmasında arka plan ve hedef pikselleri farklı ağırlıklandırılmış kovaryans matrisleri ile modellenir. Bu yöntem arka plan gürültüsü modeli oluşturur ve bu modelin ağırlıklarını kestirir. Hedef spektral imza vektörü test sahnesi üzerinde her piksel spektral vektörü ile karşılaştırılarak pikselin hedef olma ihtimali hesaplanmaktadır. Bu ihtimal belirlenen bir eşik değerinden yüksek ise burada hedef cisim var, düşükse hedef cisim yok değerlendirmesi yapılmaktadır.

2.3. Hiperspektral Görüntülerde Derin Öğrenme Tabanlı Hedef Tespit Yöntemleri

Hiperspektral görüntüleme, elektromanyetik spektrumun görünür bölgesinden, LWIR bölgelerine kadar farklı dalga boylarından elde edildiği, hem uzamsal hem de spektral

bilgiler içeren bir görüntüleme çeşididir. LWIR HSG’lerde her pikseli ifade eden spektral bilgi, o pikselin termal karakteristik özelliğini de taşıması sebebiyle cisimlerin sahip olduğu materyallere özgü spektral imzalardan faydalanan pek çok sınıflandırma yöntemi bulunmaktadır [52].

Hiperspektral görüntüler içerdikleri yüksek bilgi içeriğiyle birlikte beraberinde bazı zorluklar da getirmektedirler [8, 53]. Bunlardan bazıları veri sayısındaki azlık, sınıflandırıcıların genel bilgiler öğrenme zorluğu ve veri boyutu sebebiyle eğitim zorluklarıdır. Ayrıca LWIR hiperspektral görüntülerde yaşanan bir diğer problem cisimlerin atmosferik ve çevre koşullarından etkilenmeleri sebebiyle sahip oldukları spektral imzalardaki sınıf içi değişkenliklerdir.

Geçtiğimiz yıllar içerisinde hiperspektral görüntüler üzerinde derin öğrenme yöntemleri kullanılarak sınıflandırma yapabilen birçok model geliştirilmiştir [53, 54]. Derin öğrenme yöntemleri girdi verileri ile ilgili hiçbir istatistiksel bilgiye sahip olmadan bu verilerin davranışlarını öğrenip özniteliklerini çıkarabilmektedirler. Bu yöntemler, HSG’ler üzerinde spektral bilgi, uzamsal bilgi veya her ikisini de bir arada kullanarak her pikselin ait olduğu sınıfı olasılıksal olarak tahmin etmeye çalışmaktadırlar. Bu çalışmaları üç aşamada inceleyebiliriz;


- (i) Sadece spektral bilgi kullanan derin öğrenme yöntemleri
- (ii) Sadece uzamsal bilgi kullanan derin öğrenme yöntemleri
- (iii) Spektral ve uzamsal bilgi kullanan derin öğrenme yöntemleri

2.3.1. Sadece Spektral Bilgi Kullanan Derin Öğrenme Yöntemleri

Sınıflandırma problemlerinde en çok kullanılan spektral bilgi, cisme ait pikselin bant uzunluğunca spektral vektör ile ifade edilmesi ile elde edilir. Genellikle boyut azaltma yöntemleri ile boyut azaltılarak gereksiz bantlardan kurtulunarak çalışılmaktadır [16, 17, 55–

57]. Fakat bu yöntemler, sınıf içi spektral değişkenliğin yoğun olduğu sahnelerde performans düşmesine sebep olabilmektedir [3].

Çok katmanlı yapay sinir ağları [58], destek vektör makinesi (SVM) [59] ve lojistik regresyon (LR) [60] tabanlı modellerle piksel spektrumları ile eşleştirmeler yapılmıştır. HSG sınıflandırma probleminde kullanılan en bilindik yöntemlerden biri de SAE [9] çalışmasıdır. SAE, Şekil 2.14'te görüleceği üzere, arka arkaya eklenmiş öz-kodlayıcı (autoencoder) katmanları ve LR sınıflandırıcı katmanı kullanılarak her pikselin spektral vektörü üzerinde sınıflandırma yapmaktadır.



Şekil 2.14 İstiflenmiş Otokodlayıcı (SAE) modeli mimarisi [9]

Bu çalışmalara benzer olarak spektral bilgiyi kullanan 1D-CNN [61] yapısıyla da sınıflandırma yapılmıştır. Aynı çalışmada piksel vektörü iki boyutlu hale getirilip 2D-CNN katmanı havuzlama katmanı ve sınıflandırıcı katman ile birlikte oluşturulan mimari ile de sınıflandırma yapılmıştır.

2.3.2. Sadece Uzamsal Bilgi Kullanan Derin Öğrenme Yöntemleri

Bölüm 2.3.1.'de anlatılan modellerin sadece spektral bilgiyi kullanıp çevre piksel bilgilerini göz ardı etmeleri, sınıflandırma başarımlarının da düşük kalmasına sebep olmuştur [62]. Bu kısımdaki modellerde spektral bilgi ile ilgilenilmemiş, çevre piksellerin bilgilerinden kernel veya çerçeve tabanlı filtrelemeler kullanarak faydalanılmıştır.

SICNN [63] ve HRCNN [64] çalışmalarında uzamsal bilgi ile, CNN'ler aracılığıyla sınıflandırma yapılmıştır. Bazı çalışmalarda [65–67] PCA yöntemi ile bulunan temel bileşenlerden biri veya birkaçı kullanılarak oluşturulan azaltılmış boyutlu veriler 2D-CNN yapısına girdi olarak verilerek pikseller sınıflandırılmıştır.

2.3.3. Spektral-Uzamsal Bilgi Kullanan Derin Öğrenme Yöntemleri

HSG'nin doğası düşünüldüğünde uzamsal ve spektral bilginin cisimler arasında ayırt edici öznitelikler içerdiği görülmektedir. Bu sebeple uzamsal ve spektral bilgiyi birlikte kullanan çalışmalar yakın zamanda popülerlik kazanmış ve sınıflandırma başarımını arttırdığını göstermişlerdir [35, 68–70]. Hiperspektral küplerin hem uzamsal hem de spektral bilgilerinden üç boyutlu evrişim yapılarak [9, 71] ya da farklı bantlardaki uzamsal bilgiler ardı sıra birleştirilerek [67] faydalanılmaktadır.

Hamida ve arkadaşları [14]'nın kurduğu 3-boyutlu derin öğrenme mimarisinde her piksel, çevrelerinde bulunan piksellerle birlikte grup olarak ele alınmış, parça küpler öncelikle 3-boyutlu filtrelerden geçirilerek tek boyutlu vektörler elde edilmiş ve bu vektörler üzerinde 1-boyutlu filtreler aracılığı ile son tahminler elde edilmiştir. Mimarinin temel amacı komşu piksellerin birbirleri ile olan ilişkilerini de açığa çıkarılacak şekilde hem uzamsal hem de spektral bilgi kullanılarak tahmin yapabilmektir. He ve arkadaşlarının yaptığı çalışmada [15] ise farklı boyuttaki uzamsal filtreler kullanarak hem uzamsal hem de spektral bilgileri öznitelikleri bir arada çıkarılmış ve başarılı sonuçlar elde edilmiştir.

MugNet [36], uzamsal ve spektral bilgilerin ayrı dallarda işlenerek birleştirilmesi temeline dayanmaktadır. Aynı zamanda hiperspektral verilerdeki işaretsiz veri varlığının yarattığı sıkıntıları bertaraf etmek için yarı-denetimli eğitim ile etiketsiz verilerden de faydalanılarak sınıflandırma başarımının artırılmasını sağlamıştır.

HybridSN [17] çalışmasında 3D-CNN yapısı kullanılarak uzamsal ve spektral özniteliklerin çıkarılırken, ardına eklenen 2D-CNN ile daha soyut uzamsal bilgilerin ortaya çıkartılması

amaçlanmıştır. Bu çalışmada da işlem yükü azaltılması amacıyla PCA uygulanarak boyut düşürülmüştür.

SpectralNET [16] çalışmasında 3D CNN kullanılarak HSG sınıflandırmanın işlem yükü açısından ağır olduğu ve ayrıca 3D-2D CNN yapısının performans olarak verimli olmadığı belirtilmiştir. Bu sebeple wavelet dönüşümlerini aldıkları spektral kanalları 2D-CNN yapılarına besleyerek çok boyutlu spektral veriden faydalanıp 3D-CNN kadar işlem yükü bulunmayan dalgacık (wavelet) dönüşümü uygulayarak daha verimli bir başarı yakalamışlardır.

Bi-CLSTM [70] çalışmasında uzun kısa-süreli hafıza yapay sinir ağlar kullanılmış, hiperspektral küpten çıkarılan parçalar spektral boyutta ayrılarak modeli sırasıyla besleyip eğitimler yapılmış ve piksel tabanlı sınıflandırma elde edilmiştir. Tezde bu yapıya benzer bir yapı sınıflandırma için önerilmiş, parça boyutu 1 piksel olacak şekilde hareket edilmiştir.

Yerelleştirilmiş grafik evrişimli ağ (GNN) yapısını HSG sınıflandırma çalışmalarına adapte eden çalışmada [72] umut vadeci sonuçlar elde edilmiştir. Bu çalışmada PCA denetimsiz öznetelik azaltıcı kullanılarak boyut düşürülmüş ve GNN arayıcılığı ile denetimli öğrenim gerçekleştirilmiştir.

Transformer (dönüştürücü) yapıları yakın zamanda görüntü alanında da sıklıkça kullanılmaya başlanmış ve CNN'lere göre daha üstün performans verdiği gözlenmiştir [73]. Girard ve arkadaşlarının çalışmasında [74] transformer yapısı HSG sınıflandırma problemine uygulanmış ve umut verici sonuçlar elde edilmiştir.

LWIR HSG'ler aynı zamanda gaz tespitinde de sıklıkça kullanılmaktadır. Bu alanda yapılan çalışmalardan, Özdemir ve Koz [75] 3D-CNN ve otokodlayıcı yapısı kullanarak her pikselin bileşenlerini ortaya çıkarmış, sonrasında bu bileşen tahminleri üzerinde çok katmanlı yapay sinir ağı eğiterek gaz sınıflandırması işlemi gerçekleştirmişlerdir.

2.3.4. Çekişmeli Üretici Ağlar Kullanan Derin Öğrenme Yöntemleri

Çekişmeli Üretici Ağlar (GAN) [26] iki adet çok katmanlı yapay sinir ağını üretici ve ayırt edici rollerde birbirlerine karşı eğiterek gürültüden sentetik veri üretilmesini sağlayan modellerdir. Çekişmeli üretici ağlar HSG sınıflandırma probleminin veri eksikliği temel sorunlarına çözüm üretmek amacıyla sıkça kullanılmaktadır [76, 77]. Benzer şekilde sınıflandırma performansını arttırmak için geliştirilen modeller olduğu gibi [78], çekişmeli üretici ağ tabanlı sınıflandırma mimarisi oluşturulmuş çalışmalar da mevcuttur [79]. Çekişmeli üretici ağlar, gürültüden sentetik veri üretmeye yaradığı gibi görüntüden görüntüye transfer [80], yazıdan görüntü üretimi [81], yüz yaşlandırma [82] gibi onlarca alanda da kullanılmaktadır. Pix2Pix [83] GAN çalışmasında girdi olarak aldığı görüntüleri başka bir alandaki görüntülere çevirmeyi başarmıştır.

Tezde yapılan çalışmada Pix2Pix görüntüden görüntüye transfer ağı kullanılarak hiperspektral termal sahne transferi yöntemi önerilmiştir. Üretici modeller, görüntülerin doğasını çözümleyerek gerçeğe yakın görüntüler üretilmesine fayda sağlamaktadır. Tezde kullandığımız veri kümesinde bulunan görüntülerin farklı gün ve hava koşullarında elde edilmesinden dolayı hedef tespit performansı değişiklik göstermektedir. Görüntüden görüntüye transfer yöntemleri, modellemeye ihtiyaç duymadan görüntüler arasındaki bağlantıyı öğrenip bir resmi bir diğerine dönüştürebilmektedirler. Zorlu hava koşullarında elde edilmiş görüntüleri, istenilen koşullarındaki, hedefin yeniden tespit edilebilirliği daha yüksek görüntülere transfer edilebilmeleri hedef yeniden tespit performansını arttırmaktadır. Bu sebeple, olumsuz hava koşullarında alınan LWIR HSG'ler üzerinde elde edilen düşük tespit oranlarının artırılması amaçlanmış ve görüntüden görüntüye transfer yöntemleri kullanılarak elde edilen görüntüler ile tespit performansları artırılarak başarıya ulaşılmıştır.


2.3.5. Derin Yapay Sinir Ağları ve Temel Kavramlar

Bu bölümde tezde kullanılan derin yapay sinir ağları ile ilgili temel kavramlar anlatılacaktır. Bölüm 2.3.5.1.'de CNN tabanlı modellerle ilgili genel bilgiler verilmiştir. Bölüm 2.3.5.2.,

2.3.5.3., 2.3.5.4.'te CNN tabanlı yöntemlerin katmanlarından, Bölüm 2.3.5.5. ve Bölüm 2.3.5.6.'da ise bu katmanlarda bulunan fonksiyonlardan bahsedilmektedir. Bölüm 2.3.5.7.'de tekrarlayan sinir ağları yapılarının temel prensipleri anlatılacaktır. Bölüm 2.3.5.8.'de ise tezde kullanılan tekrarlayan sinir ağı yöntemi uzun kısa-süreli hafıza (LSTM) yöntemi anlatılacaktır. Son olarak tezde önerilen sahne üretimi yöntemi ile ilgili temel bilgiler Bölüm 2.3.5.9.'da aktarılmaktadır.

2.3.5.1. CNN tabanlı modeller

Hubel ve arkadaşları 1968 senesinde hayvanların beynindeki görsel alanı incelemişler ve görsel aktivitelerin işlendiği alanı keşfetmişlerdir [84]. Bu da aslında görsel girdilerle ilgilenen belirli bir nöron bölgesi olduğu fikrinin yani alıcı alan (receptive field) kavramının doğuşunu sağlamıştır. Bununla birlikte ilk adımı atılan evrimsel sinir ağları (CNN), Yan LeCun ve arkadaşlarının 1998 senesinde yaptıkları LeNet [10] çalışması ile birlikte popülerlik kazanmıştır. LeCun ve arkadaşlarının yaptığı çalışmada, rakam sınıflandırması yapmış ve el yazısı olarak yazılmış rakamların gerçek sınıflarını tahmin etmişlerdir.




Şekil 2.15 Evrişim tabanlı sınıflandırıcı modeli LeNet-5 mimarisi [10]

Şekil 2.15’de gösterilen LeNet-5 yapısı üzerinde bazı temel katmanlar görülmektedir. Bu katmanlardan kısaca Bölüm 2.3.5.2.’de bahsedilmektedir. Çok katmanlı yapay sinir ağları ile görüntü üzerinde sınıflandırma işlemi yapılabilmesi pek çok problemi beraberinde getirmektedir. Her piksel için bir yapay sinir ağının oluşturulması hem “aşırı uyum gösterme (overfitting)” sorunlarına hem de parametre sayısının fazla olmasına sebep olmaktadır. Ayrıca çevre piksellerin bilgisi görüntü verilerinde çalışırken önemli olmakta, çok katmanlı

yapay sinir ağlarında bu bilgi kullanılamamaktadır. Bölüm 2.3.5.2.-2.3.5.5. aralığında bazı temel CNN katmanları hakkında bilgi verilmektedir.

2.3.5.2. Evrişim katmanları


Çevre piksellerin etkisini kullanarak merkezdeki pikselin sınıfını tahmin edebilmek için filtre veya kernel adı verilen yapılar kullanılır. Filtre, görüntüdeki her pikseli işleyecek şekilde gezdirilmektedir. Bu gezdirme işlemi sırasında filtre ile “evrişim” işlemi yapılmakta ve her evrişim işleminde bir değer hesaplanmaktadır. Evrişim katmanı çıktılarına genellikle öznetelik (feature) denilmektedir.



Şekil 2.16 (a) SPICE test sahnesi. (b) SPICE test sahnesinde evrişim operasyonu sonucu

SPICE sahnesinden alınmış bir bant görüntüsü üzerinde dikey filtre ile evrişim yapılmış ve sahnedeki bazı cisim kenarları Şekil 2.16’da gösterildiği gibi belirginleştirilmiştir. HSG’lerde uzamsal ve spektral öznetelikleri birlikte çıkarabilmek için kullanılabilen 3 boyutlu evrişim işlemi Şekil 2.17’de gösterildiği gibidir.

Evrişim katmanında belirtilen sayıda $N \times N$ boyutunda filtreler bulunmaktadır. Bu filtre katsayıları model eğitimi yaptıkça değişmekte ve her biri farklı bir “özneteliği” açığa çıkaracak şekilde katsayı öğrenmektedir. Evrişim işlemi sonrasında elde edilen öznetelik haritası, işlem gören görüntü boyutundan düşük olmaktadır. Bunu engellemek, aynı boyutta katman çıktıları elde edebilmek için ekleme (padding) yapılmaktadır. Padding işlemi,



Şekil 2.17 Üç boyutlu evrişim [11]

görüntü etrafına, filtre çözünürlüğünün yarısı kadar piksel ekleme işlemidir. ‘0’ ekleme (zero-padding), yansıma ekleme (reflection padding) çeşitleri yaygın olarak kullanılanlarıdır.

2.3.5.3. Havuzlama katmanları

Görüntü içerisindeki cisimlerin kapladıkları piksel alanları, görüntüleme cihazına uzaklığına göre değişmektedir. Cismin öznitelikleri öğrenebilmek için o cisme ait her mesafedeki görüntülerine erişim pek mümkün olamadığı için modelimizin cismin boyutun mesafesinden bağımsız öznitelikler öğrenmesi sağlanmalıdır. Havuzlama (pooling) katmanı, evrişimsel sinir ağlarının cismin boyutundan bağımsız olmasını sağlamaktadır. Girdi olarak aldığı görüntüyü, atlama (stride) miktarınca piksel örnekleyerek yarısına veya istenilen boyuta düşürebilmektedir. Aynı zamanda bu katman, modelin öğrenmesi gereken parametre sayısını da düşürmektedir.

Boyut düşürürken maksimum havuzlama yöntemi sıkça kullanılmaktadır. Şekil 2.18’de görüldüğü gibi belirli bir bölgedeki en yüksek aktivasyon değeri tutulmaktadır; geri kalan değerler atılarak boyut azaltılmış ve en işe yarar aktivasyon değerinin saklanması sağlanmıştır.

8	9	12	4	6	5	12	9
1	6	6	3	3	4	8	22
7	3	2	5	6	9		
1	6	3	12	22	7	6	5
5	8	2	4	6	5	4	8
3	6	2	6	4	8		

Şekil 2.18 Aktivasyon haritası (sol), maksimum havuzlama (sağ üst) ve ortalama havuzlama (sağ alt) örneği

2.3.5.4. Tamamen Bağlı Katmanlar


Tamamen bağlı katmanlar (FCL) evrişimsel sinir ağlarının son katmanıdır. Bu katman çok katmanlı sinir ağı yapısına sahip olup alt katmanlarındaki her nöron bir sonraki katmanın bütün nöronlara bağlantı yapmaktadır. Bu yapı son katman olarak kullanıldığında, kendinden önceki katman çıktısını sınıf sayısında çıktı verecek şekilde düzenleyerek sınıfsal olasılıklar üretmektedir. Şekil 2.15’de görüldüğü gibi son üç katman tamamen bağlı katmanlardan oluşturulmuştur.

2.3.5.5. Aktivasyon Fonksiyonları

Temel anlamıyla aktivasyon fonksiyonları, bir sinir ağının aktif olup olmayacağını belirler. Bir yapay sinir ağındaki girdilerin her biri için bir önem ağırlığı vererek doğrusallıktan çıkarır. Yapay sinir ağlarının öğrenilebilirliğini arttıran en önemli faktör doğrusal olmayan bir yapı içermesidir. CNN yapılarındaki öznitelik çıkarıcı FC ve evrişim katmanlarından sonra kullanılarak doğrusal olmayan (nonlinear) öznitelikler öğrenilmesini sağlamaktadır.

Günümüze kadar birçok aktivasyon fonksiyonu üretilmiş ve bu fonksiyonlar derin yapay sinir ağlarında kullanılmıştır. Bazı sıkça kullanılan aktivasyon fonksiyonları şekilde

gösterilmektedir. Hiperspektral görüntü sınıflandırma işlemlerinde sıkça softmax ve ReLU aktivasyonları kullanılmaktadır [12].




Şekil 2.19 Aktivasyon fonksiyonları [12]

2.3.5.6. Kayıp Fonksiyonları

Derin öğrenme ve sinir ağıları modelleri temellerinde birer optimizasyon probleminin çözümleridir. Sınıflandırma problemlerinde modelde ileri besleme işlemi sonucunda piksel bazında her sınıf için olasılık değeri kestirilmektedir. Kayıp fonksiyonları bu kestirim değerleri ile gerçek değerler arasındaki kaybı hesaplamakta ve bu kayıp aracılığıyla optimize edilen modelin tahminlerinin doğru sınıf için en yüksek olması sağlanmaktadır. Çapraz Entropi kaybı (Cross - Entropy loss) sınıflandırıcı kayıp fonksiyonlarından biri olup sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Çalışmamızda eğittiğimiz modellerimizde de bu kayıp fonksiyonu kullanılmaktadır. Bölüm 5.8., 5.9. ve 5.11.'de yapılan çalışmalarda model eğitimleri sırasında kayıp fonksiyonu olarak Çapraz Entropi Kaybı kullanılmıştır.

2.3.5.7. Tekrarlayan Sinir Ağları

Temel bir ileri beslemeli sinir ağı, geçmiş bilgisinden faydalanmayarak şu anki durum için bir çıktı elde eder. Fakat gerçek hayatta bazı durumların tespiti için geçmiş bilgisine de ihtiyaç duyulmaktadır. Örneğin bir video analizi yapılacağı zaman her görüntü karesi sıralı olarak analiz edilerek karar verilmesi gerekmektedir. Sadece şu anki durum bilgisinden ziyade, zamana bağlı olarak sırasıyla elde edilmiş veriler ile işlenmesi gereken, ses tanıma, zaman serisi tahmini, video anlamlandırma gibi durumlarda “tekrarlı sinir ağları” (Recurrent Neural Network - RNN) kullanılmaktadır.




Şekil 2.20 Tekrarlayan sinir ağları

Şekil 2.20’de A yapay sinir ağı G_t anındaki girdiyi kullanarak D_t durum çıktısını üretir. Bu işlem sırasında bir önceki bilgiden yani D_{t-1} bilgisinden de faydalanmaktadır. Tekrarlamalı sinir ağlarının (TSA), klasik evrimsel sinir ağlarından temel farkı geçmiş bilgilerin de kullanılmasıdır. TSA modellerinde hiperspektral görüntülerdeki spektral bilgi zaman adımları (time step) şeklinde modellenerek işlem yapılmaktadır. Çalışmamızda her dalga boyundaki radyans bilgisini bir zaman basamağı olarak kullanmaktayız. $8.21 \mu\text{m}$ ’den $11.5 \mu\text{m}$ ’ye kadar olan 108 adet dalga boyundaki radyans bilgisi sırasıyla Şekil 3.11’deki ağa beslenmekte ve HSG’deki her piksel ilgili sınıfı için sekans şeklinde modellenmektedir. Model yol, alüminyum plaka, siyah cisim, tank ve arka plan olmak üzere 5 sınıf öğrenecek şekilde eğitilmiştir. Spektral bilginin dalga boyu küçükten büyüğe sıralı halde modellenmesi

ile sınıflar arası ayırım öğrenilmiş ve her piksel için sınıflandırma gerçekleştirilmiştir. Tekrarlayan sinir ağlarının en çok kullanılan algoritmalarından biri Uzun Kısa-Süreli Hafıza (Long Short-Term Memory - LSTM) modelidir.

2.3.5.8. Uzun Kısa-Süreli Hafıza

Uzun Kısa-Süreli Hafıza (LSTM) sinir ağı, uzun seriler için gradyan ölmesi problemini çözebilmek için ortaya çıkmış bir derin öğrenme algoritmasıdır [85]. Tekrarlayan sinir ağlarında, verinin bağımlı olduğu geçmiş verilerle mesafesinin uzun olabilmesi dolayısıyla uzun vadeli bağımlılıklarla oluşan gradyan ölmesi problemi bu çalışmada çözülmek istenmiştir. Bütün tekrarlamalı yapay sinir ağlarında zincir halinde sıralanmış modül yapısı bulunmaktadır. LSTM yönteminde zincir halinde modül yapısı korunmuş ama modülün içeriği, uzun vadeli bilgi bağlarını korumaya veya atmaya yarayan yeni terimler eklenerek geliştirilmiştir. Bu yapılar Girdi Kapısı (input gate), unutma kapısı (forget gate) ve çıktı kapısı (output gate) olarak isimlendirilmiştir. Kapıların temel amacı geçmişten kalan bilgilerden en işe yarayanı tutup yararsızlardan kurtulmaktır.




Şekil 2.21 Uzun kısa-süreli hafıza modülü

2.3.5.9. Çekişmeli Üretici Ağlar

Çekişmeli Üretici Ağlar [26], Ian Goodfellow ve arkadaşları tarafından önerilmiş ve sonrasında yapay zeka alanında neredeyse en çok çalışılan alanlardan biri haline gelmiştir. Çekişmeli üretici ağlar, modele girdi olarak giren gürültü vektörünü alıp, iteratif olarak

hedef görüntünün dağılımını öğrenerek ona benzer görüntüler üretmeye çalışır. Bu modellerde temel olarak Üretici (Generative) ve Ayırıştırıcı (Discriminative) olmak üzere iki ağ bulunmaktadır. Üretici ağı, eğitim kümesindeki verilerin dağılımından (P_{data}), bu dağılımı üreten modeli, (P_{model}), kestirerek eğitim verilerine benzer gerçekçi veriler üretebilmektedir. Bu modellerin ismine çekişmeli denmesinin sebebi birbiriyle çekişen iki farklı ağı eğitilmesidir. Bu ağlar eğitim kümesindeki verileri gerçekmiş gibi oluşturabilmek için eğitim verilerin dağılımını öğrenen model “üretici ağ”, G , ve örnek verinin eğitim veri kümesinden mi yoksa “üretici” model G ’nin çıktısından mı geldiğini olasılıksal olarak tahmin eden “ayrıştırıcı” model D ’dir. Bu modellerin birlikte eğitim sürecine “minimaks oyunu” denmektedir.



Şekil 2.22 Üretici çekişmeli ağlar genel şeması

Üretici ağ, ayırıştırıcı ağı yanıltarak gerçeğe yakın, eğitim verisi ile aynı dağılıma sahip örnekler üretmeye çalışmaktadır. Ayırıştırıcı ağ ise üretici kısımdan üretilen örneklerin gerçekliğine karar vermektedir. Eğitim kümesinin dağılımına yakın görüntüler üretmek üretici ağı başarısını göstermekte bu üretilen görüntülerin yakalanmasını sağlamak da ayırıştırıcı ağı başarısı olarak görülmektedir. Minimaks oyunu, bahsedildiği şekilde üretici ve ayırıştırıcı ağların birbirlerine karşı kazanmasıdır.

Şekil 2.22’de GAN’ların genel yapısı gösterilmektedir. Burada z vektörü gizli simgesi (latent representation), genellikle Gauss dağılımında olup üretici ağı beslemek için kullanılmaktadır. $D()$ modülü ayırt edici ağı, $G()$ üretken ağı, x de gerçek örneği temsil etmektedir. Bu iki ağı GAN [26] çalışmasında çok katmanlı yapay sinir ağı olmakla birlikte bu çalışmada da kullanılan PIX2PIX üretici çekişmeli ağlarında U-Net evrimsel sinir ağları kullanılmaktadır. Birinci senaryoda eğitim kümesinden rastgele bir veri seçilir. Ayırt edici ağa hem eğitim verisinden hem de üretken ağdan gelen veri ile bu iki girdinin yarısının gerçek yarısının sahte olduğunu bilerek ayırtırmaya, $D(x) = 1$ yapılmaya çalışılır. İkinci senaryoda ise hem üretici ağı hem de ayırt edici ağı aktif olmaktadır. Gizli temsili vektör, z , üretici ağa beslenir. Üretici ağı, gizli simgeyi kullanarak sahte örnek üretmektedir. Sahte örnek ve gerçek örnek birlikte ayırt edici ağa verilir, ayırt edici ağı $D(G(Z))$ denklemini 0 yani sahte, üretici ağı ise $D(G(Z))$ denklemini 1, yani gerçek, yapmaya çalışmaktadır. $D(G(Z)) = 0.5$ olduğunda dengeye ulaşılarak minimaks oyunu tamamlanmış olmaktadır.

GAN yapısı yukarıda anlatıldığı gibi minimaks oyunu şeklinde anlatıldığı gibi teorik olarak da kayıp fonksiyonu Denklem 4, 5 ve 6’daki gibi ifade edilmektedir. Denklem 4’te görüldüğü üzere ayırt edici ağı $V(D, G)$ ’yi maksimize etmeye çalışırken, Üretici Ağı minimize etmek için eğitilmektedir.

$$V(D, G) = E_{x-p(x)}[\log D(x)] + E_{z-q(z)}[\log(1 - D(G(z)))] \quad (4)$$

$$V(D, G) = E_{x-p_{data}}[\log \frac{p_{data}(x)}{p_{data}(x) + p_g(x)}] + E_{z-p_g}[\log \frac{p_g(x)}{p_{data}(x) + p_g(x)}] \quad (5)$$

$$\theta^{(G)*} = \operatorname{argmin}_{\theta} \theta(G) \max_{\theta} \theta(D) (\theta^{(D)}, \theta^{(G)}) \quad (6)$$

Denklem 4’te x gerçek görüntüyü, $x - p(x)$ gerçek görüntünün dağılımını, z gizli simgeyi (latent representation), p_g üretici ağın dağılım fonksiyonunu, $p_g(x)$ üretici ağın x verisi ile öğrendiği dağılımı, p_{data} ise gerçek verilerin dağılımını ve θ derin öğrenme modellerinin içerdiği parametreleri ifade etmektedir.

Ayrıştırıcının eğitilmesi ile x verisinin her noktası için Denklem 5'teki $\frac{p_g(x)}{p_{data}(x)+p_g(x)}$ oranını kestirmek mümkün hale gelmektedir. Bu oranın kestirimi ile gradyan hesabı ile yakınsama yapılması sağlanmaktadır. Burada $V()$ fonksiyonu ayırt edici ağı yapmış olduğu hata gibi düşünülebilmektedir.

2.4. Hiperspektral Görüntülerde Boyut Azaltma Yöntemleri

Hiperspektral görüntülerin yüksek spektral çözünürlükleri zengin bilgi içeriğine sahip olmalarını sağlamaktadır. Fakat aynı zamanda bu durum gürültüye kolaylıkla maruz kalabilmelerine neden olmaktadır. Bu sebeple Morales ve arkadaşlarının çalışmasında [86] gürültülü bantlardan kurtulmak ve en ihtiyaç olunan bantları seçebilmek amacıyla farklı yöntemlerle [87, 88] hedef tespiti için en etkin bantlar seçilmiş ve boyut düşürülerek hedef tespit çalışmaları yapılmıştır. Bant sayısını azaltırken bantların tespitinde önem sıralamasını belirleyebilmek için iki adımlı yöntem önerilmiştir [86]. Birinci adımda, IBRA (interband redundancy analysis) ile her bant ve komşuları arasında eş-doğrusallık analizi yapılmakta, bu sayede gereksiz bantlardan kurtularak arama uzayının boyutu düşürülmektedir. İkinci adımda ise açgözlü spektral seçim (greedy spectral selection (GSS)) yöntemi ile ilk adımın çıktılarının entropi değerleri hesaplanarak bant seçim işlemi tamamlanarak, boyutu azaltılmış HSG'ler ile evrimsel sinir ağı eğitilmektedir. Morales ve arkadaşlarının çalışması neticesinde verilerin 200 banttan 31 banda düşürülmesi performansı düşürmemiş aksine iyileştirdiği görülmüştür. Bu tezde de, hem bant seçim hem de boyut düşürme teknikleri hedef tespit çalışmalarında kullanılmıştır.

Telops Hyper-Cam kamerasıyla elde edilmiş $7.8 \mu\text{m} - 11.5 \mu\text{m}$ aralığındaki LWIR görüntülerle çalışan bir diğer çalışmada HSG boyutu, boyut düşürme işlemi verideki gürültüyü minimuma indirmeye dayandıran Minimum Gürültü Kesiti (MNF) uygulayarak düşürülmüş sonrasında Kısıtlı Enerji Minimizasyonu (CEM) sınıflandırıcısı ile hedef tespiti yapılmıştır [89]. Bu çalışmada digital renkli fotoğraf ile sınıflandırıcı başarımları artırılmıştır.

Yoğunluk tabanlı kümeleme algoritmasından esinlenen çalışmada [90], bantlar arasında yapısal benzerlik (structural similarity SSIM) ölçüğü önerilmiş ve bu ölçüğe göre bant

seçme yöntemi oluşturulmuştur. Öklit uzaklığı kullanan diğer yöntemlere göre daha uygun bir yöntem olduğundan bahsedilen bu yöntemde, uzamsal bilgiden de faydalanılmasının yanında, derin öğrenme yöntemleri ile birlikte kullanımında aşırı uyumu önlediği ve gereksiz bilgilerden arındırdığı gözlenmiştir.

Rastgele orman (RF) sınıflandırıcısı ile Boruta [88], yinelemeli öznitelik eleme (RFE) [91] ve RF modelinin ROC eğrisi altında kalan alan (AUC-RF) boyut düşürme yöntemleri kullanılarak bunların performansı incelenmiştir ve Boruta yönteminin [88] en iyi performansı verdiği gözlemlenmiştir [92]. Ayrıca Boruta ile bant sayısı düşürülmüş halde yapılan sınıflandırma testinin bütün bantlar kullanılarak yapılandan daha yüksek başarımlar gösterdiği gözlemlenmiştir. Bu çalışmada da Boruta yöntemi kullanılarak bant seçimi yapılmış ve performansı incelenmiştir. Yapılan testlerde Boruta ile bant seçimi aracılığı ile boyut düşürmenin performansı her test durumunda da arttırdığı gözlenmiştir.

LWIR HSG görüntülerinden yaprak sınıflandıran bir çalışmada [93], yaprak spektralarının düşük kontrastlı olması, farklı yapraklarının spektralarının birbirine benzemesi sebebiyle sınıflandırmada kullanılacak en etkili bantları bularak bant sayısını azaltma gereksinimi duyulmuştur. Farklı kimyasal maddelerin (kutin, silika ve oleanolik asit) soğurma bantlarında spektral farklılıklar oluşturduğu gözlenmiştir. Bant sayısının azaltımında üç farklı yöntem (mRMR[94], VSRF[95], NSSA[96]) ve bunların birleşimleri kullanılmış, sırasıyla 8-9, 8-8.3, 8.5-10.2 ve 8.6-9.2 μm aralıklarında en iyi özniteliklerin ayrıştırılabildiği gözlenmiş ve daha az bant kullanılmasına rağmen sınıflandırma başarımları %3 artmıştır.

Hiperspektral görüntüler, arazi sınıflandırma çalışmalarında da sıklıkla kullanılmaktadır [97]. Bu çalışmada HSG'ler üzerinde bant azaltma çalışması yapılmış, birleşik manifold yaklaşımı ve projeksiyonu (UMAP) boyut azaltıcısı SVM sınıflandırıcısı ile kullanılmıştır. UMAP yöntemi, farklı boyut düşürücüler (PCA[98], LDA[99], LLE[100], T-SNE[101], SVD [102], ICA[103], ve FA[104]) arasında en iyi sonucun elde edilmesini sağlamıştır. Makine öğrenmesi yöntemleri kullanılarak LWIR HSG'lerde boyut azaltma çalışmaları da bulunmaktadır [105].

Multispektral görüntüler boyut, maliyet ve karmaşıklık gibi açılardan HSG'lere göre daha avantajlıdır. Multispektral görüntüler, HSG'ler temel alınarak hedef ve arka planı ayırt edebilmemizi sağlayacak en optimum bant grupları tespit edilerek bant sayısının işlem gücü yüksek bilgisayarlar üzerinde optimizasyon yaparak düşürülmesi ile elde edilmektedir [106].

Tezde HSG'lerde bant azaltma yöntemleri iki aşamada incelenmiştir. Bölüm 2.4.2.'de 108 bant üzerinden denetimsiz boyut azaltma yöntemlerinden Bölüm 2.4.2.1.'de PCA yöntemi kullanılarak boyut düşürülmüş ve düşük boyutlu temsili HSG üzerinde hedef tespiti çalışması imza tabanlı yöntemler kullanılarak tertip edilmiştir.

Boyut azaltmak amaçlı bir diğer çalışma da en önemli bantların belirlenmesidir. SPICE veri kümesinde Telops Hyper-CAM kamerası ile 165 spektral bant içeren HSG'ler alınmış, Şekil 2.2 deki gibi olan gürültülü bantlar, Şekil 2.3'te görüldüğü gibi kesilerek kullanılmıştır. Belirlenen 108 bant arasında ise hedef yeniden tespiti için en mühim olan bantların belirlenmesi için 2.4.1.'de bahsedilen yöntemler kullanılarak en kullanılabilir 20 bant belirlenmiş ve hedef yeniden tespit performansına katkısı incelenmiştir.

2.4.1. Bant Seçim Teknikleri

Öznitelik seçimi yöntemleri, tablo şeklinde birçok öznitelik içeren çalışmalarda fazlalık özniteliklerden kurtulmak üzere kullanılmaktadır. Bu çalışmada 108 bandın her biri birer öznitelik olarak sayılmış ve bunlar arasında hedef yeniden tespit performanslarına göre önem sıralaması oluşturulmuştur.

2.4.1.1. Yinelemeli Öznitelik Eleme

Yinelemeli Öznitelik Eleme'de (RFE) [91], belirlenen bir tahmin yöntemi ile özniteliklere önem ağırlıkları ataması yapılmaktadır. Bu yöntemde yinelemeli olarak her özniteliğin ağırlığı güncellenerek önem sıralaması oluşturulur. İlk adımda bütün özniteliklere ağırlıklar verilir, belirlenen miktarda öznitelik azaltması yapılarak bir sonraki adımda daha az öznitelik

üzerinde ağırlık ataması yaparak istenilen sayıda azaltma yapana kadar bu işleme devam edilmektedir.

Çalışmada, RFE [91] ile birlikte Karar Ağacı Sınıflandırıcı (DTC) kullanılmıştır. DTC, basit karar kuralları kullanarak tahmin yapılmasını sağlayan bir yöntemdir.

2.4.1.2. Boruta ile Öznitelik Seçimi

Boruta [107] yöntemi Rastgele Orman Sınıflandırıcısı (Random Forest Classifier - RFC) kullanarak öznitelik seçimi yapan bir yöntemdir. Bu yöntemde diğer öznitelik seçimi yöntemlerinden farklı olarak öznitelik altkütmesi bularak hatayı azaltmaya yönelik çalışmaktan ziyade, bilgi taşıyan bantların bulunması amaçlanmaktadır. RFC’de eğitim kümesindeki verilerden rastgele örnekler alarak, bu örneklerle istatistiksel modeller geliştirilmesi sağlanmaktadır. Sınıflandırma işleminde bu modellerin tahminlerinin ağır basanı seçilerek nihai karar alınmaktadır. Boruta yönteminin temel basamakları şu şekildedir:

- Bütün özniteliklerin kopyaları oluşturulur.
- Öznitelikler kendi içlerinde karıştırılır.
- RFC genişletilmiş veri kümesinde çalıştırılır ve önem skorları hesaplanır.
- Kopya öznitelikler arasından en yüksek skora sahip olanlar işaretlenir, bundan daha yüksek skorlu gerçek öznitelikler belirlenir.
- Her bant için, skoru en yüksek kopya bant arasında test uygulanır.
- Bu testlerde en yüksek skorlu kopya banttan yüksek skora sahip gerçek bant önemli, daha düşük bantlar ise önemsiz olarak belirlenir.
- Tüm kopya bantlar kaldırılır ve işlem tüm bantlar için bir önem atanıncaya kadar devam eder.

2.4.2. Boyut Azaltma Teknikleri

2.4.2.1. Temel Bileşenler Analizi

Temel Bileşenler Analizi (PCA), hiperspektral görüntü boyut azaltma çalışmalarında da sıkça kullanılan, varyans doğrultusunda veri boyutu azaltma yöntemidir. Bu yöntem ortalama karesel hata (MSE) açısından en düşük hatayı verecek boyut azaltma algoritmasıdır. Diğer boyut azaltma yöntemlerinde olduğu gibi PCA'deki temel amaç, veriyi temsil edebilecek en düşük boyuttaki temel bileşenleri bulabilmektir.

2.5. Çekişmeli Üretici Ağlar ile HSG Üretimi

HSG'lerin elde edilme maliyetlerinin yüksek olması sebebiyle literatürde halka açık az veri kümesi bulunmaktadır. Bu sebeple bazı çalışmalarda araştırmacılar GAN ve benzer yapılar kullanarak materyal spektralleri oluşturmuş ve bunlar üzerinde çalışmalarını yürütmüşlerdir [108–112].

Zaman serisi çekişmeli üretici ağları TSGAN [109], iki farklı Weisserstein GAN (Generative Adversarial Network) yapısını iki ayrı dalda kullanarak zaman serisi verisi üretmek için oluşturulmuş bir modeldir. Birinci ağda gürültüden spektrogram görüntüleri üretilirken ikinci ağda ise bu üretilen sentetik spektrogram görüntüleri kullanılarak bir boyutlu zaman serisi sinyalleri elde edilmekte ve gerçek zaman serisi sinyallerine benzetilmektedir. Çalışmanın temel amacı hava durumu öngörüsü, borsa tahmini veya EKG (elektrokardiyografi) sinyallerinden kalp rahatsızlığı tespiti gibi durumlar için yeteri kadar bulunmayan gerçek veri sayısını arttırabilmektir. Buna benzer bir diğer çalışmada [110] Weisserstein çekişmeli üretici ağı kullanılarak etiketli veya etiketsiz hiperspektral örnekler üretilmiştir.

Kızılötesi görüntüler, kullanım alanlarının genişliğinin aksine elde edilmesi ve ulaşılması zor görüntülerdir. Termal görüntü azlığını aşabilmek için Li ve arkadaşlarının yaptığı çalışmada [113] koşullu çekişmeli üretici ağlar kullanılarak termal görüntüler elde edilmiştir. Gürültü yerine kullanılan koşul görüntülerinin D-LinkNet çekişmeli üretici ağı ile üretimi, PatchGan

ayrıştırıcısı ile de kontrolü sağlanmıştır. Benzer şekilde ThermalGAN [114] çalışmasında literatüre insanların hem renkli hem de termal görüntü eşlerinden oluşan bir veri kümesi katkısında bulunmuşlardır. Aynı zamanda yaptıkları çalışmada, çekişmeli üretici derin ağ ile renkli görüntüleri termal görüntülere çevirmeyi başarmışlardır.

Murphy ve arkadaşları kimyasal maddelerin sentetik reflektans verileri ile yapılan eğitimlerdeki verimsizliği aşabilmek için bir boyutlu koşullu çekişmeli üretici ağ ile, kimyasal maddelerin sentetik spektralarının gerçeğe daha yakın sentetik verilere çevrimini gerçekleştirmişlerdir [115]. Yapılan çalışma neticesinde, sentetik veri üzerinde yapılan tespit çalışmalarına göre %10 iyileştirme sağlamıştır.

3. ÖNERİLEN YENİDEN HEDEF SAPTAMA YÖNTEMLERİ

Bu çalışmada LWIR HSG'lerde hedefin yeniden saptanması için 5 farklı yöntem önerilmiştir. Bu bölümde, ilk olarak Bölüm 3.1.'de önerilen yöntemlere teşkil eden ve her bir yöntem için kullanılan temel içerik olarak, sıcaklık ve salıcılık dönüşümleri ele alınmıştır. Kullanılan deney verisinde, görüntülerdeki radyans spektralleri üzerinden ilgili sıcaklık ve salıcılık dönüşümlerinin nasıl uygulandığı Planck denklemleri üzerinden sıralı bir şekilde anlatılmıştır. Bölüm 3.2.'de LWIR HSG'lerde, radyans verisi üzerinde imza tabanlı eşleştirme yöntemleri kullanılarak hedef tespit çalışmaları gerçekleştirilmiş ve hava koşullarının tespit performansına etkisi incelenmiştir. Bölüm 3.3.'te radyans verisinden sıcaklık verisine dönüşüm yöntemiyle hesaplanmış sıcaklık verilerinin birleştirilmesi ile elde edilen sıcaklık profilleri üzerinde hedef tespiti yapılmıştır. Bölüm 3.4.'te sahne transfer yöntemi kullanılarak test sahnesi referans sahneye dönüştürülmüş ve görüntü transferinin hedef tespitine etkisi incelenmiştir. Bölüm 3.5.'te Uzun Kısa-Süreli Hafıza (LSTM) modülü ile oluşturulan model ile birlikte eğitimler tertip edilmiş, farklı örnekleme sıklıklarında bu yöntemin performansı irdelenmiştir. Bölüm 3.6.'da farklı zamanlarda görüntülenmiş LWIR HSG'leri birleştirilerek zamansal LWIR HSG'ler elde edilmiş ve bu küpler üzerinde imza tabanlı eşleştirme yöntemleri ve LSTM modeli kullanılarak hedefin yeniden saptanması gerçekleştirilmiştir. Bölüm 3.7.'de evrişim tabanlı derin öğrenme yöntemleri ile karşılaştırma amaçlı olarak LWIR HSG'ler üzerinde hedef tespiti gerçekleştirilmektedir. Bu bölümün temel amacı, literatürdeki HSG sınıflandırıcı mimarilerinin LWIR HSG'lerdeki performanslarını karşılaştırmaktır.

3.1. Atmosferik Düzeltme ve Sıcaklık-Salıcılık Dönüşümleri

Sahne içi atmosferik düzeltme, uydu veya hava görüntüleri üzerindeki atmosferik saçılma ve soğurma etkilerini düzeltmek için uzaktan algılama ve görüntü işlemede kullanılan bir tekniktir. Bu teknikler, verilerin doğruluğunu ve güvenilirliğini artırmak için pus,

bulutlar ve su buharı gibi atmosferik bileşenlerin etkisini gözlenen sinyalden kaldırmayı amaçlamaktadır. Uzaktan algılama görüntülerinde atmosferik etkileri telafi etmek için geliştirilmiş birçok yöntem ve algoritma bulunmaktadır. Bu yöntemler genel olarak iki kategoriye ayrılabilir: görüntü tabanlı yöntemler ve model tabanlı yöntemler.

Model tabanlı yöntemler, elektromanyetik radyasyonun atmosfer boyunca ışımsal transferini simüle etmek için atmosferin fiziksel modellerini gözlemlenen sinyali düzeltmek için kullanılmaktadır. Model tabanlı yöntemlerin bazı örnekleri arasında, atmosferik parametreleri tahmin etmek için ışımsal transfer modellerini kullanan FLAASH [116] yöntemi ve yaygın olarak kullanılan bir atmosferik ışımsal aktarım modeli olan MODTRAN [47] modeli yer alır. Model tabanlı yöntemler, atmosferin detaylı meteorolojik ölçümlerine gereksinim duyduğundan bu tezde kullanılmamıştır.

Görüntü tabanlı yöntemler, atmosferik parametreleri tahmin etmek için görüntünün kendisini kullanmakta ve ardından bu tahmini kullanarak görüntüyü düzeltmektedir. Bu yöntemlere örnek olarak ISAC [27] verilebilmektedir. ISAC yöntemi yardımcı meteorolojik veriler veya atmosferik modelleme kullanmadan doğrudan HSG'lerin radyans verilerinden ölçeklendirilmemiş atmosferik düzeltme spektrumlarını çıkarmak için tasarlanmıştır.

Hiperspektral görüntü alımı sırasında, bir sahneden sensöre ulaşan radyans Denklem 7'deki gibi modellenmektedir. Burada λ dalga boyunu, $\epsilon(\lambda)$ yüzey salıcılık spektrumunu, $\tau(\lambda)$ atmosferik iletim spektrumunu, $L_u(\lambda)$ yukarı yönlü atmosferik ışımayı ve $L_d(\lambda)$ atmosferik aşağı düşen radyansı temsil etmektedir.

$$L_s(\lambda) = \epsilon(\lambda)B(T, \lambda)\tau_{atm}(\lambda) + [1 - \epsilon(\lambda)]L_d(\lambda)\tau_{atm} + L_a \quad (7)$$

$B(\lambda, T)$ ise Denklem 8'de gösterilen siyah cisim ışımasıdır. $C1 = 1.19104 \times 10^{10} (\mu W/cm^2/sr/\mu m) - \mu m^5$ ve $C2 = 14387.7 \mu m - K$ radyasyon katsayılarını ve T yüzey sıcaklığını vermektedir.

$$B(\lambda, T) = \frac{C1}{\lambda^5 [e^{\frac{C2}{\lambda T}} - 1]} \quad (8)$$

Atmosferik düzeltmelerin temel amacı, yüzey ışımasını $\epsilon(\lambda)B(T, \lambda)$ 'yi elde etmek için sensöre ulaşan radyans $L_s(\lambda)$ içerisinde atmosferik katkıları çıkarmaktır. Denklem 9'da sensöre ulaşan radyansın atmosferik yol ışıması $L_a(\lambda)$, atmosferik yukarı yönlü ışıma $L_u(\lambda)$ ve atmosferik iletim τ_{atm} 'den etkilendiği gösterilmektedir. Atmosferik yukarı yönlü ışıma ise Denklem 10'da gösterilmekte olup, $B(T, \lambda)$ Denklem 8'de gösterilen siyah cisim ışımasını, $\epsilon(\lambda)$ cismin salıcılığını (emissivity) ve $L_d(\lambda)$ ise atmosferik aşağı yönlü ışımasını ifade etmektedir.

$$L_s(\lambda) = \tau_{atm}(\lambda)L_u(\lambda) + L_a(\lambda) \quad (9)$$

$$L_u(\lambda) = \epsilon(\lambda)B(T, \lambda) + [1 - \epsilon(\lambda)]L_d(\lambda) \quad (10)$$


Yukarıda verilen Denklem 9'a göre bu tezde ISAC [27] yöntemi aracılığıyla Denklem 11 eşitliğindeki atmosferik iletim τ_{atm} ve $L_a(\lambda)$ değerleri, nesneden sensöre ulaşan radyans ile nesnenin sahip olduğu sıcaklık sebebiyle yaydığı siyah cisim ışıması arasındaki doğrusal bağlantı kullanılarak hesaplanmaktadır.

$$L_u(\lambda) = \frac{L_s(\lambda) - L_a(\lambda)}{\tau_{atm}} \quad (11)$$

Deneylerde kullandığımız ISAC yöntemi şu şekilde özetlenebilir;

- İlk olarak atmosferik iletimin en yüksek olduğu varsayılan 10.102 μm bandında Denklem 1 kullanılarak görüntünün parlaklık sıcaklığı, T , bulunur.
- Her piksel için bulunmuş parlaklık sıcaklığı verileri kullanılarak piksellerdeki her 108 dalga boyu için siyah cisim ışıma değerleri Denklem 8 kullanılarak $B(\lambda, T)$ hesaplanır.

- Her bir piksel için o pikselin sahip olduğu siyah cisim radyansı $B(\lambda, T)$ ile sensöre ulaşan radyans, $L_s(\lambda)$ birlikte çizdirilir ve oluşan noktalar üzerinden geçen en yakın doğru bulunur. Bu doğrunun eğimi bize atmosferik iletimi τ_{atm} , y eksenini kestiği nokta ise atmosferik yol radyansını $L_a(\lambda)$ vermektedir.



Şekil 3.1 Sensöre ulaşan ışıma $L_s(\lambda)$ ve siyah cisim ışıması $B(T, \lambda)$ dağılımı

- Denklem 10 revize edilerek salıcılık yalnız bırakıldığında Denklem 12 elde edilmektedir. Bu denklemde L_d çok düşük olduğu için ihmal edilmiş ve Denklem 13 elde edilmiştir. Denklem 11 ve Denklem 13 birleştirilerek elde edilen Denklem 14'te, önceden hesaplanmış τ ve L_a değerleri uygulanarak salıcılık hesaplanmaktadır.

$$\epsilon(\lambda) = \frac{L_u(\lambda) - L_d(\lambda)}{B(\lambda, T) - L_d(\lambda)} \quad (12)$$

$$\epsilon(\lambda) = \frac{L_u(\lambda)}{B(\lambda, T)} \quad (13)$$

$$\epsilon(\lambda) = \frac{L_s(\lambda) - L_a(\lambda)}{B(\lambda, T) * \tau_{atm}} \quad (14)$$

Bu tezde, Bölüm 5.4.'de anlatılan yöntemlerde, bu bölümde anlatılan yöntemle elde edilen salıcılık değerleri kullanılarak hedef tespit çalışmaları gerçekleştirilmiştir.


3.2. Radyans Verisi Üzerinde Hedef Tespiti

Bu bölümde Bölüm 4.'te anlatılan hedef sahnesinde, üzerinde herhangi bir dönüşüm yapmadan radyans verileri üzerinde hedef tespiti yapılmıştır. İmza tabanlı eşleştirme uygulamalarının anlatıldığı Bölüm 2.2.'deki eşleştirme yöntemlerinden ACE, Bölüm 4.'te anlatılan hedef sahnesinde test edilmiştir.


Bu bölümde yapılan hedef tespit çalışmalarında radyans verisi spektral imza olarak kullanılmıştır. SPICE veri kümesinde bulunan tank hedeflerinin radyans imzalarının hava koşullarına göre değişimleri analiz edilmiş ve Şekil 3.2'de gösterilmiştir. Şekil 3.2(a)'da benzer saatler, nem ve 10°C, 20°C ve 30°C hava sıcaklıklarında alınmış HSG'lerdeki Tank 1 hedefinde belirlenmiş bir noktanın radyansları çizilmiştir. Şekil 3.2(b)'de ise 10°C, 20°C, 25°C ve 30°C hava sıcaklıklarında alınmış HSG'ler kullanılmıştır. Şekil 3.2(a)'da hava sıcaklığının yüksek olmasının radyans değerlerinin yüksek olmasına etki ettiği gösterilmektedir. Aynı zamanda benzer hava sıcaklığında alınan HSG'lerdeki radyans imza benzerliği de göze çarpmaktadır. Şekil 3.2(a)'da 10°C hava sıcaklığında, benzer nem oranlarında ve üç tanesi sabah saatlerinde (04:43, 05:28, 08:13), üç tanesi de akşam saatlerinde (20:28, 21:23, 20:23) olmak üzere alınan HSG'lere ait radyans imzalarına bakıldığında, sabah ve akşam alınmış imzalar arasında bir ayrım görülmektedir. Buna

sebeup olarak, öğlen saatlerinde en yüksek hava sıcaklığına erişildikten sonra sahnedeki cisimlerin soğumaya başlamalarından dolayı 20:00 saatlerindeki cisimlerin sıcaklıklarının, 05:00 saatlerindeki sıcaklıklarından yüksek kalmasıdır. Şekil 3.2(b)'de ise 20°C ve 25°C hava sıcaklıklarında alınan radyans imzalarının birbirlerine karıştığı gözlenmektedir. Hava sıcaklığının 25°C olduğu günlerdeki nem oranının, hava sıcaklığının 20°C olduğu günlerin nem oranından yüksek olması, hedeflerin radyans değerlerinin düşük olmasına sebep olduğu düşünülmektedir. Bu koşullar dikkate alındığında hedef tespiti yapılırken benzer hava koşullarından elde edilmiş radyans imzalarının kullanılmasının önemli olduğu görülmüştür.

Hedef tespiti için spektral imzanın seçildiği bölge de önem arz etmektedir. Güneşlenmenin olduğu günlerde güneş gören bölgelerin spektrumları benzer olmakla birlikte güneşsiz günlerde durum değişebilmektedir. Bu sebeple Bölüm 5.3.'te öncelikle spektral imza seçim farklılığının tespiti etkisi incelenmiş, sonrasında bütün deneylerde bu test sonucunda belirlenen noktadan spektral imza alınarak çalışmalara devam edilmiştir. Seçilen spektral imza öncelikle ertesi günün her saat başında test edilmiştir. Ayrıca belirlenen bir günde 00:00 saatinden itibaren 3'er saat aralarla seçilmiş spektral imzalar diğer günlerde karşılaştırılmış ve hava durumunun tespit performanslarına etkileri incelenmiştir. Benzer çalışmalar mevsimsel değişiklikler için de gözlemlenmiştir.



(a) Tankın benzer saatler, nem ve yaklaşık 10°C, 20°C ve 30°C hava sıcaklıklarında radyans imzaları




(b) Tankın benzer saatler, nem ve yaklaşık 10°C, 20°C, 25°C ve 30°C hava sıcaklıklarında radyans imzaları

Şekil 3.2 Sahneye yerleştirilmiş tank hedeflerinin farklı hava koşullarındaki radyans imzaları

3.3. Parlaklık Sıcaklığı Verisi Üzerinde Hedef Tespiti

Bu bölümde aynı sahne üzerinde yapılan bir başka çalışmada [50] bahsedilen radyans verisinden parlaklık sıcaklığı dönüşümü yapılarak bütün LWIR hiperspektral küpleri 2 boyutlu sıcaklık haritalarına çevrilmiş, belirlenmiş bir örnekleme sıklığına göre bu iki boyutlu sıcaklık haritaları birleştirilerek sıcaklık küpleri elde edilmiştir. Sıcaklık küplerinden alınan spektral imza aracılığıyla, Bölüm 2.2.'de anlatılan eşleştirme algoritmaları ile hedef tespiti yapılmış ve performansı Bölüm 5.5.'te değerlendirilmiştir.



Şekil 3.3 Sahnedeki atmosfer etkisi

Şekil 3.3'te veri alınan sahnenin görüntüsü verilmektedir. Bu görüntüde sensöre gelen radyans değeri birçok dış etkenden etkilenmektedir. Bir cisimden sensöre ulaşan radyans değeri içerisinde atmosferden cisim üzerine düşen radyansın yansıması, cismin sahip olduğu sıcaklık ile oluşan siyah cisim ışıması ve atmosferin sensöre direkt etkisi bulunmaktadır. Tek bir piksele düşen radyans Denklem 15'teki gibi modellenmektedir.

$$L(\lambda) = \epsilon(\lambda)B(T, \lambda)\tau(\lambda) + [1 - \epsilon(\lambda)]L_d(\lambda)\tau + L_a \quad (15)$$

Bu denklemde λ dalga boyunu, ϵ yüzey salıcılık spektrumunu, τ sensor ve hedef arasındaki atmosferik iletim spektrumunu, L_a yukarı yönlü atmosferik radyansını ve L_d aşağı yönlü atmosferik radyansını belirtmektedir. B ise Planck siyah cisim ışıma [1] fonksiyonunu vermektedir. Denklem 15'teki siyah cisim ışıması yalnız bırakıldığında Denklem 16 elde edilmektedir.

$$B(\lambda, T) = \frac{[L(\lambda) - L_a(\lambda) - [1 - \epsilon(\lambda)]L_d(\lambda)]}{\epsilon(\lambda)\tau(\lambda)} \quad (16)$$

Planck siyah cisim ışıması Denklem 17'de gösterilmektedir.

$$B(\lambda, T) = \frac{C1}{\lambda^5 [e^{\frac{C2}{\lambda T}} - 1]} \quad (17)$$

Denklemdeki $C1$ ve $C2$ değerleri ise Denklem 20'de gösterilmektedir.

$$L_a(\lambda) \approx 0, [1 - \epsilon(\lambda)]L_d(\lambda) \approx 0, \epsilon(\lambda) \approx \tau(\lambda) \approx 1 \quad (18)$$

Radyans üzerinden parlaklık sıcaklığı kestirimi için Denklem 18'de gösterilen bazı sadeleştirmeler yapılmıştır. Ölçüm mesafesinin kısa olmasından dolayı atmosferik yol radyansının ($L_a = 0$) ve iletimin (transmittance) 1'e yakınsayacağı ($\tau = 1$) ve ayrıca cisimlerin salıcılığının maksimumda olduğu varsayılmıştır.


$$L(\lambda) = B(\lambda, T) \quad (19)$$

$$TBB(\lambda, L) = \frac{C2}{\lambda [\ln(\frac{C1}{\lambda^5 L(\lambda)} + 1)]}, \quad C1 = 1.19104 \times 10^{10} (\frac{W}{cm^2 sr^{-1} m}), \quad C2 = 1487.7 mK \quad (20)$$

Denklem 18’de yapılan sadeleştirmelerle birlikte salıcılıktan gelen farklılık göz ardı edilerek, cisimlerin parlaklık sıcaklığı Denklem 20’de dalga boyu ve radyans değerleri kullanılarak elde edilmektedir.


Sıcaklık kestirimindeki hatayı azaltabilmek için -10 °C ve 70 °C arasındaki her 0.1°C aralıkla bütün sıcaklıklar için Planck denklemi kullanılarak siyah cisim ışıma değerleri oluşturulmuştur. Şekil 3.4’te görüleceği üzere örnek bir pikselin sıcaklığı kestirilerek en düşük hata alınan nokta tercih edilmiş ve parlaklık sıcaklığı grafikteki en düşük değer olarak 64.7 °C kabul edilmiştir.

$$\hat{T} = \min_{\lambda_{ilk}} \sum_{\lambda_{son}} (\beta_{\lambda} - \beta_{piksel})^2 \quad (21)$$




Şekil 3.4 Parlaklık sıcaklığı kestirimi örneği

Ayrıca her piksel radyans değeri ile, -10°C ve 70°C derece aralığında her 0.1°C aralıklarla elde edilmiş siyah cisim ışımaları arasında ortalama kare hesabıyla Denklem 21’de görüldüğü gibi en yakın sıcaklık, ilgili siyah cisim radyansını elde edildiği sıcaklık olarak belirlenmiştir. Şekil 3.5’te örnek bir parlaklık sıcaklığı haritası gösterilmektedir. Tank hedeflerinin güneşe maruz kalan bölgelerinin sıcaklıklarının çevreye göre daha yüksek olduğu gözlenmektedir.




Şekil 3.5 Parlaklık sıcaklığı haritası

Piksellerin sahip olduğu radyans spektrumu, -40°C ve 70°C aralığındaki her 0.1°C için hesaplanan siyah cisim ışıma spektrumu ile karşılaştırılmış ve en yakın ortalama kare hesabı veren sıcaklık değeri seçilmiştir. Seçilen siyah cisim ışıma spektrumları Şekil 3.6'da gösterilmektedir. Hedeflerin ve siyah cismin yaydıkları radyansların, Planck eğrisine yakın olduğu, siyah cismin ise en yakın olduğu gösterilmektedir.



Şekil 3.6 Siyah cisim ışımasına en yakın Planck eğrisi kestirimi

Planck eğrilerinden sapmaların konumu, cisimlerin özniteliklerini gösterdikleri bölgeler olabileceği düşünülmüş ve bu amaçla piksellerin her dalga boyu için sensöre ulaşan radyansı ile Planck siyah cisim ışıma eğrisi arasındaki fark alınarak hata hesaplanmış ve Şekil 3.7’de gösterilmiştir. Burada tank hedeflerinin 10.4 μm - 11.0 μm ve 8.2 μm ve 8.7 μm aralıklarında Planck eğrisinden diğer materyallere göre daha çok sapmaya uğradıkları görülmektedir. Böylece bu dalga boyu aralıklarının hedefler için daha ayırt edici öznitelikleri barındırdığı değerlendirilmektedir. Bölüm 5.12.’de, özniteliklere ağırlık atayan harici bir sınıflandırıcı ile özyinelemeli olarak daha küçük öznitelik kümelerini göz önünde bulundurarak belirli özniteliklerin seçilmesini sağlayan RFE yöntemi ve öznitelik seçim sürecini herhangi bir eşiği otomatik olarak belirleyerek veri kümesindeki en anlamlı öznitelikleri bulmakta kullanılan Boruta yöntemi ile yapılan bant seçim çalışmalarında da hedeflerin 8.17 μm - 8.85 μm ve 10.3 μm - 11.4 μm bant aralıklarında daha ayırt edici oldukları görülmüştür.




Şekil 3.7 Nesnelerin Planck siyah cisim ışıma eğrilerinden sapmaları

Sıcaklık haritaları oluşturulduktan sonra gün içerisindeki örnekleme sıklığına bağlı olarak, belirli periyotta toplanan parlaklık sıcaklığı haritaları birleştirilerek parlaklık sıcaklığı küpleri oluşturulmuştur. Gün içerisinde seçilen K tane sıcaklık haritası N uzamsal yükseklik, M ise uzamsal genişliği ifade edecek şekilde birleştirilerek $N \times M \times K$ boyutta parlaklık sıcaklığı küpleri elde edilmiştir.

3.4. Sahne Transfer Yöntemi Kullanılarak Hedef Tespiti

Materyallerin farklı hava koşullarında değişkenlik gösteren spektral davranışları tespit edilmelerini zorlaştırmaktadır. Bölüm 5.5.'te görüldüğü gibi cisimlerin spektral imzaları hava koşullarına göre değişmektedir. Özellikle günün saat 00:00 ve 03:00 gibi gece bölümlerinde hedeflerin spektral imzaları arka planla benzeşmekte ve ayırt edicilikleri oldukça düşmektedir. Bu bölümde değişen hava koşullarının tespit performansına olan olumsuz etkilerini azaltabilmek için sahne transfer yöntemi önerilmiştir. Öncelikle hedeflerin ayırt ediciliklerinin yüksek olduğu bir zaman aralığı belirlenmiştir. Test edilecek sahne, tespit edilebilirliği daha yüksek olan önceden belirlenmiş bir sahneye, sahneye transfer yöntemi ile dönüştürülmüş ve üzerinde hedef tespit çalışmaları yapılmıştır.

Sahne transfer yöntemi, Pix2pix modeli [83] temel alınarak oluşturulmuştur. Her hava koşulundaki LWIR HSG, tespit edilebilirliği daha yüksek bir görüntüye çevrilmiş, sonrasında transfer edilmiş görüntü üzerinde hedef tespiti gerçekleştirilmektedir. Şekil 3.8'te mimari şeması gösterilmektedir.



Şekil 3.8 Sahne transfer yöntemi

Bölüm 2.3.5.9.'da anlatıldığı gibi Şekil 3.9'da gösterilen üretici ağ, eğitim verisi ile aynı dağılımda veriler üretebilmesi için eğitilmektedir. Benzer şekilde Şekil 3.10'da gösterilen ayırıştırıcı ağ ise üretilen görüntünün kalitesinin gerçeğe yakın olabilmesi için gerçek-sahte

ayrımını öğrenmektedir. Bu şekilde bir öğretmen gibi davranarak üretici ağı iyileşmesini sağlamaktadır.

Baz alınan Pix2pix çalışmasında görüntüden görüntüye transferi görünür bölge RGB görüntülerinde yapılmaktadır. Fakat HSG'lerin spektral çözünürlüğünün RGB görüntülerden farklı olması model üzerinde değişiklik yapılmasını zorunlu kılmıştır. Modelin girdi görüntü çözünürlüğü 128x128 uzamsal ve 108 spektral boyutlu olmak üzere düzenlenmiş, 128x128x108 görüntüler kullanılarak eğitimler gerçekleştirilmiştir.

Çalışmamızda modelin girdi görüntü çözünürlüğü 128x128 olarak belirlenmiş ve her HSG'den rastgele kesim alarak eğitim yapılmıştır. Bunun sebebi eğitim sahnesi ile transfer sahnesi hep aynı olduğu için model tek bir görüntü üretmeyi öğrenmekte ve böylece üretici ağların genel sorunu olan mod çöküşü (mode collapse) sorunu ortaya çıkmaktadır. Bu sorunu çözmek için eğitim sırasında her görüntü rastgele olarak 128x128 kesilmekte ve transfer edilecek görüntü bu belirlenen noktalardan kesilerek referans görüntü oluşturulmaktadır. Ayrıca eğitime katılan her görüntü $[-1,1]$ aralığına normalize edilmiş ve istatistiki olarak belirli bir rastgelelik katılarak döndürülmüştür.

Üretici ağına verilen girdi görüntüleri aşağıdaki sıralama ile işlenmektedir.

- Görüntülerden rastgele bölgelerinden 128x128 kesit alınması.
- Alınan kesitlerin rastgele döndürülmesi.
- Elde edilen görüntünün $[-1,1]$ aralığına normalize edilmesi.


Belirtilen adımlar eğitim sırasında hem transfer edilecek görüntüler hem de hedef görüntüler için yapılmaktadır. Transfer görüntüleri günün her saatinden alınmış görüntülerden, hedef görüntüler ise veri kümelerinde 20°C derece hava sıcaklığında alınan HSG'lerden seçilmiştir.

Üretici ağı Bölüm 2.3.5.9.'da anlatıldığı gibi U-Net [117] modelinin düzenlenmiş halidir. Giriş görüntü boyutu ve spektral çözünürlüğü 128x128x108 yapılmış ve hiperspektral görüntüler üretilmiştir. U-Net modelinde kodlayıcı ve kod çözücü dalları ve bu dallar

arasında atlamalar bulunmakta, görüntülerin öznitelikleri çıkarılmaktadır. Kullandığımız yapıda Şekil 3.9’da gözüktüğü gibi görüntü kodlayıcı kısmında bulunan evrişim bloğunda sırasıyla;

- 2-Boyutlu Evrişim (Conv2D - her bant için 2 boyutlu evrişim),
- Grup Normalizasyonu ve
- Sızıntılı ReLU yapıları bulunmaktadır.






Şekil 3.9 Üretici ağ

Bunun paralelinde bulunan kod çözücü yapısında ise Şekil 3.10'da gösterildiği gibi;

- Tersine 2-Boyutlu evrişim (Conv2DTranspose - her bant için iki boyutlu tersine evrişim),
- Grup Normalizasyonu,
- Dropout ve
- ReLU bulunmaktadır.



Şekil 3.10 Ayrıştırıcı ağ

Pix2pix çalışmasında olduğu gibi üretici ağı ve ayrıştırıcı ağı kayıp fonksiyonları değiştirilmemiştir. Üretici ağı eğitiminde üretici ağ kaybı (GL), sigmoid çapraz entropi kaybı (SCE) ve L1 kaybı (L1) kullanılarak Denklem 22’de gösterildiği gibi hesaplanmıştır.

$$GL = SCE + 100 * L1 \quad (22)$$

Denklem 22’de görülen SCE, üretilmiş resimler ile 1’lerden oluşturulmuş aynı boyuttaki resim arasında, L1 ise üretilen resim ile hedef resim arasında hesaplanmıştır. Görüntü üretiminde hedef görüntüsündeki gibi yapının korunması bu şekilde sağlanabilmektedir [83].

$$DL = SCE(1G, HG) + SCE(SG, \ddot{U}G) \quad (23)$$

Ayrıştırıcı ağ mimarisinde PatchGan [118] çalışması kullanılmıştır. Mimari Şekil 3.10’da gösterildiği gibi olup, yine iki farklı kayıp fonksiyonun toplamı kullanılarak ayrıştırıcı ağ kaybı (DL) hesaplanmıştır. Üretici ağında olduğu gibi, gerçek görüntü (HG) ile 1’lerden oluşturulmuş aynı boyuttaki görüntü (BG) arasında SCE hesaplanmış, aynı zamanda bu kayıp fonksiyonu ile üretilmiş görüntü (ÜG) ile 0’lardan oluşturulmuş görüntü (SG) arasında kayıp hesaplanarak birbirleri ile Denklem 23’te görüldüğü gibi toplanmıştır.

Sahne transferi çalışması neticesinde hem uzamsal hem de spektral olarak tutarlı örnek üretimi gerçekleştirilebilmiş olup sonuçlar Bölüm 5.7.’de gösterilmektedir.


3.5. Uzun Kısa-Süreli Hafıza ile Hedef Tespiti

Zaman serisi sınıflandırması, veri kümesindeki zaman serisi halinde sıralanmış verilerin kategorize edilmesi için kullanılan bir sınıflandırma problemidir. Bu problemin çözümünde kullanılan yöntemler seri halindeki verileri modelleyerek sınıflandırmaktadır. HSG sınıflandırma çalışmalarında da zaman serisi sınıflandırma problemine benzer bir şekilde cisimlerin spektral bilgileri ayırt edici olarak kullanılmaktadır. Buradan yola çıkarak bu

bölümde HSG'lerdeki cisimlerin spektral bilgileri zaman serisi modelleri arasından LSTM [119] modeli kullanılarak sınıflandırma yapılmıştır.

LSTM modülleri kullanılarak oluşturulmuş model ile 108 bant HSG'ler kullanılarak eğitilmiş ve bu modellerle testler yapılmıştır. LSTM modülü kullanılarak Şekil 3.11'de görünen mimari oluşturulmuş, her spektral banda bir zaman basamağı gibi davranılmıştır. Bu şekilde bir cismin spektral imzası 108 adet zaman basamağı şeklinde modele beslenmiş ve iki adet LSTM katmanı ile öznitelikleri öğrenilmiştir. LSTM katmanı çıktıları düzleştirilerek vektör haline getirilmiş ve sonrasında tamamen bağlı katman aracılığı ile sınıf tahminleri yapılmıştır. Burada sınıf tahminleri yapılırken tanh aktivasyon fonksiyonu kullanılmış ve 5 sınıf üzerinden eğitim yapılmıştır. Model eğitimleri için kalibrasyon sırasında bozulan görüntüler kullanılmamış, gün içerisinde belirli sorunsuz görüntüler seçilmiştir. Eğitim detayları Bölüm 5.8.'de anlatılmıştır.


Bu yapının LWIR HSG sınıflandırma probleminde en iyi sonuçları verdiği görülmüştür. Şekil 3.11'de model mimarisi gösterilmektedir. $G_0, G_1, ..G_N$ modele girdi olarak beslenmekte olan verileri ifade etmektedir. N HSG'nin spektral boyutunu ifade etmektedir. Modele verilen girdiler yeşil renkle kutucuklar içerisinde A harfi ile belirtilmiş LSTM modüllerine gönderilmektedir. LSTM modüllerinden 64 boyutlu çıktı alınmakla birlikte iç yapısı Şekil 2.21'de gösterilmiştir. Ardışık iki adet LSTM modülünün çıktıları düzeltirme katmanına oradan da tamamen bağlı katmana (FCL) gönderilmektedir. FCL katmanının 64 boyutlu girişi, her sınıf için birer tahmin olacak şekilde *softmax* fonksiyonundan geçirilerek nihai tahminler üretilmektedir.




Şekil 3.11 LSTM modülleri birleşimi ile elde edilen HSG sınıflandırıcı yapısı

3.6. Zamansal LWIR HSG üzerinde Hedef Tespiti

Bölüm 2.1.'de anlatıldığı üzere sıcaklık değiştikçe materyallerin spektral imzaları farklılaşırken, aynı şekilde sıcaklık değişimlerine gösterdikleri tepkiler de farklılık göstermektedir. Şekil 3.12(a)'da görüleceği gibi toprak ve hava sıcaklığı gün içerisinde sinüs sinyaline benzer şekilde artıp azalmaktadır. Metallerin ısı değişimlerine gösterdiği tepki, toprak, çim, ağaç materyallerine göre daha hızlı gerçekleşmektedir. Bu özellik metallerin termal eylemsizliklerinin düşük olmasından kaynaklanmaktadır. Ayrıca ısı sığalarının yüksek olmasından dolayı sıcaklık değişim aralıkları da geniş olmaktadır.




(a) Cisimlerin iki günlük sıcaklık değişimleri (01-02.05.2013)



(b) Materyallerin spektrum standart sapmaları


Şekil 3.12 Zamansal LWIR HSG’lerde materyal spektrumlarının standart sapma ve ortalama değerleri

Cisimlerin ısınma ve soğuma profillerinin farklılığının radyans değerlerindeki etkisi Şekil 3.12(b)'de görülmektedir. Metalden oluşmuş insan yapımı maddelerin standart sapmalarının, ağaç toprak gibi nesnelere göre fazla olduğu görülmektedir. Standart sapma, materyalin her dalga boyundaki radyans değerinin gün içerisindeki değişiminin hesaplanması ile bulunmaktadır. 1 Mayıs tarihinin verileri kullanılmış olup her saat başı alınmış temiz HSG'ler baz alınmıştır. Şekil 3.13'de gösterilen radyans ortalamaları da standart sapmada izlenen yönetime benzer şekilde 1 Mayıs tarihinde alınan 24 adet HSG'deki her materyal için belirlenmiş noktalar için hesaplanmıştır. Belirlenen pikselin 24 farklı zamanda elde edilmiş 24 farklı radyans değerinin ortalaması alınmıştır.




Şekil 3.13 Materyallerin gün içindeki radyans ortalamaları

Bu bölümde, materyallerin ortam ısı değişimlerine gösterdikleri tepki hızlarının farklı olmasından yola çıkılarak zamansal hiperspektral küpler üzerinde hedef tespiti önerilmiştir. Gün içerisindeki örnekleme aralığı ve sıklığı değiştirilerek 1, 2, 4 ve 8 adet LWIR hiperspektral küplerin birleştirilmesi ile zamansal hiperspektral küpler elde edilmiştir. Şekil 3.14'te görüldüğü gibi ardışık olarak birleştirilerek elde edilen zamansal HSG'ler kullanılarak hedeflerin tespiti sağlanmıştır.




Şekil 3.14 Zamansal LWIR HSG örneği (4 HSG birleşimi)

Gün içerisinde belirli zaman aralıkları ile alınmış HSG'lerin birleştirilmesi ile hedef materyalleri spektrumlarının ayırt ediciliğinin artırılması hedeflenmektedir. Metallerin ısı kapasitelerinin yüksek olması, Şekil 3.12(a)'da görüldüğü gibi günün sıcak zamanlarında çevrelerine göre daha yüksek ve gecenin soğuk vakitlerinde de çevrelerine göre daha düşük sıcaklıklarda bulunmalarına sebep olmaktadır. Şekil 3.15'te zamansal HSG'lerdeki materyallerin radyans ortalama ve standart sapma değerleri gösterilmektedir. Zamansal LWIR HSG'lerde hedef materyallerin radyans ve standart sapma ortalamalarının diğer materyallere göre daha yüksek olduğu görülmektedir.



(a) Zamansal hiperspektral görüntülerdeki materyallerin dalga boylarındaki ortalama radyansları



(b) Zamansal hiperspektral görüntülerdeki materyallerin dalga boylarındaki standart sapmaları


Şekil 3.15 Zamansal LWIR HSG’lerde materyal spektrumlarının standart sapma ve ortalama değerleri

3.7. Deneysel Karşılaştırmalarda Kullanılan Derin Öğrenme Tabanlı Hedef Tespit Yöntemleri

HSG'ler hem uzamsal hem de spektral olarak sahip oldukları yoğun bilgi içerikleri sebebiyle derin öğrenme ağlarında sıklıkla kullanılmaktadırlar. Fakat bu modellerin genellikle VNIR ve NIR bölgelerinden elde edilmiş HSG'lerde eğitildiklerinden, LWIR bölgesindeki performansları bilinmemektedir. Bu çalışmada SpectralNET [16], HybridSN [17], Hamida [14], Lee [13], He [15] ve LSTM [119] çalışmalarının performansları LWIR Radyans verileri üzerinde incelenmiştir. Bu bölümde yapılan çalışmaların temel amacı modellerin performanslarını karşılaştırmaktır.

3.7.1. Bağlamsal Derin CNN ile Hiperspektral Sınıflandırma


Bağlamsal derin CNN tabanlı hiperspektral sınıflandırma [13] çalışmasında, Bölüm 3.7.'de belirtilen uzamsal ve spektral özniteliklerin birlikte kullanıldığı öznitelik çıkarıcı yapısı geliştirilmiştir. Bu çalışmada çok sayıda farklı ebatlarda üç boyutlu evrişimler uygulanarak aktivasyonlar elde edilmiştir. Aktivasyonlar sonrasında birleştirilerek uzamsal ve spektral özniteliklerin açığa çıkarılması hedeflenmiştir. Çıkarılan öznitelikler, FCL ağına sokularak sınıf sayısınca olasılık hesaplanması amaçlanmıştır.



Şekil 3.16 Lee ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [13]

3.7.2. Uzaktan Algılama Görüntü Sınıflandırmasına Üç Boyutlu Derin Öğrenme Yaklaşımı

Uzaktan algılama görüntü sınıflandırmasına üç boyutlu derin öğrenme yaklaşımı çalışmasında [14], Lee ve arkadaşlarının yaptığı çalışmada olduğu gibi uzamsal ve spektral bilgiden faydalanabilmek için üç boyutlu derin öğrenme yaklaşımı uygulanmıştır. Hiperspektral görüntü küpü öncelikle üç boyutlu evrişimsel filtrelerden geçirilerek uzamsal ve spektral öznitelikler çıkartılmıştır. Bu bilgiler bir boyutlu vektörler haline getirilerek tekrar üzerinde bir boyutlu evrişim işlemi uygulanarak doğrusal olmayan öznitelik öğreniminin artırılması hedeflenmiştir. Bir boyutlu evrişim işleminin sonuçları evrişimsel sinir ağı katmanlarının sonunda genellikle uygulandığı gibi FCL yapısına verilerek sınıf tahminleri elde edilmiştir.




Şekil 3.17 Hamida ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [14]

3.7.3. Hiperspektral Görüntü Sınıflandırması için Çok Ölçekli 3 Boyutlu Derin CNN

He ve arkadaşlarının çalışmasında [15] iki farklı katkı yapıldığından bahsedilmektedir. Üç boyutlu evrişim işleminin video analizinde olduğu gibi hiperspektral verilerde de kullanılabilir olduğundan bahsedilmiş ve iki boyutlu evrişim işlemlerine göre daha elverişli olduğuna değinilmiştir. İkinci olarak çok-ölçekli (multi-scale) üç boyutlu evrişim katmanları geliştirilmiştir. Şekil 3.18’de görüldüğü gibi tek bir katman içerisinde farklı boyutlarda evrişim işlemleri yapılmış ve birleştirilerek katman sayısı ile birlikte derinlik arttırılmıştır.

Çok ölçekli olmasının maksadı hedefin farklı boyutta yarattığı problemi çözebilmektir. Modelde kullanılan parametre sayısı ve diğer detaylara deneyler bölümünde değinilecektir.




Şekil 3.18 He ve arkadaşlarının kurduğu HSG sınıflandırıcı mimarisi [15]

3.7.4. SpectralNET: Hiperspektral Görüntü Sınıflandırması için Uzamsal-Spektral WaveletCNN

Üç boyutlu evrişim katmanları ile spektral ve uzamsal öznitelikler birlikte elde edilebilirken yüksek işlem gücü gerektirmekte, iki boyutlu evrişim sırasında ise spektral bilgiden yoksun kalmaktadır. Bu çalışmada iki boyutlu dalgacık CNN (2D Wavelet CNN) yapısı önerilerek üç boyutlu katmandan daha az işlem yükü gerektiren dalgacık dönüşümü katmanı kullanılmıştır. Dalgacık dönüşümünün [120] hiperspektral görüntülerde iyi bir öznitelik çıkarıcı olduğu görülmüştür [121].

Dalgacık dönüşümü, veriyi farklı frekans birimlerine ayırarak her birimin kendi çözünürlüğünde çalıştığı bir fonksiyondur. Sinyal bir kısım temel fonksiyonlara ayrılmakta


ve bu fonksiyonlara dalgacıklar denilmektedir. Görüntü sıkıştırma uygulamalarında da kullanılan bu yöntem verilerin iyi bir temsili olmaktadır.



Şekil 3.19 SpectralNET HSG sınıflandırıcı mimarisi [16]

3.7.5. HybridSN: Hiperspektral Görüntü Sınıflandırması için 3D-2D CNN Özellik Hiyerarşisini Keşfetme

Bu çalışmada önerilen Hibrid Spektral Evrişimsel Sinir Ağları (HybridSN) modeli sıralı şekilde üç boyutlu evrişim ve iki boyutlu evrişim katmanları kullanarak önce uzamsal spektral özniteliklerin çıkarılmasını ve sonrasında uzamsal olarak işlenmesini amaçlamaktadır. Üç boyutlu CNN yapısı spektral ve uzamsal bilgi öğrenirken bunun çıktısını kullanan iki boyutlu CNN katmanı soyut seviyede uzamsal bilgi öğrenilmesini sağlamaktadır.



Şekil 3.20 HybridSN HSG sınıflandırıcı mimarisi [17]

4.UZUN DALGA BOYU HİPERSPEKTRAL GÖRÜNTÜ VERİ KÜMESİ


Hiperspektral görüntüleme, yüksek bilgi içeriğiyle piksel ve piksel kümeleri boyutlarında cisimleri tespit etme uygulamalarında önemli bir yer tutmaktadır. Araştırmacıların yoğun ilgisini çeken bu görüntüleme çeşidi maliyeti sebebiyle kolay erişilebilir değildir. Literatürde SWIR ve VNIR dalgaboylarında sıkça kullanılan Pavia Üniversitesi, Botswana, Salinas veri kümeleri gibi hiperspektral veri kümeleri bulunmasına rağmen, LWIR bölgede bulunan örnek sayısı oldukça azdır. Uzun dalga boyu görüntülemeye karşılaşılan temel zorluklardan birisi çevre ve hava koşullarının değişiminden oldukça etkilenen bir görüntüleme yöntemi olmasıdır. Bu sebeple farklı mevsim ve hava koşullarında toplanmış LWIR HSG veri kümesi, bu alanda yapılacak çalışmalar için oldukça yararlı olmaktadır. Bu çalışmada, birçok farklı hava koşullarından görüntü içeren, Bölüm 4.1.'de anlatılan SPICE veri kümesi kullanılmıştır.

4.1. SPICE Veri Kümesi

SPICE [19] veri kümesi, ABD Ordusu Araştırma Laboratuvarı (ARL), ABD Ordusu Silahlanma Araştırma, Geliştirme ve Mühendislik Merkezi (ARDEC) ve ABD Hava Kuvvetleri Teknoloji Enstitüsü (AFIT) araştırma gruplarının ortak çalışması ile toplanmıştır. Veri kümesinin oluşturulma amacı, farklı çevre koşullarında, birden fazla yılı kapsayan kapsamlı bir veri kümesi elde etmektir.

SPICE, 25 bine yakın LWIR hiperspektral görüntüden oluşan bir veri kümesidir. Amerika Birleşik Devletleri'nin kuzeydoğu bölgesinde bulunan görüntüleme bölgesine çeşitli cisimler yerleştirilmiş sahneden farklı hava koşullarında veri toplanmıştır. Bunlar arasından seçilen azınlıktaki gürültüsüz ve iyi kalibre edilmiş görüntüler bu çalışmada kullanılmaktadır.

Görüntüleme cihazı, 126 metre yükseklik ve hedef sahnesine 570 metre uzaklığa yerleştirilmiştir. ABD'nin kuzey doğu bölgesinde yapılan bu çalışmada, hafiften sağanağa kadar yağmurlu, hafiften yoğun sisli, aynı zamanda farklı bulutluluk, kar ve nem




Şekil 4.1 Görüntüleme alanı Google Haritalar görüntüsü [18]

koşullarında görüntüleme yapılmıştır. Bu hava koşullarının kaydedilebilmesi için hem kule hem de hedef sahne meteorolojik ölçüm cihazlarıyla donatılmış ve bu meteorolojik veriler görüntülerle birlikte kaydedilmiştir. Bu tezde kullanılan hava sıcaklığı, toprak sıcaklığı, nem gibi meteorolojik bilgiler hedef sahneye yerleştirilmiş meteorolojik ölçüm sensörlerinden elde edilmiş bilgilerdir [19, 122]. Bu bilgiler her hiperspektral küpün yerleştirildiği **.hdf5** uzantılı dosyada başlık olarak bulunduğu gibi **excel** dosyasında da saklanmaktadır.


Sahne Şekil 4.2(a)'da gösterildiği üzere saat yönüyle 0° , 90° , and 135° açılarla yerleştirilmiş üç adet askeri araç, bir adet alüminyum tabaka bir adet de siyah tabaka bulunmaktadır. Bu sahneden 2012 senesi 7, 8 ve 9. ayları ve 2013 senesinin 4, 5 ve 10. aylarında elde edilmiştir. Bu çalışmada testler ve eğitimler çoğunlukla 2013 senesinin Mayıs ayında gerçekleştirilmiştir. 2013 verileri 224×300 uzamsal ve 165 spektral çözünürlüğe sahipken iken, 2012 verileri 256×320 uzamsal 165 spektral çözünürlüğe sahip olup spektral çözünürlük $7.4081 \mu\text{m}$ ve $12.4493 \mu\text{m}$ dalga boyu aralığından elde edilmektedir.



(a) SPICE sahne görüntüsü ve insan yapımı cisimler (İlkbahar) [19]



(b) SPICE sahne görüntüsü ve insan yapımı cisimler (Sonbahar)[48]




(c) Örnek sahne termal görüntüsü

Şekil 4.2 SPICE veri kümesi sahne örnekleri


LWIR Telops HyperCam Kamera ve Sahne Özellikleri	
Spektrum Aralığı	7.40 μm - 12.45 μm (165 Bant)
Uzamsal Çözünürlük	320x256, 300x224 ve 320x224
Ölçüm Mesafesi	549 m mesafe, 126 m yükseklik
Görüntüleme Tarihleri	Temmuz, Ağustos, Eylül 2012 ve Ocak, Nisan, Ekim 2013
Sahnedeki İnsan Yapımı Nesneler	0°, 90° ve 135° açılarla yerleştirilmiş askeri araçlar, Siyah Cisim, Alüminyum Plaka
Meteorolojik Ölçümler	Hava Sıcaklığı, Toprak Sıcaklığı, Toprak Su Basıncı, Bulutluluk Oranı, Nem, Güneşlenme Miktarı

Tablo 4.1 Hiperspektral kameranın özellikleri

Denetimli görüntü bölütleme yöntemleri hedef sahne üzerinde her piksel için bir sınıf tahmini yapmaya çalışan algoritmalar. Bu algoritmalar eğitim sırasında, eğitim yapılacak görüntüye ait, piksel bazında etiketlenmiş doğruluk haritalarına ihtiyaç duymaktadır. Bu çalışmada da piksel bazlı tahmin yapılmaya çalışıldığı için doğruluk haritasına ihtiyaç duyulmuş ve **MATLAB Image Labeler** uygulaması kullanılarak elle doğruluk haritası oluşturulmuştur. Şekil 4.3(a)'dan görüleceği üzere askeri araçlar, yol, arka plan, siyah cisim ve alüminyum plaka etiketlenmiştir.




(a) Etiketlenmiş sahne görüntüsü



(b) Etiketleme aracı

Şekil 4.3 Etiketlenmiş sahne ve etiketleme aracı


LWIR bölgeden algılanan görüntüler Kanadalı Telops firmasına ait LWIR Hyper-Cam cihazı kullanılarak alınmıştır. Soğutmalı kızılötesi dedektör içeren cihaz elektromanyetik spektrumun $7.48 \mu\text{m}$ ile $12.5 \mu\text{m}$ dalga boyu aralığında görüntüleme yapabilmektedir. Sahnede bulunan siyah cisim ve alüminyum tabaka sayesinde saatlik olarak sensörlerden gelen ham görüntü kalibre edilmektedir.



Şekil 4.4 Hiperspektral görüntülerin kalibrasyon kayıtları

Şekil 4.4'te görülen kalibrasyon sürecinde saatlik olarak sahnedeki siyah cisim kullanılarak aykırı piksel temizleme (bad pixel correction), hızlı fourier dönüşümü (FFT), 2 nokta kalibrasyonu yapılmaktadır. Aynı zamanda TES yöntemleri ile görüntü kalibre edilip radyometrik olarak doğrulanmakta ve sıcaklık, salıcılık değerleri kaydedilmektedir.


Şekil 4.5'de SPICE sahnesi ve sahnede bulunan bazı cisimlerin radyans spektrumları verilmektedir. Şeklin sağ üstünde belirtilen sınıfların rengine göre radyans değerlerine



Şekil 4.5 Sahne görüntüsü ve materyallerin radyansları [19]

bakıldığında 04:24 saatinde çekilmiş LWIR HSG’de materyallerin radyans spektrumlarının birbirlerinden ayırt edilemez hale geldiği görülmektedir.

Sensöre ulaşan radyansa etki eden faktörler arasında mesafe de bulunmaktadır. Sinyalin ortamla etkileşimi mesafe arttıkça artmaktadır. Bu durum da sinyalin gürültüye oranını düşürmektedir. Şekil 4.6’da üstteki grafikte yakın mesafeden alınan tank hedefinin spektral imzası, alttaki grafikte ise kuleden alınan HSG’deki tanklara ait spektral imzalar gösterilmektedir. Hedefin bulunduğu konuma göre spektral imzasının değiştiği gösterilmektedir.




Şekil 4.6 Cisimlerin spektral imzalarının mesafeye göre değişimi [19]

4.2. Veri Kümesinde Karşılaşılan Zorluklar


Her ne kadar veri kümesinin kalitesi yüksek olsa da, çekim şartları bazı zorlukları beraberinde getirebilmektedir. Denetimli yapay zeka modelleri eğitimlerinde görüntü ve görüntüye ait doğruluk haritasının etiketlerinin birebir örtüşmesi gerekmektedir. Özellikle üretici çekişmeli ağlarla yapılan eğitimlerde görüntüler birbirlerine transfer edilmeye çalışıldığı sırada gözlenen kaymalar, tutarlı transfer yapılmasını engellemektedir.

Şekil 4.7’de görüleceği üzere 2013 senesinin Mayıs ve Ekim ayında çekilmiş görüntüler arasında piksel kaymaları mevcuttur. Bu tip kaymaların her ay çekilmiş veriye özel olarak doğruluk haritası üretimi ile önüne geçilmiştir. Üretici ağlarla eğitimlerde ise her görüntü aynı gün içerisindeki belirlenen en ayırt edici sıcaklığa transfer edilmeye çalışılarak kayma bazlı yaşanan sorunlar önlenmeye çalışılmıştır.

Veri kümesinde karşılaşılan bir diğer problem ise, kalibrasyon ile ilgili olabileceğini düşündüğümüz parlama problemidir. Şekil 4.8’de 01.05.2013 tarihli ve 02.00 saatinde alınmış bir hiperspektral küp ortalaması görünmektedir. Şekil 4.8’e benzer olarak birçok günde her saat başında elde edilmiş görüntülerde bu problem bulunmaktadır. Sebebi bilinmemekle birlikte, saat başı yapılan kalibrasyon sırasında bir problem olmuş olabileceği düşünülmektedir.



Şekil 4.7 Farklı tarihlerde alınmış görüntülerdeki piksel kaymaları



2-point calibration of data
Mean Signal(Radiance)=16.0346
Mean Noise (Radiance)=0.130398
Mean SNR(radiance)=171.007
Mean Signal(brightness temperature)=58.5601
Mean Noise (brightness temperature)=0.662550
Mean SNR(brightness temperature)=160017.
Mean Signal(relative emissivity)=1.03956
Mean Noise (relative emissivity)=0.0106197
Mean SNR(relative emissivity)=61332.4
Time to run program=92.290000 sec

Şekil 4.8 Kalibrasyon sırasında bozulmuş görüntü ve kalibrasyon kayıtları



2-point calibration of data
Mean Signal(Radiance)=5.97610
Mean Noise (Radiance)=0.0611428
Mean SNR(radiance)=103.120
Mean Signal(brightness temperature)=2.11212
Mean Noise (brightness temperature)=0.490752
Mean SNR(brightness temperature)=594.748
Mean Signal(relative emissivity)=1.03125
Mean Noise (relative emissivity)=0.0114122
Mean SNR(relative emissivity)=97.2276
Time to run program=92.009000 sec

Şekil 4.9 Temiz görüntü ve kalibrasyon kayıtları

Şekil 4.8 ve Şekil 4.9'dan da görüleceği üzere aynı saat içerisinde alınmış iki görüntüden elde edilen salıcılık ve parlaklık sıcaklığı değerlerinde büyük farklılıklar bulunmaktadır. Şekil 4.8 hem görsel olarak anlam ifade etmemekle birlikte, parlaklık sıcaklığı SNR değeri de oldukça yüksek çıkmıştır.

5. DENEYLER ve GÖZLEMLER

5.1. Deneylerin Akışı

Bölüm 3.'te anlatılan hedef yeniden tespit yöntemleri bu bölümde incelenmiş ve yapılan deneylerin detay ve sonuçları paylaşılmıştır. Şekil 5.1'de turuncu ile boyalı kısımlar bu tezde önerilmiş yöntemler olup diğerleri mevcut hedef tespit yöntemleri kullanılarak yapılmış çalışmalardır.

Bölüm 5.2.'de deneylerin sonuçlarında kullanılmış değerlendirme metriklerinden bahsedilmiştir. Deneylerin sıralamasında ise imza tabanlı eşleştirme yöntemlerinde kullanılacak spektral imza seçimi için düzenlenen deneylerden Bölüm 5.3.'te bahsedilmiş, bu imza kullanılarak Bölüm 5.5.'te deneyler düzenlenmiştir. Bölüm 5.6.'da sahnenin parlaklık sıcaklığı bulunmuş ve gün içerisinde belirli bir örnekleme sıklığında bu sıcaklık haritaları birleştirilerek elde edilmiş sıcaklık profillerinde hedef tespiti gerçekleştirilmiştir.

Bölüm 5.7.'de ise hava koşullarının yarattığı performans düşüşlerini bertaraf edebilmek adına derin öğrenme tabanlı sahne transfer yöntemi önerilmiş, test sahnesi, referans imzası bilinen güne transfer edilerek hedef tespit çalışması yapılmıştır. Bölüm 5.8.'de HSG görüntülerin yüksek spektral çözünürlüğünden faydalanılarak derin öğrenme yöntemleri ile sekans modelleme yapılarak materyal karakteristiği öğrenilmeye çalışılmış ve hedef tespiti performansı incelenmiştir. Cisimlerin ısınma ve soğuma profillerinin farklılığından yola çıkarak Zamansal LWIR HSG verileri oluşturulmuş ve bu veriler ile Bölüm 5.9. ve Bölüm 5.10.'da hedef yeniden tespiti gerçekleştirilmiştir. Bölüm 5.11.'de ise Bölüm 3.7.'de anlatılan modellerin LWIR HSG'lerdeki performansları karşılaştırılmaktadır. Son olarak Bölüm 5.12.'de spektral bantların önem sırası belirlenmesiyle bant seçimi yaparak veya bant azaltma yöntemleri ile band sayısı düşürülmüş ve hedef tespitine etkileri incelenmiştir.

Tablo 5.1 Önerilen tespit yöntemleri diagramı

ÖNERİLEN HEDEF TESPİT YÖNTEMLERİ					
		VERİ ÇEŞİTLERİ			
TESPİT YÖNTEMLERİ		LWIR IŞINIM	PARLAKLIK SICAKLIĞI	ZAMANSAL LWIR IŞINIM	SALICILIK (Emissivity)
	ACE	[3, 47, 21]	[49, 21]	✓	
	MF		[32]		✓
	SAHNE TRANSFERİ	✓			
	LSTM	[17, 117]		✓	
	Derin Sinir Ağları	[1, 2, 3, 4, 5, 17]			

5.2. Değerlendirme Metrikleri

Hedef tespit performanslarını ölçmek, kullanılan modellerin koşullara bağlı performans değişimlerini gözlemlemek ve tespit yöntemlerini birbirleri ile karşılaştırabilmek için bazı değerlendirme kriterleri kullanılmaktadır. Bunlar şu şekildedir:

- **Duyarlılık ve doğruluk (precision and recall) eğrisi ve F1 skoru:** Duyarlılık, sahne üzerindeki hedeflerin ne kadarını bulduğumu, doğruluk ise bulduklarımın ne kadarının hedef olduğunu ifade eden metriklerdir. F1 skoru ise duyarlılık ve doğruluk değerlerinin harmonik ortalamaları ile elde edilen bir metriktir. Duyarlılık Doğruluk eğrileri değişen eşik değerlerine göre modelin performansını incelememizi sağlayan grafiklerdir.

$$Duyarlılık = \frac{TP}{TP + FP} \quad (24)$$

$$Doğruluk = \frac{TP}{TP + FN} \quad (25)$$


$$F1 = 2 * \frac{Duyarlılık * Doğruluk}{Duyarlılık + Doğruluk} \quad (26)$$

- **Kesinlik (Accuracy):** Toplam doğru tahminin yapılan tahmine oranı ile elde edilmektedir. Deneylerimizden de görüleceği üzere bu metrik eşit dağılmamış veri kümelerinde yanıltıcı olmaktadır. Örneğin sınıf dağılımları %98 arka plan ve %2 hedef pikseli olarak dağılan bir görüntüde bütün pikseller için arka plan tahmini yapıldığında kesinlik %98 gibi yüksek bir değer çıkacak fakat aslında hedeflerin doğru tahmin edilemediğini bizlere sunmamış olacaktır.
- **Alıcı Çalışma Karakteristiği Eğrisi (ROC) ve AUC (Eğri Altındaki Alan):** Tespit algoritmalarında bazı durumlarda farklı eşik değerlerinde modellerden farklı sonuçlar elde edilmektedir. Bu sebeble yöntemin farklı eşiklere göre karakteristiğini çıkarıp incelemek daha faydalı olmaktadır. Eğrinin y eksenini Doğru Pozitif Oranından (TPR), x eksenini ise Yanlış Pozitif Oranından (FPR) oluşmaktadır. Denklem 27’de doğru pozitif için TP , yanlış negatif için FN , doğru negatif için TN ve yanlış pozitif için FP kullanılmıştır.

$$TPR = \frac{TP}{TP + FN} \quad \text{ve} \quad FPR = \frac{FP}{FP + TN} \quad (27)$$

AUC değeri ise çizilen eğrinin altındaki alanın hesabı ile bulunur ve modelin sınıfları ne kadar iyi ayırt edebildiğini ifade eder. Ne kadar yüksekse model o kadar güvenilir denilebilmektedir.

- **Jaccard Skoru (IOU):** Jaccard indeksi veya Jaccard benzerlik katsayısı, Şekil 5.1’de gösterildiği gibi kesişme boyutunun iki etiket kümesinin birleşiminin boyutuna bölümü olarak tanımlanmaktadır.



Şekil 5.1 Jaccard indeksi gösterimi

- **Kappa Skoru** [123]: Etiketler arasındaki anlaşmayı ölçen bir istatistiki metriktir.


$$Kappa = \frac{p_0 - p_e}{1 - p_e} \quad (28)$$

Bu denklemde p_0 herhangi bir örneğe atanan etiket üzerindeki ampirik anlaşma olasılığını göstermektedir; p_e her iki etiketleyici de etiketleri rastgele atadığında beklenen olasılıktır.


5.3. Spektral İmza Seçimi

Gürültülü bantların elenmesi amacıyla küçük bir deney tertip edilmiştir. Şekil 5.2’de ACE eşleştirme yönteminin hiperspektral sahne üzerinde farklı dalga boyu sayılarına sahip küpler üzerindeki performansları gösterilmiştir. Şekil 5.2’de görülen ROC eğrisinden de görüleceği üzere gürültülü olduğu düşünülen bantların eksiltilmesi hedef tespit performansını düşürmemiş aksine güçlendirmiştir. Bu sebeple çalışmalarımızda 108 sayıda bant kullanılmıştır. Ayrıca Şekil 5.3’te görüldüğü gibi gürültülü bantların elenmesinin görüntü üzerindeki tuz ve biber (salt and pepper) gürültüsü gibi görünen gürültünün ortadan kalkmasını sağlamıştır.

Bahsedilen ısı transfer yöntemleri arasında radyasyon en baskın ısı transfer yöntemidir. Şekil 5.5 ve 5.7’de hedef sahnesinde bulunan hedef araçlarından alınan radyasyon spektral




Şekil 5.2 Bant sayısının azaltılmasının hedef tespitine etkisi




Şekil 5.3 Gürültülü bantlardan arındırılmış sahne görüntüsü (HSG spektral ortalaması)

imzaları verilmiştir. Cisim üzerinden farklı noktalardan alınan imzaların farklı olduğu görülmüş, bunların da sebebinin güneşlenme olduğu kanısına varılmıştır. Bu sebeple tez içerisinde hedeflerden referans imza alırken, güneşlenmeye daha müsait olan **tavan**


bölgesinden seçilmiştir. Şekil 5.4'te hedefler üzerinden imzalar güneşlenmeleri yüksek olan, tavanlarından alınmıştır. Şekil 5.5'te görüldüğü üzere spektral imzaları benzer davranış sergilemektedir.




Şekil 5.4 Hedeflerin tavanlarından referans imza alınan noktalar



Şekil 5.5 Hedeflerin tavanlarında belirlenmiş noktalardan alınan referans spektrumlar




Şekil 5.6 Hedeflerin ortalarından referans spektrum alınan noktalar



Şekil 5.7 Hedeflerin ortalarında belirlenmiş noktalardan alınan referans spektrumlar


Şekil 5.6'da spektral imzalar Belenoğlu ve arkadaşlarının [25] yaptığı çalışmada olduğu gibi cisimlerin ortasından alınmıştır. Güneşlenmelerinden ve konumlarından bağımsız olarak yapılmış olan bu imza alma yöntemi Şekil 5.7'de gösterildiği gibi imzalar arasında

farklılığa sebep olmakta ve tek imzayla bütün hedeflerin bulunma performanslarını olumsuz etkileyebilmektedir. Araç üzerinde gölgede kalmış bölgelerin daha az ısınması sebebiyle nispeten daha düşük radyasyon yaydıkları görülmektedir. Bu durum toprakla temas eden bölgeleri için de sıcaklık farklılığı açısından benzerdir.




Şekil 5.8 Hedef 1 üzerinde seçilmiş noktalar

Şekil 5.8’de görüldüğü gibi hedef üzerinden farklı noktalardan spektral imzalar alınmış ve Şekil 5.9’da gösterilmiştir. Güneşlenmenin daha fazla olduğu Yeşil, Mavi ve Turuncu noktaların benzer ve daha fazla radyasyon değerine sahip olduğu, gölgede kalmış noktaların daha az radyasyon yaydıkları görülmektedir. Benzer durum imzaların Şekil 5.10 ve Şekil 5.12’den alındığı Şekil 5.11 ve Şekil 5.13’te de vardır. Bütün hedeflerde güneşlenme açılarının dike yakın olan yüzeylerinden yayılan radyansların diğer yüzeylerden yayılanlara göre daha yüksek olduğu görülmektedir.




Şekil 5.9 Hedef 1 üzerinden seçilmiş noktaların spektrumları




Şekil 5.10 Hedef 2 üzerinde seçilmiş noktalar

Hedef üzerinde referans imza seçiminin performansa etkisini incelemek için 1 Mayıs tarihinde 00:12 saatinde alınan HSG'de görüntülenen hedeflerin Şekil 5.5 ve Şekil 5.6'da gösterilen tavan ve orta noktalarından referans spektral imzalar alınmış, bu imzalar aynı tarihin 04:12 saatinde alınmış LWIR HSG'de ACE eşleştirme yöntemi kullanılarak




Şekil 5.11 Hedef 2 üzerinden seçilmiş noktaların spektrumları




Şekil 5.12 Hedef 3 üzerinde seçilmiş noktalar

hedefin yeniden saptanması gerçekleştirilmiştir. Test sonucunda Şekil 5.14(b) ve Şekil 5.14(a)'da tavan noktalarından imza seçiminin orta noktalara göre daha iyi performans sağladığı gösterilmektedir. Buradan yola çıkarak tank 0 hedefinin tavanında belirtilen nokta referans olarak belirlenmiştir. Hedef üzerinde referans imza seçiminin performansa etkisini



Şekil 5.13 Hedef 3 üzerinden seçilmiş noktaların spektrumları

incelemek için 1 Mayıs tarihinde 00:12 saatinde alınan HSG’de görüntülenen hedeflerin Şekil 5.5 ve Şekil 5.6’da gösterilen tavan ve orta noktalarından referans spektral imzalar alınmış, bu imzalar aynı tarihin 04:12 saatinde alınmış LWIR HSG’de ACE eşleştirme yöntemi kullanılarak hedefin yeniden saptanması gerçekleştirilmiştir. Test sonucunda Şekil 5.14(b) ve Şekil 5.14(a)’da tavan noktalarından imza seçiminin orta noktalara göre daha iyi performans sağladığı gösterilmektedir. Buradan yola çıkarak tank 0 hedefinin tavanında belirtilen nokta referans olarak belirlenmiştir.



(a) Saat 04:12 LWIR HSG test sonucu


(b) Saat 20:12 LWIR HSG test sonucu

Şekil 5.14 Referans imza seçiminin tespit performansına etkisi

5.4. İmza Tabanlı Eşleştirme Yöntemleri ile Salıclık Verisi Üzerinde Hedef Tespiti


Bu bölümde Bölüm 3.1.'de anlatılan yöntem ile radyans verisinden elde edilen salıclık verisi üzerinde hedef tespit çalışmaları gerçekleştirilmiştir. Bölüm 2.2.'de anlatılan eşleştirme yöntemlerinden Uyum Filtresi (MF) kullanılmıştır. Yapılan testlerde 1 Mayıs tarihinde 00:00, 06:00, 12:00 ve 18:00 saatlerinde alınan HSG'lerden elde edilen referans hedef salıclık imzaları kullanılarak, 2, 3, 4, 5, 14, 15, 16, 18 Mayıs tarihlerinin aynı saatlerinde alınmış HSG'ler üzerinde imza tabanlı hedef tespit çalışması gerçekleştirilmiştir.

Sıcaklık-salıclık dönüşümü neticesinde elde edilen materyal salıclık imzaları Şekil 5.15'te gösterilmektedir. Burada tank hedeflerinin salıclık spektrumlarının birbirlerinin aynısı olmadığı ama yakın çıktığı görülmektedir. Ayrıca alüminyum plakanın salıclık değerinin sıfır olmamasından dolayı mükemmel yansıtıcı olmadığı sonucu elde edilmiştir.



Şekil 5.15 Salıcılık dönüşümü sonucunda elde edilen materyal salıcılık spektrumları

Şekil 5.16'da gösterilen grafikte, test günlerinde elde edilen sonuçların ortalaması gösterilmektedir. 1 Mayıs tarihinde belirlenen saatlerde alınan HSG'ler üzerindeki Tank1'den alınan imza test günlerinde kullanılarak yine Tank1 hedefinin bulunması amaçlanmıştır. Salıcılık spektrumları kullanılarak yapılan testlerde hedef tespit başarımının radyans imzası kullanılarak yapılan testlere göre bir miktar iyileştiği görülmektedir.



Şekil 5.16 Salıcılık spektrumları kullanılarak yapılan hedef tespit sonuçları

Test sonuçlarının görselleştirilmesi Şekil 5.17’de gösterilmiştir. Burada test HSG’lerinde eşleştirme yöntemi ile elde edilen skorların ortalamaları gösterilmektedir. Beyazdan siyaha geçiş en yüksek skordan en düşük skoru temsil etmektedir. Şekil 5.17’den sadece Tank1 hedefinin salıcılık imzası kullanılarak elde edilen sonuçlarda, Tank 1 yanında diğer tankların da ayırt edilebilir olduğu görülmektedir. Ayrıca Tank1 hedefi, 06:00 saatinde yapılan testlerin haricindeki test saatlerinde en yüksek skor alınan bölge olmaktadır.

Radyans verisi sonuçları (Test günleri saat 00:00)



Salıcılık verisi sonuçları (Test günleri saat 00:00)



Radyans verisi sonuçları (Test günleri saat 06:00)



Salıcılık verisi sonuçları (Test günleri saat 06:00)



Radyans verisi sonuçları (Test günleri saat 12:00)



Salıcılık verisi sonuçları (Test günleri saat 12:00)



Radyans verisi sonuçları (Test günleri saat 18:00)



Salıcılık verisi sonuçları (Test günleri saat 18:00)




Şekil 5.17 Salıcılık ve radyans imzaları kullanılarak yapılan testlerin görselleştirilmesi

5.5. İmza Tabanlı Eşleştirme Yöntemleri ile Radyans Verisi Üzerinde Hedef Tespiti


Bölüm 2.2.' de anlatılan eşleştirme yöntemlerinden ACE kullanılarak hedef yeniden tespiti çalışmaları yapılmıştır. Hedeften alınan referans imza, Bölüm 4.1.'de bahsedilen test kümesi içerisindeki bütün görüntülerde aratılmış ve elde edilen tespit sonuçları incelenmiştir. Bölüm 5.3.'te eşleştirme yöntemlerinde referans olarak kullanılacak spektranın hedefin hangi bölgesinden seçilmesi gerektiği deneyler yoluyla tespit edilmiş ve 0 derece açıyla yerleştirilmiş tank hedefinin tavanından alınan imza seçilmiştir. Bölüm 5.5.3.'de günün herhangi bir saatinde alınan bir referans imza ile günün geri kalan saatlerinde eşleştirme yöntemleri kullanılarak hedef tespit edilmeye çalışılmış ve performansı değerlendirilmiştir. Bölüm 5.5.1.'de referans spektrumun alındığı hava koşulu ile test zamanı hava koşulu farklılığının hedef tespiti üzerine etkisi değerlendirilmiştir. Bölüm 5.5.2.'de ise mevsim koşulları farklılığının hedef tespit performansına etkisi incelenmiştir.

5.5.1. Saat Farkının Hedef Tespitine Etkisi

1 Mayıs tarihinin her saatinden alınan referans imza, 2 Mayıs tarihinin her saatinde test edilmiş ve yeniden tespit edilebilirlikleri irdelenmiştir. Şekil 5.18 ve Şekil 5.19'dan görüleceği üzere yeniden tespit işlemi, referans imza ile aynı sıcaklıktaki görüntülerde en yüksek başarıyı göstermektedir. En düşüğü de yine sıcaklık farkının en yüksek olduğu görüntülere denk gelmektedir.



Şekil 5.18 11:58 referans imzası ile 2 Mayıs tarihindeki yeniden tespit performansı




Şekil 5.19 14:58 referans imzası ile 2 Mayıs tarihindeki yeniden tespit performansı

5.5.2. Mevsimsel Farklılıkların Hedef Tespitine Etkisi


Farklı mevsimler için yapılan çalışmada sırasıyla her mevsimden belirlenmiş günler için spektral imzalar, gün içerisindeki hiperspektral küplerin ortalaması alınarak günü temsil eden ortalama HSG oluşturulmuş ve bu diğer günlerde kullanılmıştır.

Şekil 5.20’de test sonuçları gösterilmiştir. Kış ve yaz günlerinden alınmış ortalama HSG’lerin daha başarılı olabildiği gözlenmiştir. Bu günlerde meydana gelen sınıf içi varyasyonun yüksek olmasının başarımlarını artıran bir faktör olabileceği düşünülmektedir.



Şekil 5.20 Farklı mevsimlerden alınan referans imzaların performansları: (a) Sonbahar; (b) Yaz; (c) İlkbahar; ve (d) Kış.

T1: 08.07.2012
T2: 01.08.2012
T3: 08.09.2012
T4: 24.01.2013
T5: 30.04.2013
T6: 20.05.2013




Şekil 5.21 Farklı mevsimlerde elde edilen meteorolojik veriler

Şekil 5.21’de SPICE veri kümesinin içerdiği meteorolojik verilerin farklı mevsimlerdeki grafikleri gösterilmektedir. Hava ve toprak sıcaklığının ocak ayında en düşük olduğu, buna paralel şekilde bulutluluk oranının da tutarlı bir şekilde en yüksek olduğu gösterilmektedir. Bulutluluk oranı ve hava sıcaklığının görüntüler üzerindeki etkisi piksel radyans ortalaması grafiğinden görülebilmektedir. Hava sıcaklığı düştükçe cisimler daha düşük enerji yayabilmektedir.

5.5.3. Gün Farkının Hedef Tespitine Etkisi


Referans olarak 1 Mayıs tarihinin 00:00 saatinden itibaren 3 er saat arayla seçilen ışınlım spektral imzaları 2-3-4-5-14-15-16-18 Mayıs tarihlerindeki aynı saatlerde test edilmiş ve sonuçları incelenmiştir. Şekil 5.22’de 00:00’dan alınan referans imza ertesi günlerde aratılmış ve hava sıcaklığının benzer olduğu ardışık günlerde yine benzer tespit



Şekil 5.22 Hava sıcaklığının hedef tespitine etkisi-referans imza 00:00

performansları göstermiştir. Fakat 3 - 4 Mayıs ve 15 - 16 Mayıs geçişlerinde dramatik sıcaklık değişimlerinin performans üzerindeki etkilerinin de gözle ayırt edici olduğu gözlenmiştir.

Şekil 5.23'te ise 08:57'den alınan örnek karşılaştırılması yapılmış, bu sefer hava sıcaklığı sabit olmasına rağmen performans sürekli düşmüş, nem yüzdesi incelendiğinde sürekli yükseldiği görülmüştür. Buradan yola çıkarak LWIR bölgede tespit yapılırken hava sıcaklığının yanı sıra nem yüzdesinin de önemli bir etken olduğu görülmektedir.



Şekil 5.23 Nemin hedef tespitine etkisi-referans imza 08:57

Şekil 5.24'te ise 14-15 Mayıs arasındaki 20:58 saatindeki geçişte performans düşüşü gözlenmiş ve neticesinde hava sıcaklığı, nem ve güneşlenmenin diğer günlere göre daha keskin olarak değiştiği görülmüştür. PIR, güneşlenmenin yoğunluğunu ölçebilen bir ölçüm aracı olup bizlere bulutluluk oranı hakkında da bilgi verebilmektedir. Bu gün için havadaki bulut oranının arttığı ve bu sebeple de performansın düştüğü düşünülebilir.



Şekil 5.24 Hava sıcaklığı, nem ve güneşlenme hedef yeniden tespitine etkisi


5.6. Parlaklık Sıcaklığı Verisi Üzerinde Hedef Tespiti

5.6.1. Tespit Algoritması ve Örnekleme Sıklığı Seçimi


LWIR HSG'ler üzerinde parlaklık sıcaklığı kestirimi Bölüm 3.3.'te aktarıldığı gibi yapılmakta ve her 3 boyutlu küp için 2 boyutlu sıcaklık haritası çıkarılmaktadır. Bölüm 2.1.'de aktarıldığı gibi cisimlerin sahip oldukları termal eylemsizlik, ısı sığası gibi özellikleri sebebiyle gün içerisindeki sıcaklık değişme hızları farklı olmakta ve bu da onları ayırt edici yapmaktadır. Bu sebeple elde edilen sıcaklık haritaları belirli zaman aralıklarında örneklenmiş ve birleştirilerek sıcaklık küpleri elde edilmiştir.

Öncelikle sıcaklık küplerinin boyutunu belirleyebilmek için 1 ve 2 Mayıs tarihinde her saat başı alınan LWIR HSG'lerin parlaklık sıcaklık haritaları oluşturulmuştur. Bu haritalar 0.25, 0.5, 1, 2, 3, 4, 6 saat aralıklarla olacak şekilde örneklenerek farklı boyutlarda sıcaklık küpleri elde edilmiştir. Referans sıcaklık profili 1 Mayıs'tan, test sıcaklık profili ise 2 Mayıs'tan alınacak şekilde farklı boyutlardaki sıcaklık küpleri ile imza tabanlı eşleştirme yöntemleri kullanarak hedef yeniden tespit çalışması yapılmıştır.


Şekil 5.25(a) ve Şekil 5.25(b)'den görüleceği üzere MF daha üstün performans göstermiş ve tercih sebebi olmuştur. Ayrıca Şekil 5.25(c) gösteriyor ki gün içerisinde 3'er veya 6'şar saat aralıkla örneklenmiş sıcaklık profili ile elde edilmiş sıcaklık küpü üzerinde çalışılması daha yüksek F1 skorları elde etmemizi sağlamaktadır. Hedefin yeniden saptanması testleri 6 saat aralıkla örnekleme ile elde edilmiş sıcaklık küpleri üzerinden gerçekleştirilmiştir.



(a) Uyum filtresi (MF) ile örnekleme sıklığı seçimi



(b) ACE ile örnekleme sıklığı seçimi




(c) MF ve ACE ROC eğrileri

Şekil 5.25 Etiketlenmiş sahne ve etiketleme aracı


5.6.2. Sıcaklık Profilleri ile Hedef Tespiti

Bu bölümde sıcaklık profilleri çıkarılmış günler üzerinde hedef yeniden tespitleri deneyleri yapılmıştır. 1 Mayıs tarihinin $N \times M \times 4$ (N genişlik, M yükseklik) boyutlu hedef sıcaklık profili, diğer günlerde aratılmış ve sonuçları Şekil 5.26'da gösterilmiştir. Genel itibariyle tatmin edici sonuçlar elde edilmiş olup en düşük performansların elde edildiği günler ilgi çekmektedir. Şekil 5.26'da gösterildiği gibi 3, 14, 15 ve 18 Mayıs tarihlerinde en düşük sonuçlar elde edildiği görülmüştür. Bunun sebebi 1 Mayıs tarihinde hava sıcaklığının saat 00:00'dan saat 06:00'a kadar düştüğü fakat düşük performanslı günlerde bu saatler aralığında sıcaklığın daha farklı değiştiği görülmüştür.


Hedef tespit sonuçlarının belirli bir eşiğin üzeridekileri 1, altındakileri 0 yapılmak üzere Şekil 5.27'de görselleştirilmiştir. Burada hedeflerle birlikte sahnedeki toprak ve alüminyum tabakanın da yanlış tahmin olarak dahil olduğu görülmektedir.



Şekil 5.26 Sıcaklık profilleri kullanılarak hedef tespit görselleştirmesi



(a) Doğruluk haritası




(b) Soldan sağa 2-3-4-5 ve 14-15-16-18 Mayıs tarihleri tespit sonuçları

Şekil 5.27 Doğruluk haritası ve test sonuçları görselleştirmeleri

5.7. Sahne Transfer Yöntemi Kullanılarak Hedef Tespiti


Bölüm 3.4.'de anlatılan sahne transfer yöntemi, değişen kava koşullarını referans seçilen görüntüdeki hava koşullarına geri çevirerek tespit performansını arttırmaya yönelik bir yöntem olarak önerilmiştir. Adapte edilmiş PIX2PIX GAN mimarisi ile 128x128x108 boyutlu HSG'ler transfer edilmiş ve transfer edilen sahne üzerinde tespit çalışması yapılmıştır. Model eğitimi yapılırken Adam optimizasyon yöntemi kullanılmış, öğrenme hızı 0.0002 olarak belirlenmiştir. Eğitim 50000 basamakta tamamlanmıştır. Model eğitimi 11th Gen Intel(R) Core(TM) i5-11400F @ 2.60GHz işlemci, 16GB RAM, 8GB NVIDIA RTX 3060 GPU özelliklerine sahip bilgisayarda yapılmıştır.

Şekil 5.28'de sahne transfer örnekleri gösterilmiştir. HSG'ler spektral ortalamaları alınarak görselleştirilmiştir. Test görüntüsü 02.05.2013 tarihinde saat 00:12 tarihinde alınmış olup, referans görüntü 01.05.2013 tarihinin hava sıcaklığının 20°C olduğu 15:12 saatinde alınan



Şekil 5.28 Test sahnesinin referans sahneye dönüştürülmesi örnekleri


görüntü seçilmiştir. Meteorolojik koşullar sebebiyle gözle bile ayırt edilemeyecek durumda olan hedefler en soldaki sütunda test sahnesinde gösterilmektedir. Spektral imzanın alındığı referans sahne orta sütunda bulunmakla birlikte en sağda da sahne transfer edilmiş hali bulunmaktadır. Salıcılığı ve radyansı arka planla karışımının maksimum olduğu test sahnesi görüntüsünden, kontrastı artmış ve ayırt edilebilir hale gelmiş görüntüye dönüşüm tespit edilebilirliği de artırmaktadır.




Şekil 5.29 Hedeye ait referans, test ve transfer spektral imzaları

Şekil 5.29’da test, referans ve transfer edilmiş sahnenin hedef piksel spektrumları gösterilmiştir. Görüldüğü gibi imza test imzası transfer edilince referans imzaya benzemiştir. Bu durumun tespit performansına etkisini gözlemleyebilmek adına Bölüm 3.7.3.’te anlatılan yöntem kullanılarak transfer edilmiş ve edilmemiş test sahnesi üzerinde hedef tespit çalışmaları gerçekleştirilmiştir.

Şekil 5.30’da test görüntüsü ve transfer edilmiş test görüntüsü çiftleri gösterilmektedir. Günün 03:00, 06:00 ve 21:00 saatlerinde alınan LWIR HSG’lerde hedefler net bir şekilde gözükmemekle birlikte sahne transferi ile transfer edilen görüntülerde hedeflerin netlik kazandığı görülmektedir. Önerilen sahne transferi yönteminin tespit performansına etkisini gözlemleyebilmek için Bölüm 3.7.3.’de anlatılan hedef tespit yöntemi uygulanmıştır. Sahne transferinin hedef tespit performansına etkisi 5.31’de gösterilmiştir. Hedeflerin gözle ayırt edilmesinin güç olduğu 03:00, 06:00 ve 21:00 saatlerinde alınan LWIR HSG’lerin transfer edilmesi ile hem görsel açıdan hedefler belirginleştirilmiş hem de tespit yönteminin performansı iyileşmiştir.



Şekil 5.30 Sahne transferi ile hedef tespit performansının iyileştirilmesi çalışmasında kullanılan test görüntüleri ve transfer edilmiş test görüntüleri.




Şekil 5.31 He [15] çalışmasının test görüntüsü ve transfer edilmiş test görüntüsü üzerindeki hedef tespit performansı.

5.8. Uzun Kısa-Süreli Hafıza Tabanlı Model ile Hedef Tespiti


Bölüm 3.5.'te anlatılan LSTM yöntemi ile hedef yeniden tespiti çalışmaları 1 Mayıs tarihi eğitim, 2, 3, 4, 5, 14, 15, 16 ve 18 Mayıs tarihleri test günleri olmak üzere testler gerçekleştirilmiştir. Bu model eğitimi için 1 Mayıs tarihinde çekilen saat başı görüntüler kullanılmış olup testler için belirlenen günlerin 00:00'dan itibaren 3'er saat arayla elde edilmiş görüntüleri kullanılmıştır. Model eğitimi sırasında öğrenim hızı 0.001 olarak seçilmiş, 5 basamakta (epoch) eğitim tamamlanmıştır.

5.8.1. Günlük Örnekleme Sıklığının Eğitim Performansına Etkisi


Bilindiği üzere veri kümesi büyüklüğünün derin öğrenme modellerinin performansına etkisi yüksektir. Veri kümesinin içerdiği görüntülerin miktarı ve çeşitliliği, bu verilerle




(a) 24 HSG ile eğitilmiş modelin belirli saatlerdeki sonuçları



(b) 12 HSG ile eğitilmiş modelin belirli saatlerdeki sonuçları



(c) 6 HSG ile eğitilmiş modelin belirli saatlerdeki sonuçları




(d) 3 HSG ile eğitilmiş modelin belirli saatlerdeki sonuçları


Şekil 5.32 Farklı sayıda HSG ile eğitilen modellerin belirli saatlerdeki performansları

eğitilen modelin sınıflandırma performansını artırmaktadır. Buradan yola çıkarak LSTM modülü ile kurulmuş mimari ile yapılan eğitimlerde farklı miktarda HSG kullanılarak, veri sayısının tespit performansına etkisi irdelenmiştir. Şekil 5.32’de 1 Mayıs 2013 tarihinde alınan 24, 12, 6 ve 3 HSG kullanılarak eğitilmiş modellerin 2 Mayıs 2013 tarihindeki saat bazlı performansları gösterilmektedir. Eğitim verisi arttıkça performans artarken, 3 HSG kullanılarak eğitilmiş modelin sonuçlarının tatmin edici olmadığı Şekil 5.33’te gösterilmektedir.


Şekil 5.32’de görüldüğü gibi saat başı toplanmış veriler ile yapılan eğitimde ertesi gün testlerinde AUC değeri en yüksek 12:00’da 0.976, en düşük 21:00’da 0.904 ve ortalama




(a) 24 HSG ile eğitilmiş model ortalama sonucu



(b) 12 HSG ile eğitilmiş model ortalama sonucu



(c) 6 HSG ile eğitilmiş model ortalama sonucu




(d) 3 HSG ile eğitilmiş model ortalama sonucu

Şekil 5.33 Farklı sayıda HSG ile eğitilen modellerin günlük ortalama performansları

olarak 0.938 elde edilmiştir. Gün içerisinde 6 saatte bir elde edilmiş 4 adet küp kullanılarak yapılmış eğitimlerde performansın oldukça düşük olduğu görülmüştür. Bunun sebebi olarak da eldeki verilerde hava koşulları ve sıcaklık farklılıklarının düşük olmasından dolayı modelin genel öznitelikler çıkarmayı öğrenemediği düşünülmektedir.

5.8.2. Gün Farkının Hedef Tespitine Etkisi


Saat başlarında edinilmiş 24 adet LWIR HSG kullanılarak eğitim yapılmış ve elde edilen model 02.05.2013 tarihi itibarıyla Şekil 5.35'te belirtilen tarihlerde gün içerisindeki 3'er saat aralıkla test edilmiştir. Sonuçları Şekil 5.34 ve Şekil 5.35'te gösterilmektedir. Model, imza tabanlı eşleştirme yöntemlerine paralel olarak 03:00'da en düşük performans göstermiştir. En iyi performans ise 12:00 ve 15:00 saatlerinde elde edilmiştir.



Şekil 5.34 01.05.2013 tarihinde saat başı alınan 24 adet HSG ile eğitilmiş LSTM modelinin 02.05.2013 alınan HSG’lerde test sonuçları

Gece performans düşükken 06:00’da görülen iyileşmenin sebebi gün doğumunda hava sıcaklığı değişimi ve cisimlerin karakteristik olarak gösterdikleri farklı hızlardaki tepkilerdir.

Bu testlerdeki bir diğer çıkarım ise en düşük performansın görüldüğü tarih olan 15 Mayıs tarihinin hava durumu olarak da en farklı gün olduğu görülmüştür. Benzer şekilde Bölüm 5.5.’te yapılan testlerde de Şekil 5.24’te de gösterildiği gibi performans düşüşü



Şekil 5.35 02.05.2013 tarihinde 24 adet küple eğitilmiş LSTM modeli ile farklı günlerdeki test sonuçları

görülmektedir. 4 Mayıs tarihinin performansının iyi olma sebebi de hava durumunun benzer olmasıdır.

Bölüm 5.2.'de bahsedilen metrik sonuçları Tablo 5.2'de gösterilmiştir. Buraya göre 02.05.2013 tarihi testlerinin en iyi sonucu 15:00 saatinde alınmıştır. Bu tabloda ilgi çeken nokta Bölüm 5.2.'de bahsettiğimiz Kesinlik Skoru'nun yanıltıcılığının bu tabloda bariz şekilde görülebilmesidir. Hedef başarıyla tespit edilememiş de olsa %98-99 gibi skorlar vermektedir.

Tablo 5.2 01.05.2013 tarihinde 24 adet küple eğitilmiş LSTM modeli ile farklı günlerdeki test sonuçları

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Doğruluk
00:00	0,60	0,68	0,35	0,98
03:00	0,51	0,54	0,73	0,98
06:00	0,73	0,82	0,64	0,99
09:00	0,61	0,70	0,39	0,98
12:00	0,72	0,81	0,62	0,99
15:00	0,81	0,88	0,76	0,99
18:00	0,64	0,72	0,45	0,99
21:00	0,65	0,73	0,46	0,99



5.9. Zamansal Hiperspektral Görüntüleri Kullanarak İmza Eşleştirme Yöntemleri ile Hedef Tespiti

Bölüm 3.6.'da bahsedilen yöntem kullanılarak farklı sıklıklarla seçilmiş HSGler birleştirilmiş ve cisimlerin spektralarının zamana bağlı değişimlerinden faydalanmak için birleştirilmiştir. Bölüm 5.9.1.'de hangi aralıklarla seçim yapılmasının daha faydalı olacağı, Bölüm 5.9.2.'de ise seçilen periyodla birleştirilmiş Zamansal LWIR HSG'lerin performansı incelenmiştir.

5.9.1. Örnekleme Sıklığı Seçimi

İmkanlar dahilinde gün içerisinde istenildiği kadar görüntü alınıp, çeşitli boyutlarda zamansal LWIR HSG'ler elde edilebilmektedir, fakat burada açığa çıkan sorun hangi sıklığın daha iyi performansı vereceğini belirlemek olarak açığa çıkmaktadır. Bu bölümde Gece 00:00 dan başlayarak farklı saat aralıklarında görüntüler birleştirilerek farklı boyutlarda görüntüler elde edilmiştir. Örneğin Şekil 5.36'da gösterilen 6 saat aralıkla örneklemede kullanılan veri büyüklüğü 00:00, 06:00, 12:00 ve 18:00 verilerinin birleştirilmesi ile elde edilmiş ve boyutu $108 \times 4 = 432$ banttır. Benzer şekilde 4 saat aralıkla örnekleme de 00:00, 04:00, 08:00, 12:00, 16:00, 20:00 verilerinin birleştirilmesi ile oluşturulmuştur.


Yapılan deneylerde 6 saat aralıkla örnekleme ile üretilmiş zamansal HSG üzerinde hedef tespiti diğer örnekleme sıklıklarına göre daha başarılı sonuçlar almamızı sağlamıştır. Bu sebeple Bölüm 5.9.2.'de 6 saat aralıkla örnekleme kullanılacaktır.




Şekil 5.36 Örnekleme sıklığının hedef tespit performansına etkisi

5.9.2. Referans ve Test Günleri Arasındaki Zaman Farkı Etkisi

Bölüm 5.9.1.'de belirlenen yöntemle hazırlanmış Zamansal HSG'ler üzerinde hedef tespiti yapılmış ve tespit performansları Şekil 5.38'de gösterilmiştir. En iyi sonuç ertesi günde alınırken Bölüm 5.5.3.'te olduğu gibi en düşük performans 15.05.2013 tarihinde alınmıştır. Buradan Zamansal LWIR HSG'lerde de hava durumunun performansa etkisi LWIR HSG'lere benzer şekilde olmaktadır.




Şekil 5.37 Zamansal LWIR HSG'ler üzerinde bütün hedeflerin yeniden tespiti sonuçları



Şekil 5.38 Zamansal LWIR HSG'ler üzerinde 0° hedefin yeniden tespit sonuçları

5.9.3. Gün İçerisindeki Sıcaklık Değişiminin Hedef Tespitine Etkisi

Zamansal LWIR HSG'lerin oluşturulmasında farklı anlardan alınmış LWIR HSG'ler kullanıldığı için her bir dizi elemanı üzerindeki hava durumu etkisi farklı olduğundan sıralamaları da tespit performansına etkili olmaktadır. Farklı aylardan alınmış Zamansal HSG'ler kullanılarak yapılan test sonuçları Şekil 5.39'da görülmektedir. İlkbaharda sonuçların en kötü olma sebebinin kış olarak belirtilen tarihte birleştirilerek oluşturulmuş Zamansal LWIR HSG'nin sıcaklık sıralaması yüksekte düşüğe farklı olması ve varyansının yüksek olması olarak yorumlanmıştır.



Şekil 5.39 Referans imza alındığı mevsimin yeniden tespit performansına etkisi


5.10. Zamansal Hiperspektral Görüntüleri kullanarak Derin Öğrenme ile Hedef Tespiti

Bölüm 3.6.'da cisimlerin materyal özellikleri neticesinde ısı değişim hızları ve miktarlarının farklı olduğundan bahsedilmişti. Bu bölümde bu yapıdan faydalanılarak zamansal HSG'ler üzerinde deneyler gerçekleştirilmiştir. Bölüm 3.5.'te anlatılan model, öncelikle 108, 216, 432 ve 864 bant uzunluğunda zamansal HSG'lere çevrilmiş, bunlara uygun sayılı girdi katmanları olan uzun kısa-süreli hafıza modelleri eğitilmiştir. 1 Mayıs günü Zamansal LWIR HSG'leri ile eğitilen modeller aynı gün ve ertesi gün verilerinde test edilmiş ve sonuçları ROC eğrisi değerlendirmesi yöntemi ile karşılaştırılmıştır. Bölüm 5.8.'de ise bu bölümde elde edilen en iyi sonucu veren modelle 2, 3, 4, 5, 14, 15, 16, 18 Mayıs 2013 tarihindeki gün içerisindeki belirlenen saatlerde test edilmiş ve test sonuçları eklenmiştir.


5.10.1. Örneklem Periyodunun Hedef Tespitine Etkisi

Şekil 3.14'da 432 spektral boyutlu Zamansal LWIR HSG örneği verilmiştir. Bu küp, gün içerisindeki 6 saat aralıklarla alınmış LWIR HSG'lerin ardışık olarak birleştirilmesi ile oluşturulmuştur. Eğitim sırasında 01.05.2013 tarihinde alınmış LWIR hiperspektral görüntüler ardışık 4'er saat olmak üzere birleştirilmiştir. Örneğin 00:00, 01:00, 02:00 ve 03:00 küpleri birleştirilerek tek küp elde edilmiş ve gün içerisinde çıkan 6 küp eğitimde kullanılmıştır. Aynı işlem 108, 216 , 432 ve 864 zamansal spektral boyuta ulaşacak şekilde tekrarlanmış ve aşağıdaki gibi sonuçlar elde edilmiştir.

Şekil 5.40(a)'da modellerin eğitim verileri üzerindeki test sonuçları verilmiş ve bu teste "Aşırı Uyum" testi ismi verilmiştir. Bunun sebebi modellerin eğitim verilerine ne kadar uyum sağladığını görmektir. Üçer saat arayla çekilerek alınmış HSG'lerin birleşimi ile elde edilen 864 (8*108) boyutlu Zamansal LWIR HSG ile eğitilen modelin en iyi performansı verdiği gözlenmektedir. Fakat aynı modeller 2 Mayıs tarihi için oluşturulan Zamansal LWIR HSG'ler üzerinde test edildiğinde performansın zamansal spektral uzunluk arttıkça düştüğü gözlenmektedir.




(a) Aşırı uyum testi



(b) Öğrenim testi

Şekil 5.40 Eğitilen modellerin eğitim günü ve ertesi gün verileri üzerindeki performansı: (a) Aşırı Uyum Testi; (b) Öğrenim Testi;


Buradan spektral boyut arttıkça çıkarılan özniteliğin performansı iyileştirdiği, fakat eğitim verisinin azalmasının performansı olumsuz etkilediği gözlemlenmektedir. 864 boyutlu Zamansal LWIR HSG 3 adet, 432 boyutlu 6 adet, 216 boyutlu 12 ve 108 boyutlu olan 24 adet bulunmakta ve bu sebeple veri dağılımı eşit olmamaktadır. 1 Mayıs tarihinde alınan 3 adet 864 boyutlu zamansal LWIR HSG kullanılarak eğitilen LSTM modelinin 2 Mayıs tarihinde alınan ve aynı zaman aralıkları kullanılarak oluşturulan zamansal LWIR HSG'lerdeki test sonuçları Şekil 5.41'de gösterilmektedir. Model eğitimi sırasında 00:00-07:00, 08:00-15:00 ve 16:00-23:00 saat aralıklarındaki verilerin birleştirilmesi ile oluşturulmuş zamansal HSG kullanılmıştır. Test sonucunda en düşük performansı 08:00-15:00 saat aralığında elde edilmiştir. Bu duruma 00:00-07:00 ve 16:00-23:00 zaman aralıklarının hava koşullarının, 08:00-15:00 zaman aralığının hava koşulundan farklı olduğu için modelin eğitiminde bu aralıktan daha az veri kullanılmasının sebep olduğu düşünülmektedir.



Şekil 5.41 Eğitim verisinin artırılmasının performansa etkisi (3 HSG ile eğitim)

Şekil 5.42'de 864 boyutlu zamansal LWIR HSG eğitim veri kümesinin genişletilmesinin model performansındaki değişimi gösterilmektedir. Bu çalışmada 1 Mayıs tarihinde alınan

Zamansal HSG üzerinde LSTM yöntemi ile hedef tespiti ROC eğrisi (864 bant)



Şekil 5.42 Eğitim verisinin artırılmasının performansa etkisi(11 HSG ile eğitim)

LWIR HSG'ler ardışık 8'er saat olmak üzere 11 farklı şekilde birleştirilerek veri kümesi büyütülerek LSTM modeli eğitilmiştir. Veri kümesinin büyütülmesi performansı olumlu etkilemiştir.

5.11. Derin Öğrenme Yöntemleri ile Hedef Tespiti

Bölüm 3.7.'de bahsedilen Derin öğrenme yöntemleri kullanılarak yapılan hedef tespit yöntemleri ile hedef yeniden tespitleri yapılmıştır. Modeller 1 Mayıs tarihinde alınmış 8 adet LWIR HSG kullanılarak eğitilmiş ve test edilmiştir.

5.11.1. Deney Hiperparametreleri

Derin öğrenme modelleri Bölüm 5.7.'de bahsedilen “11th Gen Intel(R) Core(TM) i5-11400F @ 2.60GHz” işlemci, 16GB RAM, 8GB NVIDIA RTX 3060 GPU özelliklerine sahip bilgisayarda eğitilmiş ve testleri yapılmıştır. Eğitim veri kümesi bütün modelleri için sabit tutulmuş ve 1 Mayıs tarihi olarak belirlenmiştir. 00:00 saatinden itibaren 3'er saat arayla alınmış LWIR HSG'ler eğitim verisi olarak kullanılmış, test kümesi ise 1 Mayıs dahil 2, 3, 4, 5, 14, 15, 16 Mayıs tarihlerinin gün içerisindeki yine 3'er saatlik zaman aralıkları ile toplanmış görüntülerden oluşturulmuştur. Bütün modeller 5 sınıflı olacak şekilde eğitilmiştir. Sınıflar şu şekildedir: Alüminyum Plaka, Tank, Siyah Cisim, Yol ve Arka Plan. Test sırasında ise sadece “Tank” hedefinin tespit performansı incelenmiştir.

Bölüm 3.7.1., 3.7.2. ve 3.7.3.'te yapılan eğitim sırasında spektral örnekler rastgele seçilmiş ve döndürme veri arttırım yöntemi uygulanmıştır. Bu modellerin eğitimleri 20 basamakta gerçekleştirilmiş, öğrenim hızı(learning rate) 0.0001 olarak belirlenmiştir. Sadece Bölüm 3.7.2. çalışması için kanal bazlı görüntü normalizasyon işlemi gerçekleştirilmiştir. Bu yöntemle 3 Boyutlu HSG'lerin her spektral bandı için normalizasyon yapılmış ve değerler [0,1] aralığına çekilmiştir.

Bölüm 3.7.5.'te anladılan modelin eğitimi sırasında parça boyutu 25 olarak belirlenmiş, görüntüdeki her piksel için yapılan eğitimde parça boyutunca uzamsal çözünürlükte alanda işlem yapılmıştır. Bu çalışmada HSG'lerin PCA ile boyutları azaltılmakta ve 15'e düşürülmektedir. Öğrenim hızı 0.0001, optimizasyon yöntemi ise Adam olarak belirlenmiştir. Eğitim 100 basamakta bitirilmiştir. Bölüm 3.7.4.'da anladılan modelde parça boyutu 16 seçilmiş, HSG'lerin spektral kanalı ise 3'e düşürülmüştür. Burada optimizasyon yöntemi olarak SGD seçilmiş ve model yine benzer şekilde 100 basamak eğitilmiştir.

5.11.2. Test Sonuçları

Derin öğrenme tabanlı modeller 1 Mayıs 2013 00:00'dan itibaren üçer saat arayla alınmış 8 adet LWIR HSG'ler ile eğitilmiştir. Modellerin hedef tespit performansları 2 Mayıs 2013 tarihinde aynı saatlerde alınmış LWIR HSG'lerde test edilmiştir. Tablo 5.3'de [13] çalışmasının sonuçları gösterilmektedir. Modelin tespit performansı 12:00 ve 15:00 saatlerinde en yüksek olmaktadır. Bu model, hedeflerin LWIR HSG'de görsel olarak ayırt edildiği saatlerde iyi çalışmaktadır. Fakat modelin hedef tespit performansı gece saatlerinde alınmış HSG'lerde düşük kalmaktadır.

Tablo 5.3 Bağlamsal derin CNN ile hiperspektral sınıflandırma

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Doğruluk
00:00	0.566	0.641	0.289	0.950
03:00	0.511	0.566	0.142	0.932
06:00	0.592	0.668	0.337	0.972
09:00	0.575	0.659	0.330	0.938
12:00	0.645	0.737	0.479	0.964
15:00	0.771	0.854	0.708	0.985
18:00	0.570	0.636	0.273	0.973
21:00	0.589	0.668	0.339	0.962

Tablo 5.4'teki sonuçlar incelendiğinde Tablo 5.3'tekine benzer sonuçlar elde edildiği görülmektedir. Hedeflerin sıcaklıklarının çevreye göre daha yüksek olduğu, termal görüntüde gözle ayırt edilebilir 12:00 ve 15:00 saatlerinde model performansı diğer saatlere göre yüksek çıkmaktadır. Hedefin yeniden tespiti günün 00:00 ve 09:00 saat aralıklarında düşük performansla gerçekleştirilebilmektedir.

Tablo 5.4 Uzaktan algılama görüntü sınıflandırmasına 3-boyutlu derin öğrenme yaklaşımı

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Accuracy
00:00	0.469	0.544	0.145	0.846
03:00	0.445	0.518	0.107	0.819
06:00	0.683	0.773	0.548	0.9798
09:00	0.620	0.709	0.423	0.9594
12:00	0.716	0.807	0.615	0.979
15:00	0.764	0.848	0.697	0.985
18:00	0.552	0.614	0.22	0.963
21:00	0.564	0.642	0.294	0.941

Tablo 5.5 Hiperspektral görüntü sınıflandırması için çok ölçekli 3 boyutlu derin CNN

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Doğruluk
00:00	0.424	0.503	0.099	0.782
03:00	0.400	0.483	0.084	0.743
06:00	0.484	0.562	0.174	0.859
09:00	0.517	0.596	0.22	0.894
12:00	0.198	0.296	0.020	0.379
15:00	0.407	0.491	0.09	0.750
18:00	0.315	0.411	0.047	0.596
21:00	0.314	0.409	0.047	0.593

SpektralNET modeli test sonuçları Tablo 5.6’da gösterilmektedir. Test sonuçları [13] ve [14] çalışmalarının gerisinde olduğu görülmektedir. SpektralNET çalışmasında olduğu gibi HSG’lerin spektral boyutları 108’den 3’e düşürülerek eğitim ve testler gerçekleştirilmiştir. Bu çalışmada, HSG’ler boyutları düşürülerek kullanıldığı için performansın düşük kaldığı düşünülmektedir.

Tablo 5.6 SpectralNET: Hiperspektral görüntü sınıflandırması için Uzamsal-Spektral WaveletCNN

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Doğruluk
00:00	0.522	0.572	0.147	0.953
03:00	0.504	0.545	0.094	0.946
06:00	0.545	0.597	0.195	0.974
09:00	0.576	0.643	0.28	0.978
12:00	0.591	0.664	0.329	0.976
15:00	0.531	0.573	0.147	0.976
18:00	0.529	0.569	0.14	0.977
21:00	0.503	0.522	0.04	0.978
15.05.2013-03:00	0.536	0.585	0.17	0.969
15.05.2013-15:00	0.531	0.573	0.14	0.976

Tablo 5.7 HybridSN: Hiperspektral görüntü sınıflandırması için 3D-2D CNN özellik hiyerarşisini keşfetme

Test Saati	Jaccard Skoru	F1 Skoru	Kappa	Doğruluk
00:00	0.521	0.553	0.112	0.982
03:00	0.517	0.547	0.098	0.979
06:00	0.610	0.688	0.377	0.984
09:00	0.526	0.564	0.131	0.979
12:00	0.520	0.552	0.110	0.981
15:00	0.639	0.726	0.453	0.976
18:00	0.585	0.655	0.311	0.980
21:00	0.504	0.521	0.051	0.981
15.05.2013-03:00	0.526	0.562	0.130	0.981
15.05.2013-15:00	0.527	0.563	0.131	0.981

Bölüm 5.11.2.'de elde edilen sonuçlar ve Bölüm 5.8.'de elde edilen sonuçlar birleştirilmiş ve karşılaştırılmıştır. Şekil 5.8 ve Şekil 5.9'da en yüksek skor yeşilden, en düşük skor kırmızıya doğru bir renk paleti kullanılmıştır. Şekil 5.8'de en sağ sütunda görüldüğü üzere imza tabanlı eşleştirme yöntemi ile en düşük performans alınmaktadır. LSTM modülü ile hemen hemen her saat aralığında en iyi performans elde edilmiştir. Buradan LWIR HSG sınıflandırma probleminde, sekans modelleme yöntemlerinin evrimsel modellere göre daha tercih edilebilir olduğu çıkarılmaktadır. Hem uzamsal hem de spektral bilgi kullanarak HSG'lerde sınıflandırma yapan Lee [13] çalışmasında en yüksek ikinci performans elde edilmiştir. Derin öğrenme tabanlı modeller, eşleştirme tabanlı yöntemlere göre daha iyi performans vermektedir.

Ayrıca mimarilerinde PCA ve dalgacık dönüşümleri kullanarak boyut azaltan, sırasıyla HybridSN ve SpektralNET çalışmaları karşılaştırılan yöntemlere göre daha düşük performans göstermektedir. Bant sayısının fazla azaltmak bilgi kaybına yol açabileceğinden, yapılacak en uygun bant sayısının seçilmesi çalışması ile bu modellerin performansının iyileşebileceği öngörülmektedir.

Tablo 5.9'da her modelin çeşitli saatlerdeki performans sıralamaları gösterilmiştir. Modellerin genel olarak 00:00 ve 03:00 saatlerinde başarılarının düştüğü görülmektedir.

Tablo 5.8 Modellerin birbirleri ile karşılaştırmaları

Test Saati	HybridSN	SpectralNET	He	Hamida	Lee	LSTM
0:00	0.553	0.572	0.503	0.544	0.641	0.677
3:00	0.547	0.545	0.483	0.518	0.566	0.536
6:00	0.688	0.597	0.562	0.773	0.668	0.817
9:00	0.564	0.643	0.596	0.709	0.659	0.696
12:00	0.552	0.664	0.296	0.807	0.737	0.811
15:00	0.726	0.573	0.491	0.848	0.854	0.88
18:00	0.655	0.569	0.411	0.614	0.636	0.724
21:00	0.521	0.522	0.409	0.642	0.668	0.731
15.05.2013-03:00	0.562	0.585				0.582
15.05.2013-15:00	0.563	0.573				0.743

Tablo 5.9 Modellerin zaman dilimlerine göre performans deęerlendirmeleri


Test Saati	HybridSN	SpectralNET	He	Hamida	Lee	LSTM
0:00	0.553	0.572	0.503	0.544	0.641	0.677
3:00	0.547	0.545	0.483	0.518	0.566	0.536
6:00	0.688	0.597	0.562	0.773	0.668	0.817
9:00	0.564	0.643	0.596	0.709	0.659	0.696
12:00	0.552	0.664	0.296	0.807	0.737	0.811
15:00	0.726	0.573	0.491	0.848	0.854	0.88
18:00	0.655	0.569	0.411	0.614	0.636	0.724
21:00	0.521	0.522	0.409	0.642	0.668	0.731
15.05.2013-03:00	0.562	0.585				0.582
15.05.2013-15:00	0.563	0.573				0.743

Hedeflerin bu saatlerde evre pikseller ile benzer ıřınım yapımları ayırt ediciliklerini dıřırdıęı gzlenmektedir.


5.12. Boyut Azaltma ve Bant Seiminin Hedef Tespitine Etkisi

Blm 2.4.1. ve Blm 2.4.2.’de anlatılan PCA, Boruta [88] ve RFE [91] yntemleri kullanılarak LWIR HSG’lerin boyutları dıřırlmıř, dıřk boyutlu HSG’ler ile testler gerekleřtirilmiřtir. ncelikle ACE ve MF tespit edicileri bir arada kullanılmıř ve her ikisi ile de analiz yapılmıřtır. 1 Mayıs tarihinin 00:00, 06:00, 12.00 ve 18:00 saatlerinden alınmıř imzalar, bu tarihten sonraki 02, 03, 04, 05, 14, 15 ve 16 Mayıs tarihinin aynı saatlerinde test edilmiřtir.


řekil 5.43 ve řekil 5.44’de spektral boyutu yirmiye dıřırlmıř LWIR HSG’ler zerinde sırasıyla ACE ve MF sınıflandırıcıları kullanılarak yapılan hedef tespit alıřmaları sonuları ROC eęrileri ile gsterilmektedir. Bu testler sonucunda RFE [91] ve Boruta [88] bant seim yntemleri ile boyut azalmanın tespit performansını her durumda arttırdıęı gzlenmiřtir. Bu durum, tank hedeflerini ayırt edici bantların doęru seildięini gstermektedir. Ayrıca 00:00 ve 06:00 saatlerinde alınan LWIR HSG’lere PCA uygulanarak boyutları azaltılmıř ve boyutları azaltılmıř LWIR HSG’ler zerinde her iki sınıflandırıcı ile yapılan testlerde performansta ykselme grlmemiřtir. RFE [91] bant seim ynteminin her kořulda tespit performansını arttırdıęı ve dięer yntemlere gre en iyi performansı sergiledięi grlmüřtür.




(a) Test günlerinin 00:00 saatlerindeki ortalama sonuçlar



(b) Test günlerinin 06:00 saatlerindeki ortalama sonuçlar



(c) Test günlerinin 12:00 saatlerindeki ortalama sonuçlar




(d) Test günlerinin 18:00 saatlerindeki ortalama sonuçlar


Şekil 5.43 ACE sınıflandırıcı kullanarak çeşitli boyut azaltma ve bant seçme yöntemleri sonuçları

RFE [91] ve Boruta [88] yöntemleri ile 20 bant seçimi yoluna gidilmiş ve yapılan bütün testlerde, bant azaltmanın bütün bantların kullanıldığı duruma göre daha iyi performans gösterdiği görülmüştür.


HSG'lerde boyut azaltılması ile performansın yükseleceği gibi bir kaide görülmemiştir. PCA ile 20, 50 ve 75 spektral boyuta düşürme deneyleri yapılmış, genellikle performansı iyileştirdiği gözlenmiştir. Gece yapılan deneylerde bu iyileştirme düşük kalmıştır. Bant




(a) 00:00 saatindeki sonuçlar



(b) 06:00 saatindeki sonuçlar



(c) 12:00 saatindeki sonuçlar




(d) 18:00 saatindeki sonuçlar

Şekil 5.44 Uyum filtresi (MF) kullanarak çeşitli boyut azaltma ve bant seçme yöntemleri sonuçları


seçim teknikleri genel itibariyle tatmin etmiş, RFE [91] ile yapılan deneylerde Boruta [88] ve PCA'e göre daha iyi sonuçlar elde edilmiştir.

Şekil 5.45, 5.46'de 2 farklı bant seçim tekniğinin, Boruta [88] ve RFE [91], sonuçları gösterilmektedir. Her iki yöntemde de $10.3 \mu\text{m} - 11.4 \mu\text{m}$ ve $8.17 \mu\text{m} - 8.85 \mu\text{m}$ dalga boyları aralıklarının diğer bantlardan önemli olduğu gösterilmektedir. Bölüm 3.3.'de yapılan hata analizi çalışmalarında da $10.4 \mu\text{m} - 11.0 \mu\text{m}$ ve $8.2 \mu\text{m}$ ve $8.7 \mu\text{m}$ aralıklarında Planck eğrisinden diğer materyallere göre daha çok sapmaya uğradıkları görülmektedir. Böylece



Şekil 5.45 Boruta yöntemi ile seçilmiş dalga boyları

hem bant seçim yöntemlerinden elde edilen sonuçlarda, hem de Plank eğrisinden sapmadan kaynaklı hata analizinde 8.2 μm - 8.7 μm ve 10.3 μm - 11.0 μm dalga boyu aralıklarının tankların tespitinde önemli rol oynadıkları tespit edilmiştir.



Şekil 5.46 RFE yöntemi ile seçilmiş dalga boyları

6.ÇIKARIMLAR

Bu çalışmada SPICE veri kümesi üzerinde hedef yeniden tespiti çalışmaları yapılmıştır. Hedef tespiti için farklı yöntemler önerilmiş, yöntemlerin sonuçları incelemiştir. Cisimler, materyal yapıları gereği farklı termodinamik özelliklere sahip olmaktadır. Isı sığalarının ve termal eylemsizliklerinin farklı olması, gün içerisindeki sıcaklık değişim hızlarına ve sıcaklık aralıklarına etki etmekte bu da onların ayırt edilebilirliğini arttırmaktadır. Çalışmamızda, öncelikle ısı transfer yöntemlerinden “ışınım ile ısı transferi” yöntemi göz önüne alınarak imza tabanlı eşleştirme çalışmalarında imzalar hedeflerin en çok güneşe maruz kalan, tavan bölgelerinden, referans imzalar alınarak yeniden tespit yapılmış ve tespit performansının, tankın ortasından alınana göre iyileştirdiği gözlenmiştir.

Materyallerin gün içerisindeki ısınma ve soğuma hızlarının farklılığından yararlanmak amacıyla parlaklık sıcaklığı dönüşümü uygulanarak sıcaklık profilleri elde edilerek sıcaklık küpleri oluşturulmuş ve hedef tespiti gerçekleştirilmiştir. Elde edilen sonuçlarda sıcaklık profilleri ile yapılan tespitlerin, ışıınım ile yapılandan daha güvenilir sonuçlar verdiği görülmüştür.

Atmosferik koşulların değişiminin hedef tespitine etkisi incelendiğinde hava sıcaklığı ve nemin tespit performansına etki ettiği görülmüş ve aynı hava sıcaklığında tespit yapıldığında performansın iyileştiği görülmüştür. Buradan yola çıkarak önerilen “Sahne Transferi” yönteminde test edilecek sahne, referans sahneye transfer edilerek hedef tespiti gerçekleştirilmiş ve sonuçların gözle görülür şekilde iyileştiği ortaya konulmuştur. Tezimizde önerdiğimiz bu yöntemle bilinen bir test sahnesinde hedef tespit çalışmaları için üretici çekişmeli ağların kullanımının önemi ortaya konulmuştur.

Cisimlerin gün içerisindeki ışıınım değişimleri zamansal olarak modellemek amacıyla belirli aralıklarla birleştirilerek Zamansal LWIR HSG’ler elde edilmiş ve üzerinde tespit çalışmaları gerçekleştirilmiştir. Bu çalışmalarda 6 saat arayla elde edilen HSG’lerin birleştirilmesi ile hedef tespit başarımlarının kullanılabilir olduğu gözlenmiştir.

Spektral bilgilerin cisimlere özgü olması, bunların modellenebileceği sorusunu akıllara getirmiş ve Bölüm 5.8.'de anlatılan sekans modelleme derin öğrenme yöntemleri ile hedef yeniden tespit çalışması yapılmış ve en iyi sonuçlar elde edilmiştir. Benzer şekilde sahne üzerinde, literatürdeki Pavia University ve Indian Pines hiperspektral veri kümelerinde başarı göstermiş modeller eğitilmiş fakat LWIR sahnesinde, orada oldukları kadar yüksek performans gösteremedikleri görülmüştür.

Spektral çözünürlüğün yüksek olması, işlem yükünü arttırmaktadır. Hedef yeniden tespit çalışmasında en uygun spektral bantların seçimi için RFE, Boruta ve PCA bant seçimi ve bant azaltma yöntemleri kullanılmış ve performansları incelenmiştir. PCA kullanılıp boyutun azaltılmasının hemen her koşulda performansı iyileştirdiği gözlenmiştir. Ayrıca bant seçim tekniklerinden RFE, Boruta'dan daha iyi performans göstermiştir. Bant seçim çalışmaları sonucunda $10.3\mu\text{m}$ - $11.4\mu\text{m}$ ve $8.17\mu\text{m}$ - $8.85\mu\text{m}$ aralıklarının tank yeniden tespitinde en verimli bantlar olduğu gözlenmiştir. Benzer şekilde cisimlerin ışınlamalarının siyah cisim ışımasından saptıkları dalga boyları incelendiğinde, bant seçim tekniklerinde elde edilen dalga boyları ile benzer olduğu görülmüştür.

Atmosferik etkilerin giderilmesi ve sıcaklık-salıcılık dönüşümü çalışmaları ile radyans verisinden salıcılık elde edilmiş, ve cisimlerin salıcılıkları hedef tespitinde kullanılmıştır. Çalışmalar neticesinde salıcılık (emissivity) verisinin de hedef tespitinde kullanılabileceği ortaya konulmuştur. Ayrıca yapılan testlerde salıcılık verisi kullanımının radyans verisi kullanımına göre hedef tespit performansını arttırdığı gözlenmiştir.

REFERENCES

- [1] Floyd F Sabins Jr. Remote sensing: principles and interpretation. Technical report, Chevron Oil Field Research Co., **1986**.
- [2] Christoph Borel, Dalton Rosario, and Joao Romano. Range-invariant anomaly detection applied to imaging fourier transform spectrometry data. In *Imaging Spectrometry XVII*, volume 8515, pages 149–160. SPIE, **2012**.
- [3] Nirmalan Jeganathan. *Hyperspectral and Hypertemporal Longwave Infrared Data Characterization*. Rochester Institute of Technology, **2017**.
- [4] Nirmalan Jeganathan, John Kerekes, and Dalton Rosario. Characterizing the temporal and spatial variability of longwave infrared spectral images of targets and backgrounds. In Miguel Velez-Reyes and David W. Messinger, editors, *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXIII*, volume 10198, page 101980K. International Society for Optics and Photonics, SPIE, **2017**. doi:10.1117/12.2262506.
- [5] Dimitris Manolakis, Michael Pieper, Eric Truslow, Ronald Lockwood, Andrew Weisner, John Jacobson, and Thomas Cooley. Longwave infrared hyperspectral imaging: Principles, progress, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(2):72–100, **2019**. doi:10.1109/MGRS.2018.2889610.
- [6] Tipler PA. *Physik, 3rd edn*. Spektrum Akademischer Verlag, Heidelberg, 1520pp, **2000**.
- [7] Walker Jearl. *Fundamentals of physics, 8th edn*. Wiley, New York, 891pp. ISBN 9780471758013, **2008**.
- [8] Claudia Kuenzer Stefan Dech. *Thermal Infrared Remote Sensing: Sensors, Methods, Applications, Remote Sensing and Digital Image Processing*. Springer Science+Business Media Dordrecht, **2013**. doi:DOI10.1007/978-94-007-6639-6_3.

- [9] Yushi Chen, Zhouhan Lin, Xing Zhao, Gang Wang, and Yanfeng Gu. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6):2094–2107, **2014**. doi:10.1109/JSTARS.2014.2329330.
- [10] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, **1998**. doi:10.1109/5.726791.
- [11] 3 dimensional representative image. <https://www.kaggle.com/code/shivamb/3d-convolutions-understanding-use-case>.
- [12] M.E. Paoletti, J.M. Haut, J. Plaza, and A. Plaza. Deep learning classifiers for hyperspectral imaging: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158:279–317, **2019**. ISSN 0924-2716. doi:https://doi.org/10.1016/j.isprsjprs.2019.09.006.
- [13] Hyungtae Lee and Heesung Kwon. Contextual deep cnn based hyperspectral classification. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 3322–3325. **2016**. doi:10.1109/IGARSS.2016.7729859.
- [14] Amina Ben Hamida, Alexandre Benoit, Patrick Lambert, and Chokri Ben Amar. 3-d deep learning approach for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8):4420–4434, **2018**. doi:10.1109/TGRS.2018.2818945.
- [15] Mingyi He, Bo Li, and Huahui Chen. Multi-scale 3d deep convolutional neural network for hyperspectral image classification. In *2017 IEEE International Conference on Image Processing (ICIP)*, pages 3904–3908. **2017**. doi:10.1109/ICIP.2017.8297014.

- [16] Tanmay Chakraborty and Utkarsh Trehan. Spectralnet: Exploring spatial-spectral waveletcnn for hyperspectral image classification, **2021**. doi:10.48550/ARXIV.2104.00341.
- [17] Swalpa Kumar Roy, Gopal Krishna, Shiv Ram Dubey, and Bidyut B. Chaudhuri. Hybridsn: Exploring 3d-2d CNN feature hierarchy for hyperspectral image classification. *CoRR*, abs/1902.06701, **2019**.
- [18] Google maps. <https://www.google.com/maps/@40.9293797,-74.5839155,742m/data=!3m1!1e3>. Accessed: 2023-01-20.
- [19] Joao M. Romano, Melvin Felton, David Chenault, and Brian Sohr. Polarimetric imagery collection experiment. In Firooz A. Sadjadi, Abhijit Mahalanobis, David P. Casasent, Tien-Hsin Chao, Steven L. Chodos, and William E. Thompson, editors, *Automatic Target Recognition XX; Acquisition, Tracking, Pointing, and Laser Systems Technologies XXIV; and Optical Pattern Recognition XXI*, volume 7696, page 769611. International Society for Optics and Photonics, SPIE, **2010**. doi:10.1117/12.849911.
- [20] M. Tavana, A. Rahmati, and V. Mansouri. Congestion control with adaptive access class barring for lte m2m overload using kalman filters. *Computer Networks*, 141:222 – 233, **2018**. ISSN 1389-1286. doi:<https://doi.org/10.1016/j.comnet.2018.01.044>.
- [21] Xuan Deng, Yueming Wang, Daogang He, Guicheng Han, Tianru Xue, Yifan Hao, Xiaoqiong Zhuang, Jun Liu, Changxing Zhang, and Shengwei Wang. A compact mid-wave infrared imager system with real-time target detection and tracking. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:6069–6085, **2022**. doi:10.1109/JSTARS.2022.3192311.
- [22] Marco Canil, Jacopo Pegoraro, and Michele Rossi. milliTRACE-IR: Contact tracing and temperature screening via mmWave and infrared sensing. *IEEE*

- Journal of Selected Topics in Signal Processing*, 16(2):208–223, **2022**. doi:10.1109/jstsp.2021.3138632.
- [23] Dimitris Manolakis, David Marden, and Gary Shaw. Hyperspectral image processing for automatic target detection applications. *Lincoln Laboratory Journal*, 14:no. 1, pp. 79–116, **2003**.
 - [24] Dimitris Manolakis, David Marden, and Gary Shaw. Hyperspectral image processing for automatic target detection applications. *Lincoln Laboratory Journal*, 14, **2003**.
 - [25] Alper Koz, İlke Belenoğlu, Seniha Esen Yüksel, and Abdullah Aydın Alatan. Target rediscovery on long-wave infrared hyperspectral images using radiance and emissivity data. SET-277 Workshop on Phenomenology and Exploitation of Hyperspectral Sensing within NATO, **2019**.
 - [26] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial networks. *Commun. ACM*, 63(11):139–144, **2020**. ISSN 0001-0782. doi:10.1145/3422622.
 - [27] Stephen Young, B Johnson, and John Hackwell. An in-scene method for atmospheric compensation of thermal hyperspectral data. *J. Geophys. Res*, 107, **2002**. doi:10.1029/2001JD001266.
 - [28] Gila Notesco, Veronika Kopaková, Petr Rojík, Guy Schwartz, Ido Livne, and Eyal Ben-Dor. Mineral classification of land surface using multispectral lwir and hyperspectral swir remote-sensing data. a case study over the sokolov lignite open-pit mines, the czech republic. *Remote. Sens.*, 6:7005–7025, **2014**.
 - [29] Christoph Borel, Dalton Rosario, and Joao Romano. Data processing and temperature-emissivity separation for tower-based imaging fourier transform spectrometer data. *International Journal of Remote Sensing*, 36(19-20):4779–4792, **2015**. doi:10.1080/01431161.2015.1047996.

- [30] Patrick Rauss and Dalton Rosario. Deep greedy learning under thermal variability in full diurnal cycles. *Optical Engineering*, 56(8):081809–081809, **2017**.
- [31] Patrick Rauss and Dalton Rosario. Understanding of multi-domain battle challenges: AI/ML and the day/night thermal variability of targets. In Tien Pham, editor, *Artificial Intelligence and Machine Learning for Multi-Domain Operations Applications*, volume 11006, page 110061W. International Society for Optics and Photonics, SPIE, **2019**. doi:10.1117/12.2517510.
- [32] Gila Notesco, Yaron Ogen, and Eyal Ben-Dor. Mineral classification of makhtesh ramon in israel using hyperspectral longwave infrared (lwir) remote-sensing data. *Remote. Sens.*, 7:12282–12296, **2015**.
- [33] Sefa Küçük and Seniha Esen Yüksel. Comparison of rx-based anomaly detectors on synthetic and real hyperspectral data. In *2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, pages 1–4. **2015**. doi:10.1109/WHISPERS.2015.8075504.
- [34] M. T. Eismann. *[Hyperspectral Remote Sensing]*. SPIE Press, Bellingham, Washington, first ed., **2012**.
- [35] Gaigai Zhang, Shizhi Zhao, Wei Li, Qian Du, Qiong Ran, and Ran Tao. Htd-net: A deep convolutional neural network for target detection in hyperspectral imagery. *Remote Sensing*, 12(9):1489, **2020**.
- [36] Bin Pan, Zhenwei Shi, and Xia Xu. Mugnet: Deep learning for hyperspectral image classification using limited samples. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145:108–119, **2018**. ISSN 0924-2716. doi:https://doi.org/10.1016/j.isprsjprs.2017.11.003.
- [37] Alin Khaliduzzaman, Satoshi Yamamoto, and Yoh Nishimura. Perspectives and insight toward solving flaws of vegetation indices. *arXiv preprint arXiv:2212.00569*, **2022**.

- [38] Joseph Meola. Characterizing sensitivity of longwave infrared hyperspectral target detection with respect to signature mismatch and dimensionality reduction. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXIII*, volume 10198, pages 84–95. SPIE, **2017**.
- [39] Zorana Lanc, Milan Zeljković, Miodrag Hadžistević, Branko Strbac, Danka Labus Zlatanovic, and Sebastian Balos. Emissivity of metal surface coatings. **2021**.
- [40] M. Teena and A. Manickavasagan. *Thermal Infrared Imaging*, pages 147–173. Springer Berlin Heidelberg, Berlin, Heidelberg, **2014**. ISBN 978-3-642-54888-8. doi:10.1007/978-3-642-54888-8_8.
- [41] Robert Sundberg, Lawrence Bernstein, Jonathan Gelbord, Steven Adler-Golden, Nevzat Guler, and Patrick Conforti. An improved in-scene atmospheric retrieval and correction algorithm for long-wavelength infrared hyperspectral imagery. page 19. **2018**. doi:10.1117/12.2321116.
- [42] V. Payan Corresponding author and A. Royer. Analysis of temperature emissivity separation (tes) algorithm applicability and sensitivity. *International Journal of Remote Sensing*, 25(1):15–37, **2004**. doi:10.1080/0143116031000115274.
- [43] Nathan P Wurst, Seung Hwan An, and Joseph Meola. Comparison of longwave infrared hyperspectral target detection methods. In *Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imagery XXV*, volume 10986, pages 343–354. SPIE, **2019**.
- [44] Nathan P. Wurst, Seung Hwan An, and Joseph Meola. Comparison of longwave infrared hyperspectral target detection methods. In Miguel Velez-Reyes and David W. Messinger, editors, *Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imagery XXV*, volume 10986, page 1098617.

- International Society for Optics and Photonics, SPIE, **2019**. doi:10.1117/12.2518638.
- [45] Christoph Borel, Dalton Rosario, and Joao Romano. Analysis of diurnal, long-wave hyperspectral measurements of natural background and manmade targets under different weather conditions. In *2014 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, pages 1–5. **2014**. doi:10.1109/AIPR.2014.7041903.
- [46] E. A. Guggenheim. *Thermodynamics, Classical and Statistical*, pages 1–118. Springer Berlin Heidelberg, Berlin, Heidelberg, **1959**. ISBN 978-3-642-45912-2. doi:10.1007/978-3-642-45912-2_1.
- [47] A. Berk and G. P. Anderson. Impact of modtran®5.1 on atmospheric compensation. In *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, volume 3, pages III – 127–III – 129. **2008**. doi:10.1109/IGARSS.2008.4779299.
- [48] João M. Romano, Dalton Rosario, and James McCarthy. Day/night polarimetric anomaly detection using spice imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(12):5014–5023, **2012**. doi:10.1109/TGRS.2012.2195186.
- [49] João M. Romano, Dalton Rosario, and Edip Niver. Morphological operators for polarimetric anomaly detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(2):664–677, **2014**. doi:10.1109/JSTARS.2013.2271896.
- [50] İlke Belenoğlu, Metehan Yalçın, Seniha Esen Yuksel, and Alper Koz. Target detection over temperature profiles. In *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*, pages 1237–1240. **2022**. doi:10.1109/IGARSS46834.2022.9884269.
- [51] Xuan Deng, Yueming Wang, Daogang He, Guicheng Han, Tianru Xue, Yifan Hao, Xiaoqiong Zhuang, Jun Liu, Changxing Zhang, and Shengwei Wang. A

- compact mid-wave infrared imager system with real-time target detection and tracking. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:6069–6085, **2022**. doi:10.1109/JSTARS.2022.3192311.
- [52] Pedram Ghamisi, Naoto Yokoya, Jun Li, Wenzhi Liao, Sicong Liu, Javier Plaza, Behnood Rasti, and Antonio Plaza. Advances in hyperspectral image and signal processing: A comprehensive overview of the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 5(4):37–78, **2017**. doi:10.1109/MGRS.2017.2762087.
- [53] Shutao Li, Weiwei Song, Leyuan Fang, Yushi Chen, Pedram Ghamisi, and Jón Atli Benediktsson. Deep learning for hyperspectral image classification: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9):6690–6709, **2019**. doi:10.1109/TGRS.2019.2907932.
- [54] Muhammad Ahmad, Sidrah Shabbir, Swalpa Kumar Roy, Danfeng Hong, Xin Wu, Jing Yao, A. Khan, Manuel Mazzara, Salvatore Distefano, and Jocelyn Chanussot. Hyperspectral image classification—traditional to deep models: A survey for future prospects. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:968–999, **2021**.
- [55] Yu Fang, Hao Li, Yong Ma, Kun Liang, Yingjie Hu, Shaojie Zhang, and Hongyuan Wang. Dimensionality reduction of hyperspectral images based on robust spatial information using locally linear embedding. *IEEE Geoscience and Remote Sensing Letters*, 11(10):1712–1716, **2014**. doi:10.1109/LGRS.2014.2306689.
- [56] Masashi Sugiyama. Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis. *Journal of Machine Learning Research*, 8(37):1027–1061, **2007**.
- [57] Hwann-Tzong Chen, Huang-Wei Chang, and Tyng-Luh Liu. Local discriminant embedding and its variants. In *2005 IEEE Computer Society Conference on*

Computer Vision and Pattern Recognition (CVPR'05), volume 2, pages 846–853 vol. 2. **2005**. doi:10.1109/CVPR.2005.216.

- [58] Yanfei Zhong and Liangpei Zhang. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(3):894–909, **2012**. doi:10.1109/TGRS.2011.2162589.
- [59] Farid. Melgani and Lorenzo Bruzzone. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8):1778–1790, **2004**. doi:10.1109/TGRS.2004.831865.
- [60] Jun Li, José M. Bioucas-Dias, and Antonio Plaza. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Transactions on Geoscience and Remote Sensing*, 48(11):4085–4098, **2010**. doi:10.1109/TGRS.2010.2060550.
- [61] Xiu Jin, Lu Jie, Shuai Wang, Hai Jun Qi, and Shao Wen Li. Classifying wheat hyperspectral pixels of healthy heads and fusarium head blight disease using a deep neural network in the wild field. *Remote Sensing*, 10(3), **2018**. ISSN 2072-4292. doi:10.3390/rs10030395.
- [62] Jón Atli Benediktsson, Jón Aevvar Palmason, and J.R. Sveinsson. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):480–491, **2005**. doi:10.1109/TGRS.2004.842478.
- [63] Pedram Ghamisi, Yushi Chen, and Xiao Xiang Zhu. A self-improving convolution neural network for the classification of hyperspectral data. *IEEE Geoscience and Remote Sensing Letters*, 13(10):1537–1541, **2016**. doi:10.1109/LGRS.2016.2595108.

- [64] Yunsong Li, Weiying Xie, and Huaqing Li. Hyperspectral image reconstruction by deep convolutional neural network for classification. *Pattern Recognition*, 63:371–383, **2017**. ISSN 0031-3203. doi:<https://doi.org/10.1016/j.patcog.2016.10.019>.
- [65] Jiaojiao Li, Xi Zhao, Yunsong Li, Qian Du, Bobo Xi, and Jing Hu. Classification of hyperspectral imagery using a new fully convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 15(2):292–296, **2018**. doi:10.1109/LGRS.2017.2786272.
- [66] Juan Mario Haut, Mercedes E. Paoletti, Javier Plaza, Antonio Plaza, and Jun Li. Hyperspectral image classification using random occlusion data augmentation. *IEEE Geoscience and Remote Sensing Letters*, 16(11):1751–1755, **2019**. doi:10.1109/LGRS.2019.2909495.
- [67] Yonghao Xu, Bo Du, Fan Zhang, and Liangpei Zhang. Hyperspectral image classification via a random patches network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142:344–357, **2018**. ISSN 0924-2716. doi:<https://doi.org/10.1016/j.isprsjprs.2018.05.014>.
- [68] Mercedes E. Paoletti, Juan Mario Haut, Ruben Fernandez-Beltran, Javier Plaza, Antonio J. Plaza, and Filiberto Pla. Deep pyramidal residual networks for spectral–spatial hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(2):740–754, **2019**. doi:10.1109/TGRS.2018.2860125.
- [69] Zhouhan Lin, Yushi Chen, Xing Zhao, and Gang Wang. Spectral-spatial classification of hyperspectral image using autoencoders. In *2013 9th International Conference on Information, Communications Signal Processing*, pages 1–5. **2013**. doi:10.1109/ICICS.2013.6782778.
- [70] Qingshan Liu, Feng Zhou, Renlong Hang, and Xiaotong Yuan. Bidirectional-convolutional lstm based spectral-spatial feature learning for

- hyperspectral image classification. *Remote Sensing*, 9(12), **2017**. ISSN 2072-4292. doi:10.3390/rs9121330.
- [71] Yushi Chen, Xing Zhao, and Xiuping Jia. Spectral–spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6):2381–2392, **2015**. doi:10.1109/JSTARS.2015.2388577.
- [72] Shengliang Pu, Yuanfeng Wu, Xu Sun, and Xiaotong Sun. Hyperspectral image classification with localized graph convolutional filtering. *Remote Sensing*, 13(3), **2021**. ISSN 2072-4292. doi:10.3390/rs13030526.
- [73] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, and Neil Houlsby. An image is worth 16x16 words: Transformers for image recognition at scale, **2021**.
- [74] Ludovic Girard, Vincent Roy, Thierry Eude, and Philippe Giguère. Swin transformer for hyperspectral rare sub-pixel target detection. In *Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imaging XXVIII*, volume 12094. SPIE, **2022**.
- [75] Okan Bilge Özdemir and Alper Koz. 3d-cnn and autoencoder-based gas detection in hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16:1474–1482, **2023**. doi:10.1109/JSTARS.2023.3235781.
- [76] Zilong Zhong, Jonathan Li, David A. Clausi, and Alexander Wong. Generative adversarial networks and conditional random fields for hyperspectral image classification. *IEEE Transactions on Cybernetics*, 50(7):3318–3329, **2020**. doi:10.1109/tcyb.2019.2915094.
- [77] Xue Wang, Kun Tan, Qian Du, Yu Chen, and Peijun Du. Caps-triplegan: Gan-assisted capsnet for hyperspectral image classification. *IEEE Transactions*

- on Geoscience and Remote Sensing*, 57(9):7232–7245, **2019**. doi:10.1109/TGRS.2019.2912468.
- [78] Lin Zhu, Yushi Chen, Pedram Ghamisi, and Jón Atli Benediktsson. Generative adversarial networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9):5046–5063, **2018**. doi:10.1109/TGRS.2018.2805286.
- [79] Zhi He, Han Liu, Yiwen Wang, and Jie Hu. Generative adversarial networks-based semi-supervised learning for hyperspectral image classification. *Remote Sensing*, 9(10), **2017**. ISSN 2072-4292. doi:10.3390/rs9101042.
- [80] Hao Tang, Dan Xu, N. Sebe, Yanzhi Wang, Jason J. Corso, and Yan Yan. Multi-channel attention selection gan with cascaded semantic guidance for cross-view image translation. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 2412–2421, **2019**.
- [81] Han Zhang, Tao Xu, Hongsheng Li, Shaoting Zhang, Xiaogang Wang, Xiaolei Huang, and Dimitris Metaxas. Stackgan: Text to photo-realistic image synthesis with stacked generative adversarial networks. In *2017 IEEE International Conference on Computer Vision (ICCV)*, pages 5908–5916. **2017**. doi:10.1109/ICCV.2017.629.
- [82] Grigory Antipov, Moez Baccouche, and Jean-Luc Dugelay. Face aging with conditional generative adversarial networks. In *2017 IEEE International Conference on Image Processing (ICIP)*, pages 2089–2093. **2017**. doi:10.1109/ICIP.2017.8296650.
- [83] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, and Alexei A. Efros. Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. **2017**.

- [84] David H. Hubel and Torsten N. Wiesel. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of Physiology*, 160, **1962**.
- [85] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, **1997**.
- [86] Giorgio Morales, John W. Sheppard, Riley D. Logan, and Joseph A. Shaw. Hyperspectral dimensionality reduction based on inter-band redundancy analysis and greedy spectral selection. *Remote Sensing*, 13(18), **2021**. ISSN 2072-4292. doi:10.3390/rs13183649.
- [87] Qi Wang, Qiang Li, and Xuelong Li. A fast neighborhood grouping method for hyperspectral band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6):5028–5039, **2021**. doi:10.1109/TGRS.2020.3011002.
- [88] Miron B. Kursa and Witold R. Rudnicki. Feature selection with the boruta package. *Journal of Statistical Software*, 36(11):1–13, **2010**. doi:10.18637/jss.v036.i11.
- [89] Richa Marwaha, Anil Kumar, P. Raju, and Krishna Murthy Yelisetty. Target detection algorithm for airborne thermal hyperspectral data. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-8:827–832, **2014**. doi:10.5194/isprsarchives-XL-8-827-2014.
- [90] Buyun Xu, Xihai Li, Weijun Hou, Yiting Wang, and Yiwei Wei. A similarity-based ranking method for hyperspectral band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 59(11):9585–9599, **2021**. doi:10.1109/TGRS.2020.3048138.
- [91] Isabelle Guyon, Jason Weston, Stephen Barnhill, and Vladimir Vapnik. Gene selection for cancer classification using support vector machines. *Machine learning*, 46:389–422, **2002**.

- [92] Nitesh Keshavelal Poona, Adriaan van Niekerk, Ryan Leslie Nadel, and Riyad Ismail. Random forest (rf) wrappers for waveband selection and classification of hyperspectral data. *Applied Spectroscopy*, 70(2):322–333, **2016**. doi:10.1177/0003702815620545. PMID: 26903567.
- [93] Yaqian Long, Benoit Rivard, Arturo Sanchez-Azofeifa, Russell Greiner, Dominica Harrison, and Sen Jia. Identification of spectral features in the longwave infrared (lwir) spectra of leaves for the discrimination of tropical dry forest tree species. *International Journal of Applied Earth Observation and Geoinformation*, 97:102286, **2021**. ISSN 1569-8432. doi:https://doi.org/10.1016/j.jag.2020.102286.
- [94] Chris Ding and Hanchuan Peng. Minimum redundancy feature selection from microarray gene expression data. *Journal of bioinformatics and computational biology*, 3(02):185–205, **2005**.
- [95] Ramón Diaz-Uriarte. Genesrf and varselrf: a web-based tool and r package for gene selection and classification using random forest. *BMC bioinformatics*, 8(1):1–7, **2007**.
- [96] Yaqian Long, Benoit Rivard, Derek Rogge, and Minghua Tian. Hyperspectral band selection using the n-dimensional spectral solid angle method for the improved discrimination of spectrally similar targets. *International Journal of Applied Earth Observation and Geoinformation*, 79:35–47, **2019**.
- [97] Hongda Li, Jian Cui, Xinle Zhang, Yongqi Han, and Liying Cao. Dimensionality reduction and classification of hyperspectral remote sensing image feature extraction. *Remote Sensing*, 14(18):4579, **2022**. ISSN 2072-4292. doi:10.3390/rs14184579.
- [98] Jonathon Shlens. A tutorial on principal component analysis derivation , discussion and singular value decomposition. **2003**.

- [99] David M. Blei, A. Ng, and Michael I. Jordan. Latent dirichlet allocation. *J. Mach. Learn. Res.*, 3:993–1022, **2001**.
- [100] Sam T. Roweis and Lawrence K. Saul. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 290(5500):2323–2326, **2000**. doi:10.1126/science.290.5500.2323.
- [101] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-sne. *Journal of Machine Learning Research*, 9(86):2579–2605, **2008**.
- [102] G. H. Golub and C. Reinsch. *Singular Value Decomposition and Least Squares Solutions*, pages 134–151. Springer Berlin Heidelberg, Berlin, Heidelberg, **1971**. ISBN 978-3-642-86940-2. doi:10.1007/978-3-642-86940-2_10.
- [103] P.S Prasad. Independent component analysis. *Cambridge University Press, UK*, **2001**.
- [104] M Mooi, E.; Sarstedt. *M. Factor Analysis. In A Concise Guide to Market Research: The Process, Data, and Methods Using IBM SPSS Statistics*. Springer: Berlin/Heidelberg, Germany, 2011; pp. 201–236, **2011**.
- [105] Nicholas Westing, Brett Borghetti, and Kevin C. Gross. Fast and effective techniques for lwir radiative transfer modeling: A dimension-reduction approach. *Remote Sensing*, 11(16), **2019**. ISSN 2072-4292. doi:10.3390/rs11161866.
- [106] Michael Zelinski, Andrew Mastin, Vic Castillo, and Brian Yoxall. Optimal band selection for target detection with a lwir multispectral imager. *Journal of Applied Remote Sensing*, 16(2):026505–026505, **2022**.
- [107] Miron B. Kursa and Witold R. Rudnicki. Feature selection with the boruta package. *Journal of Statistical Software*, 36(11):1–13, **2010**. doi:10.18637/jss.v036.i11.

- [108] Kaleb E. Smith and Anthony O. Smith. A spectral enabled GAN for time series data generation. *CoRR*, abs/2103.01904, **2021**.
- [109] E Kaleb Smith and O Anthony Smith. Time series generation using a one dimensional wasserstein gan. *ITISE 2019 International Conference on Time Series and Forecasting*, pages 771–781, **2019**.
- [110] Nicolas Audebert, Bertrand Le Saux, and Sébastien Lefevre. Generative adversarial networks for realistic synthesis of hyperspectral samples. In *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, pages 4359–4362. **2018**. doi:10.1109/IGARSS.2018.8518321.
- [111] Jean-Christophe Burnel, Kilian Fatras, and Nicolas Courty. Generating natural adversarial hyperspectral examples with a modified wasserstein gan. *arXiv preprint arXiv:2001.09993*, **2020**.
- [112] Vladimir Kniaz, V. Gorbatshevich, and Vladimir Mizginov. Thermalnet: A deep convolutional network for synthetic thermal image generation. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W4:41–45, **2017**. doi:10.5194/isprs-archives-XLII-2-W4-41-2017.
- [113] Bing Li, Yong Xian, Juan Su, Da qiao Zhang, and Weilin Guo. I-gans for infrared image generation. *Complex.*, 2021:6635242:1–6635242:11, **2021**.
- [114] Vladimir V. Kniaz, Vladimir A. Knyaz, Jiří Hladůvka, Walter G. Kropatsch, and Vladimir Mizginov. Thermalgan: Multimodal color-to-thermal image translation for person re-identification in multispectral dataset. In Laura Leal-Taixé and Stefan Roth, editors, *Computer Vision – ECCV 2018 Workshops*, pages 606–624. Springer International Publishing, Cham, **2019**. ISBN 978-3-030-11024-6.

- [115] Cara Murphy and John Kerekes. 1d conditional generative adversarial network for spectrum-to-spectrum translation of simulated chemical reflectance signatures. *Journal of Spectral Imaging*, 10, **2021**. doi:10.1255/jsi.2021.a2.
- [116] T. Cooley, G.P. Anderson, G.W. Felde, M.L. Hoke, A.J. Ratkowski, J.H. Chetwynd, J.A. Gardner, S.M. Adler-Golden, M.W. Matthew, A. Berk, L.S. Bernstein, P.K. Acharya, D. Miller, and P. Lewis. Flaash, a modtran4-based atmospheric correction algorithm, its application and validation. In *IEEE International Geoscience and Remote Sensing Symposium*, volume 3, pages 1414–1418 vol.3. **2002**. doi:10.1109/IGARSS.2002.1026134.
- [117] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In Nassir Navab, Joachim Hornegger, William M. Wells, and Alejandro F. Frangi, editors, *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pages 234–241. Springer International Publishing, Cham, **2015**.
- [118] Chuan Li and Michael Wand. Precomputed real-time texture synthesis with markovian generative adversarial networks. In Bastian Leibe, Jiri Matas, Nicu Sebe, and Max Welling, editors, *Computer Vision – ECCV 2016*, pages 702–716. Springer International Publishing, Cham, **2016**.
- [119] Sepp Hochreiter and Jürgen Schmidhuber. Long Short-Term Memory. *Neural Computation*, 9(8):1735–1780, **1997**. ISSN 0899-7667. doi:10.1162/neco.1997.9.8.1735.
- [120] Pengju Liu, Hongzhi Zhang, Kai Zhang, Liang Lin, and Wangmeng Zuo. Multi-level wavelet-cnn for image restoration, **2018**.
- [121] Muhammad Ahmad, Adil Mehmood Khan, Manuel Mazzara, Salvatore Distefano, Mohsin Ali, and Muhammad Shahzad Sarfraz. A fast and compact 3-d CNN for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 19:1–5, **2022**. doi:10.1109/lgrs.2020.3043710.

- [122] Spice technical document. <https://apps.dtic.mil/sti/pdfs/ADA564548.pdf>.
- [123] Jacob Cohen. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1):37–46, **1960**. doi:10.1177/001316446002000104.

