

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

HİPERSPEKTRAL VERİLER İÇİN KAYNAŞTIRMA İLE
UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

SEVCAN KAHRAMAN

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

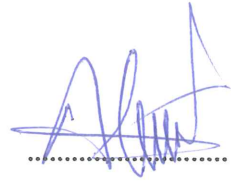
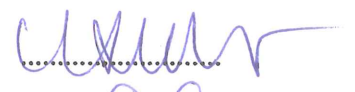



ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

HİPERSPEKTRAL VERİLER İÇİN KAYNAŞTIRMA İLE
UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

SEVCAN KAHRAMAN

Ünvan Ad SOYAD Prof. Dr. Ali TANGEL
Danışman, KOCAELİ ÜNİVERSİTESİ
Ünvan Ad SOYAD Prof. Dr. Mehmet ENGİN
Jüri Üyesi, EGE ÜNİVERSİTESİ
Ünvan Ad SOYAD Doç. Dr. M.Kemal GÜLLÜ
Jüri Üyesi, KOCAELİ ÜNİVERSİTESİ
Ünvan Ad SOYAD Dr. Öğr. Üyesi Burhan BARAKLI
Jüri Üyesi, SAKARYA ÜNİVERSİTESİ
Ünvan Ad SOYAD Dr. Öğr. Üyesi Orhan AKBULUT
Jüri Üyesi, KOCAELİ ÜNİVERSİTESİ


.....

.....

.....

.....

.....

Tezin Savunulduğu Tarih: 09.07.2019

ÖNSÖZ VE TEŞEKKÜR

Tez süresince RASAT verilerinin herkese ulaşımını sağlayan TÜBİTAK UZAY'a ve GÖKTÜRK-2 verileri ile algılayıcı Modülasyon Transfer Fonksiyonu (Modulation Transfer Function - MTF) ve Spectral Yanıt Fonksiyonu (Spectral Response Function - SRF) değerlerinin temin edildiği Hava Kuvvetleri Komutanlığı, Keşif Uydu Tabur Komutanlığı'na çok teşekkür ederim. Bu çalışma TÜBİTAK 115E883 nolu proje kapsamında desteklenmiştir.

Ayrıca, Light Detection And Ranging (LiDAR) verileri ile ilgili yapılan tüm çalışmalar Prof. Jocelyn CHANUSSOT başkanlığında, Fransa'daki Grenoble Institute of Technology, the Laboratoire Grenoblois de l'Image, de la Parole, du Signal et de l'Automatique (Gipsa-lab), Department of Images and Signal'de yürütülmüştür. Kendisine tezime katkılarından dolayı çok teşekkür ederim. Fransa'da gerçekleştirilen bu çalışmalar TÜBİTAK 2214/A yurt dışı doktora sırası araştırma burs programı kapsamında desteklenmiştir. Dünyadaki en önemli araştırma laboratuvarlarından biri olan Gipsa-lab'da araştırmacı olarak bulunma imkanı tanıdığı için TÜBİTAK'a katkılarından dolayı çok teşekkür ederim.

Beni görüntü işleme dünyası ile tanıştıran Prof. Dr. Tayfun DALBASTI'ya, mühendislik, görüntü işleme ve uzaktan algılama alanında çok şey öğreten Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği hocalarıma, ve tez sunum sınavımda bulunan tez izleme komitesi hocalarım Prof. Dr. Ali TANGEL, Prof. Dr. Mehmet ENGİN, Doç. Dr. M. Kemal GÜLLÜ, Dr. Öğr. Üyesi Burhan BARAKLI ve Dr. Öğr. Üyesi Orhan AKBULUT'a çok teşekkür ederim.

Gipsa-Lab'ta yaptığım kolaboratif çalışmalarla beraber bana farklı bir vizyon kazandıran hiperspektral görüntü analizi duayenlerinden Prof. Jocelyn CHANUSSOT'e, Gipsa-Lab'taki araştırmam süresince değerli dostluklarının yanında sorduğum her soruya en iyi şekilde cevap vererek beni hiperspektral ve LiDAR verisi hakkında bilgilendiren Yang XU, Tatsumi UEZATO and Raphael BACHER'a, bana dostluklarının en güzelini sunan Gipsa-Lab'taki dostlarım Elaheh SOBHANI, Maria OLIVER PARERA, Dawood AL CHANTI, Julien MUZEAU, Jitendra SINGH SEWADA, Ivan CASTILLO CAMACHO, Julien MEYER, Isidora STANKOVIC, Ludovic DARMET, Tien LE QUYET, Buce CANOVAS ve Daniele PICONE'a çok teşekkür ederim.

Temmuz - 2019

Sevcan KAHRAMAN

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	v
TABLolar DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	ix
ÖZET.....	xi
ABSTRACT.....	xii
GİRİŞ	1
1. PANKESKİNLEŞTİRME TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI.....	6
1.1 Pankeskinleştirme Yaklaşımları.....	6
1.1.1. Bileşen ekleme (Component substitution - CS)	10
1.1.1.1. Işıklılık, renk tonu, doygunluk (Intensity hue saturation - IHS)	12
1.1.1.2. Brovey dönüşümü (BT).....	12
1.1.1.3. Temel bileşen analizi (Principal component analysis - PCA).....	13
1.1.1.4. Gram Schmidt (GS).....	13
1.1.1.5. Hiperküre renk uzayı (Hyperspherical color space - HCS).....	13
1.1.1.6. Yüksek geçiren filtre (High pass filter - HPF)	14
1.1.1.7. University of New Brunswick (UNB).....	14
1.1.1.8. Kısmi yer değiştirmeye dayalı bileşen ekleme (Partial replacement adaptive component substitution - PRACS).....	14
1.1.1.9. Gram Schmidt Gaussian Laplacian Pyramid - GS2- GLP	15
1.1.1.10. Banda bağlı uzamsal detay (Band dependent spatial detail – BDS)	15
1.1.2. Çok çözünürlüklü analiz (Multiresolution analysis - MRA).....	15
1.1.2.1. Yumuşatma süzgeci tabanlı yoğunluk modülasyonu (Smoothing filter based intensity modulation - SFIM)	16
1.1.2.2. Spektral simulasyon renk normalizasyonu (Spectral simulation color normalization -SSCN).....	16
1.1.2.3. Wavelet dönüşümü (Wavelet transform - WT).....	17
1.1.2.4. Eklemeli Dalgacık Parlaklığı (Additive Wavelet Luminance - AWL)	17
1.1.2.5. A trous Wavelet dönüşümü (A trous wavelet transform - ATWT)	18
1.1.2.6. Laplacian Piramit (Laplacian Pyramid - LP)	18
1.1.3. Hibrid yaklaşımlar (Hybrid approaches)	19
1.1.3.1. Ehlers veri kaynaştırma (Ehlers fusion)	20
1.1.3.2. Rehber süzgeç PCA (Guided filter PCA - GFPCA)	20

1.1.4. Varyasyonel yaklaşımlar (Variational approaches).....	21
1.1.4.1. P+XS	21
1.2. Wald's Protokolü.....	21
1.3. Pankromatik-Multispektral Pankeskinleştirme Temelli Uzamsal Çözünürlük Artırımı.....	22
1.3.1. RASAT alıcı görüntüleri üzerinde pankeskinleştirme yaklaşımları ve deneysel sonuçlar.....	22
1.3.2. GÖKTÜRK-2 alıcı görüntüleri üzerinde pankeskinleştirme yaklaşımları ve deneysel sonuçlar.....	30
1.3.3. GÖKTÜRK-2 görüntüleri için MTF ve SRF değerlerini içeren pankeskinleştirme yaklaşımlarının başarımları ve deneysel sonuçlar	38
1.4. Karışım Giderimi (Unmixing) ile Veri Kaynaştırma	46
1.4.1. Lineer karışım modeli - LKM (Linear mixing model - LMM) ile hiperspektral karışım giderimi.....	47
1.4.2. Matris faktörizasyonu (Matrix factorization).....	48
1.4.2.1. NMF için çarpımsal iteratif güncelleme algoritması.....	49
1.4.3. Eşlemeli negatif olmayan matris faktörizasyonu (Coupled non-negative matrix factorization - CNMF)	51
1.4.4. Bayesian veri kaynaştırma yaklaşımı	54
1.4.5. Hiperspektral süper çözünürlük (Hyperspectral super resolution - HySure)	59
1.4.6. Sylvester denkleminde dayalı hızlı kaynaştırma (Fast fusion based on Sylvester equation – FUSE)	61
1.4.7. Maksimum deney sonrası / stokastik karışım modelini (Maximum a posterior - MAP / stochastic mixing model - SMM).....	62
1.4.8. Akhtar'ın metodu.....	64
1.4.9. Lanaras'ın metodu.....	65
1.5. Pankromatik - Hiperspektral Pankeskinleştirme Temelli Uzamsal Çözünürlük Artırımı.....	67
1.5.1. Blok ve kümeleme tabanlı PAN-HS pankeskinleştirme yaklaşımlarının başarımları ve deneysel sonuçlar.....	67
1.5.1.1. Çakışan ve çakışmayan bloklar için deneysel sonuçlar.....	69
1.5.1.2. k-ortalama, ISODATA ve SLIC kümeleme yaklaşımları için deneysel sonuçlar.....	73
1.5.2. Bayesian, Hysure temelli PAN-HS pankeskinleştirme yaklaşımlarının başarımları ve deneysel sonuçlar	81
1.6. Vargılar.....	83
2. MULTİSPEKTRAL – HİPERSPEKTRAL (MS –HS) KAYNAŞTIRMA TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI.....	84
2.1. Çeşitli Kısıtlamaları İçeren NMF Yaklaşımları	85
2.1.1. Seyreklik kısıtlı L_1 -NMF (Sparsity constrained L_1 -NMF).....	86
2.1.2. Seyreklik kısıtlı $L_{1/2}$ -NMF (Sparsity constrained $L_{1/2}$ -NMF).....	87
2.1.3. Graf düzenleyicili NMF (Graph regularized NMF - GLNMF).....	91
2.1.4. Çok katmanlı NMF (Multilayer NMF - MLNMF).....	96
2.1.5. Veriye dayalı NMF (Data guided NMF, DGC - NMF).....	97

2.1.6. Toplam deęişinti kısıtlı graf düzenleyicili NMF (Total variation constrained graph regularized NMF, TV-GNMF).....	98
2.1.7. Son eleman ve bolluk oranları kısıtlı NMF (NMF Method with endmemeber and abundance constraints, EAC-NMF).....	100
2.1.8. Lokal komşuluk aęırlıklı NMF (Local neighborhood weights NMF - WNMF).....	102
2.2. Vargılar.....	104
3. LiDAR - HİPERSPEKTRAL KAYNAŞTIRMA TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI	105
3.1. LiDAR Verisi Yardımıyla Hipergraf Kısıtlı Hiperspektral Karışım Giderimi	105
3.1.1. Toplam deęişinti (Total variation - TV) düzenleyicili LiDAR yardımıyla karışım giderimi	106
3.1.2. Hiper-graf	107
3.1.3. Hiper-grafi karışım giderimi ile birleştirme	109
3.1.4. Optimizasyon.....	110
3.1.5. Deneysel sonuçlar.....	111
3.2. LiDAR Yardımıyla Hiperspektral Görüntülerde Spektral Deęişkenlięin Azaltılması	112
3.2.1. Metodoloji	114
3.2.1.1. Spektral bölge karışım giderimi (Spectral zone unmixing - SZU).....	114
3.2.1.2. Hiyerarşik bölütleme	114
3.2.1.3. Sunulan yaklaşım	115
3.2.2. Deneysel sonuçlar.....	116
3.3. Vargılar.....	117
4. SONUÇLAR VE ÖNERİLER	118
4.1. PAN-HS ya da LiDAR-HS Verilerini Kullanarak Spektral Deęişkenlięin Azaltılmasının Karşılaştırılması	118
4.2. Deneysel Çalışmalar.....	119
4.3. Vargılar.....	120
KAYNAKLAR	123
KİŞİSEL YAYINLAR VE ESERLER	136
ÖZGEÇMİŞ	137

ŞEKİLLER DİZİNİ

Şekil 1.1.	Tez kapsamının blok şeması.....	6
Şekil 1.2.	RASAT Mersin verisi için pankeskinleştirme girdi ve çıktı sonucu (a) RASAT verisi Mersin RGB görüntüsü, (b) RASAT verisi Mersin PAN görüntüsü, (c) RASAT verisi Mersin pankeskinleştirilmiş görüntü.	7
Şekil 1.3.	Pankeskinleştirme işlemi girdileri a), b) ve çıktı sonucu c), a) MS görüntü, b) PAN görüntü, c) pankeskinleştirilmiş görüntü.	7
Şekil 1.4.	Rehber Süzgeç Yaklaşımı (Guided Filter PCA – GFPCA).	20
Şekil 1.5.	Wald’s Protokolü blok şeması.	21
Şekil 1.6.	RASAT Mersin veri seti için RGB ve PAN görüntüleri.	23
Şekil 1.7.	RASAT İstanbul veri seti için RGB ve PAN görüntüleri.....	23
Şekil 1.8.	RASAT Sinop veri seti RGB ve PAN görüntüleri	23
Şekil 1.9.	ASAT Mersin veri seti için pankeskinleştirme görsel sonuçları.....	27
Şekil 1.10.	RASAT İstanbul veri seti için pankeskinleştirme görsel sonuçları.....	28
Şekil 1.11.	RASAT Sinop veri seti için pankeskinleştirme görsel sonuçları.....	29
Şekil 1.12.	a) MS veri seti b) PAN veri seti İstanbul, GÖKTÜRK-2.....	31
Şekil 1.13.	a) MS veri seti b) PAN veri seti Büyükada, GÖKTÜRK-2.....	31
Şekil 1.14.	a) MS veri seti b) PAN veri seti Alanya Tepebaşı, GÖKTÜRK-2.....	32
Şekil 1.15.	İstanbul veri seti için pankeskinleştirme görsel sonuçları, GÖKTÜRK-2.....	36
Şekil 1.16.	Büyükada veri seti için pankeskinleştirme görsel sonuçları, GÖKTÜRK-2.....	37
Şekil 1.17.	Alanya-Tepebaşı veri seti için pankeskinleştirme görsel sonuçları, GÖKTÜRK-2.....	38
Şekil 1.18.	GÖKTÜRK-2 uydu verisi görselleri a) İstanbul-1 RGB, b) İstanbul-2 RGB, c) Kumluca Yeniköy RGB d) İstanbul-1 PAN e) İstanbul-2 PAN f) Kumluca Yeniköy PAN.....	40
Şekil 1.19.	GÖKTÜRK-2 İstanbul-1 verisi pankeskinleştirme görsel sonuçları a) IHS, b) BT, c) PCA, d) GS, e) GSA, f) HPF, g) UNB, h) PRACS, i) GS2-GLP, j) BDS, k) ATWT, l) AWLP, m) SSCN, n) GLP, o) MTF-GLP, p) MTF-GLP-HPM, r) GFPCA, s) PXS.....	44
Şekil 1.20.	GÖKTÜRK-2 İstanbul-2 verisi pankeskinleştirme görsel sonuçları a) IHS, b) BT, c) PCA, d) GS, e) GSA, f) HPF, g) UNB, h) PRACS, i) GS2-GLP, j) BDS, k) ATWT, l) AWLP, m) SSCN, n) GLP, o) MTF-GLP, p) MTF-GLP-HPM, r) GFPCA, s) PXS.....	45
Şekil 1.21.	Spektral karışım giderimi.....	46

Şekil 1.22.	CNMF kavramı	51
Şekil 1.23.	Akhtar's yaklaşımının şematik görünümü	65
Şekil 1.24.	Global, çakışmayan ve çakışan blokları içeren pikseller a) global b) çakışmayan blok ve c) kayan pencere şeklinde çakışan blok gösterimleri	68
Şekil 1.25.	Veri Setleri a) AVIRIS - Moffett, b) ROSIS - Pavia University	73
Şekil 1.26.	AVIRIS Moffett veri seti için görsel sonuçlar a) IHS b) IHS_ çakışmayan c) IHS_ çakışan d) IHS_k-ortalama e) IHS_ISODATA f) IHS_SLIC g) BT h) BT_ çakışmayan i) BT_ çakışan j) BT_k- ortalama k) BT_ISODATA l) BT_SLIC m) GS n) GS_ çakışmayan o) GS_çakışan p) GS_k- ortalama r) GS_ISODATA s) GS_SLIC t) PCA u) PCA_ çakışmayan v) PCA_ çakışan w) PCA_k- ortalama x) PCA_ISODATA y) PCA_SLIC.	81
Şekil 1.27.	AVIRIS sensörü HS-PAN veri kaynaştırması görsel sonuçları	83
Şekil 2.1.	$L_{1/2}$ - düzenleyicisinin geometrik yorumu.	90
Şekil 2.2.	Veri setlerinin RGB görüntüleri, a) AVIRIS Indian Pines-HS görüntüsü, b) AVIRIS Indian Pines-MS görüntüsü, c) AVIRIS Indian Pines-orijinal görüntü, d) HYDICE Washington, D.C-HS görüntüsü, e) HYDICE Washington, D.C-MS görüntüsü, f) HYDICE Washington, D.C-orijinal görüntü.	94
Şekil 2.3.	Veri kaynaştırma sonucunun RGB görüntüsü, (a) Indian Pines - CNMF, (b) Indian Pines – sunulan yaklaşım, (c) DC Mall – CNMF, (d) DC Mall – sunulan yaklaşım.	95
Şekil 2.4.	Çok katmanlı NMF dekompozisyonu	96
Şekil 2.5.	S benzerlik matrisine göre homojen ve geçiş alanlarının bölütlenmesi a) simule edilmiş spektral görüntü b) benzerlik matrisi c) bölütleme sonuçları	102
Şekil 3.1.	Sunulan yaklaşımın akış diyagramı.	115
Şekil 3.2.	Bant seçim yaklaşımının RMSE değerleri, (a) gürültüsüz, (b) 30dB değerinde gürültülü.	116
Şekil 4.1.	2013 IEEE GRSS Veri Kaynaştırması Yarışması Houston University veri seti a) HS'nin RGB görüntüsü b) LiDAR-DSM görüntüsü.	118
Şekil 4.2.	2013 IEEE GRSS Veri Kaynaştırması Yarışması Houston Üniversitesi veri setinden seçilen alt görüntü a) HS'nin RGB görüntüsü b) DSM görüntüsü.	119

TABLolar DİZİNİ

Tablo 1.1.	Mersin veri seti için niceliksel pankeskinleştirme sonuçları.....	24
Tablo 1.2.	İstanbul veri seti için niceliksel pankeskinleştirme sonuçları.....	25
Tablo 1.3.	Sinop veri seti için niceliksel pankeskinleştirme sonuçları.....	26
Tablo 1.4.	İstanbul veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.....	33
Tablo 1.5.	Büyükada veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.....	34
Tablo 1.6.	Alanya Tepebaşı veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.....	35
Tablo 1.7.	GÖKTÜRK-2 İstanbul-1 verisi için niceliksel sonuçlar.....	41
Tablo 1.8.	GÖKTÜRK-2 İstanbul-2 verisi için niceliksel sonuçlar.....	42
Tablo 1.9.	GÖKTÜRK-2 Kumluca Yeniköy verisi için niceliksel sonuçlar.....	43
Tablo 1.10.	NMF Algoritmasının sözde kodu.....	51
Tablo 1.11.	CNMF Algoritması'nın sözde kodu.....	54
Tablo 1.12.	HySure Algoritması'nın sözde kodu.....	60
Tablo 1.13.	AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS- PAN çakışan bantlar (2-35) SRF ile, senaryo 1.....	70
Tablo 1.14.	AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS- PAN çakışan bantlar (1-224) SRF ile, senaryo 2.....	71
Tablo 1.15.	AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS- PAN çakışan bantlar (1-224) SRF olmadan, senaryo 3, PAN = mean(data(:, :, overlap)) çakışan_bantlar = 1:41.....	72
Tablo 1.16.	Pankeskinleştirme performansı AVIRIS Moffett veri seti, oran = 2.....	74
Tablo 1.17.	Pankeskinleştirme performansı AVIRIS Moffett veri seti, oran = 4.....	75
Tablo 1.18.	Pankeskinleştirme performansı ROSIS Pavia veri seti, oran=2.....	76
Tablo 1.19.	Pankeskinleştirme performansı ROSIS Pavia University veri seti, oran = 4.....	77
Tablo 1.20.	Pankeskinleştirme Performansı ROSIS Pavia University veri seti, oran = 2.....	78
Tablo 1.21.	Pankeskinleştirme Performansı ROSIS Pavia veri seti, oran=4.....	79
Tablo 1.22.	AVIRIS Indian Pines HS-PAN veri kaynaştırma sonuçları.....	82
Tablo 1.23.	AVIRIS Moffett HS-PAN veri kaynaştırma sonuçları.....	82
Tablo 1.24.	AVIRIS Cuprite HS-PAN veri kaynaştırma sonuçları.....	82
Tablo 2.1.	L_1 -CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.....	87
Tablo 2.2.	$L_{1/2}$ -NMF Algoritması'nın sözde kodu.....	89
Tablo 2.3.	$L_{1/2}$ -CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.....	91
Tablo 2.4.	GLCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.....	95
Tablo 2.5.	MLCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.....	97

Tablo 2.6.	DGC-CNMF ile kaynaştırılmış görüntülerin PSNR değerleri.	98
Tablo 2.7.	TV-GCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.	100
Tablo 2.8.	EAC-CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.....	101
Tablo 2.9.	WCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.	104
Tablo 3.1.	TV düzenleyicili LiDAR w-DSM ve w-DSM-HG-NMF.	111
Tablo 3.2.	Önerilen yaklaşımın RMSE değeri.	116
Tablo 4.1.	PAN-HS ve LiDAR-HS karşılaştırması.....	119



SİMGELER VE KISALTMALAR DİZİNİ

Kisaltmalar

ADMM	: Alternating Direction Method of Multipliers (Çarpanların Alternatif Yön Yaklaşımı)
ATWT	: A Tróus Wavelet Transform (A Tróus Wavelet Dönüşümü)
AVIRIS	: Airborne Visible/Infrared Imaging Spectrometer (Havadan Görünür / Kızılötesi Görüntüleme Spektrometresi)
AWL	: Additive Wavelet Luminance (Eklemeli Wavelet Parlaklığı)
AWLP	: Proportional AWL (Dik AWL)
BCD	: Block Coordinate Descent (Blok Koordinat Azalan)
CC	: Correlation Coefficient (Korelasyon Katsayısı)
CNMF	: Coupled Non-Negative Matrix Factorization (Eşlemeli Negatif Olmayan Matris Faktörizasyonu)
DSM	: Digital Surface Model (Dijital Yüzey Modeli)
ELMM	: Extended linear mixing model (Genişletilmiş Lineer Karışım Modeli)
ERGAS	: Erreur Relative Globale Adimensionnelle de Synthése (Boyutsuz Global Görelî Sentez Hatası)
FCLS	: Fully Constraint Least Squares (Tam Kısıtlı En Küçük Kareler Algoritması)
FUSE	: Fast fUision based on Sylvester Equation (Sylvester denklemine dayalı hızlı kaynaştırma)
GFPCA	: Guided Filter PCA (Rehber Süzgeç PCA)
GS-LS	: Gram Schmidt Least Square (Gram Schmidt En Küçük Kareler)
HS	: Hiperspectral (Hiperspektral)
HySime	: Hyperspectral Signal Subspace Identification by Minimum Error (En Küçük Hata ile Hiperspektral İşaret Altuzay Belirleme)
LiDAR	: Light Detection And Ranging (Işık Bulan ve Tarayan)
LKM	: Linear Mixing Model (Lineer Karışım Modeli)
LP	: Laplacian Pyramid (Laplacian Piramidi)
MAP	: Maximum A Posteriori (Maksimum Deney Sonsalı)
MMSE	: Minimum Mean Square Error (En Küçük Ortalama Karesel Hata)
MS	: Multispectral (Multispektral)
MTF	: Modulation Transfer Function (Algılayıcı Modülasyon Transfer Fonksiyonu)
MTF-GLP	: Generalized Laplacian Pyramid with MTF - matched filter (Modülasyon Transfer Fonksiyonu Eşlemeli Genelleştirilmiş Laplacian Piramidi)
MTF-GLP-HPM	: Generalized Laplacian Pyramid with MTF - matched filter High Pass Modulation (Modülasyon Transfer Fonksiyonu Eşlemeli Yüksek Geçiren Modülasyonlu Genelleştirilmiş Laplacian Piramidi)
MUR	: Multiplicative Update Rule (Çarpımsal Güncelleme Kuralı)

NMF	: Non Negative Matrix FaktORIZATION (Negatif Olmayan Matris Faktörizasyonu)
PAN	: Pancromatic (Pankromatik)
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
PPI	: Pixel Purity Index (Piksel Saflık İndeksi)
PSF	: Point Spread Function (Nokta Yayılım Fonksiyon)
PSNR	: Peak Signal to Noise Ratio (Sinyalin Gürültüye Oranı)
RMSE	: Root Mean Square Error (Kök Ortalama Kare Hata)
SALSA	: Split Augmented Lagrangian Shrinkage Algorithm (Bölünmüş Artırılmış Lagrange Büzülme Algoritması)
SAM	: Spectral Angle Mapper (Spektral Açık Eşleme)
SMA	: Spectral Mixture Analysis (Spektral Karışım Analizi)
SMM	: Stochastic Mixing Model (Stokastik Karışım Modelini)
SRF	: Spectral Response Function (Algılayıcı Spektral Yanıt Fonksiyonu)
SSIM	: Structural Similarity Index (Yapısal Benzerlik İndeksi)
SVD	: Singular Value Decomposition (Tekil Değer Parçalaması)
UIQI	: Universal Image Quality Index (Evrensel Görüntü Kalite İndeksi)
VCA	: Vertex Component Analysis (Köşe Bileşeni Analizi)
WT	: Wavelet Dönüşümü (Wavelet Transformü)

HİPERSPEKTRAL VERİLER İÇİN KAYNAŞTIRMA İLE UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

ÖZET

Uzaktan algılama sistemlerinde kullanılan önemli teknolojilerden biri olan hiperspektral görüntüler sahip oldukları fazla miktardaki spektral bant sayesinde sahnede bulunan nesnelere hakkında daha ayrıntılı bilgi sunmaktadır. Ancak fiziksel kısıtlamalardan dolayı spektral çözünürlüğü yüksek olan bu hiperspektral görüntülerinin uzamsal (yerel) çözünürlüğü düşüktür. Bu tezde, hiperspektral görüntülerin çözünürlüğünün karışım giderimi temelli yaklaşımlar kullanılarak artırılması hedeflenmiştir.

Bunun için bir alt yapı oluşturması amacıyla öncelikle pankromatik ve multispektral görüntülerin pankeskinleştirilmesi üzerinde durulmuştur. Standart ve en son kabul edilen yaklaşımlar incelenmiştir. Bu amaçla ilk olarak, bu pankeskinleştirme yaklaşımları Türkiye'nin uyduları olan RASAT ve GÖKTÜRK-2 görüntüleri üzerinde uygulanarak çözünürlüğü artırılmış pankeskinleştirilmiş görüntüler elde edilmiştir. Ayrıca GÖKTÜRK-2 uydu görüntülerinin MTF ve SRF değerleri ilgili pankeskinleştirme yaklaşımlarında literatürde ilk defa kullanılmıştır. CNMF [82]'ye yeni kısıtlamalar eklenerek hiperspektral karışım giderimi başarımları gerçekleştirilmiştir. Daha sonra, Hiper-graf düzenleyicisine dayalı hiperspektral karışım giderimi LiDAR verisi ile gerçekleştirilmiştir. Son olarak ise, hiperspektral karışım gideriminde spektral değişkenliği azaltmak için, LiDAR - DSM bölütleme bilgisi kullanılarak hiperspektral görüntüsünden özellik çıkarımı gerçekleştirilmiştir. Ayrıca elde edilen bütün görsel ve sayısal sonuçlar ayrıntılı yorumlarıyla beraber sunulmuştur.

Anahtar Kelimeler: Hiperspektral, Hiperspektral Çözünürlük Artırımı, Karışım Giderimi, LiDAR, Veri Kaynaştırması.

HYPERSPECTRAL SPATIAL RESOLUTION ENHANCEMENT BY USING DATA FUSION AND UNMIXING

ABSTRACT

Hyperspectral images, which are one of the most important technologies used in remote sensing systems, provide more information about the objects on the scene due to the spectral bands. However, due to physical constraints high spectral resolution hyperspectral images have low spatial (local) resolution. In this thesis, it is aimed to increase the spatial resolution of hyperspectral images by using unmixing based approaches.

For this purpose, firstly, it has been investigated pansharpening between panchromatic and multispectral images. Standard and the state-of-the-art pansharpening approaches have been implemented. These pansharpening approaches are applied to Turkey's satellites RASAT and GÖKTÜRK-2 images in order to generate high spatial and high spectral resolution pansharpened images. In addition, the values of MTF and SRF of GÖKTÜRK-2 satellite have been used firstly in the literature for the related pansharpening approaches. It has been obtained high resolution hyperspectral images by adding some constraints to CNMF [82] approach. Later, hyper-graph regularization is considered on hyperspectral unmixing with a LiDAR data-aided context. Finally, a new framework has been proposed that incorporates feature extraction with LiDAR - DSM clustering information to suppress the effect of spectral variability in hyperspectral unmixing. Besides, all obtained visual and quantitative results have been shown in the detailed description.

Keywords: Hyperspectral, Hyperspectral Spatial Resolution Enhancement, Unmixing, LiDAR, Data Fusion.

GİRİŞ

Gelişen teknolojiyle birlikte hiperspektral görüntüleme hem uzaktan algılama hem de bilgisayarlı görüde sahnedeki olay veya nesnelere hakkında daha ayrıntılı bilgi verme konusunda büyük bir olanak sağlamaktadır. Hiperspektral görüntülerinin elde edilmesi ve bu elde edilen görüntülerden anlamlı bilgi çıkartılarak yorumlanması oldukça önemlidir. Hiperspektral uzaktan algılama verileri hava ve uzay kaynaklı sistemlerden elde edilebilmektedir. 'Hyper', 'aşırı' ya da 'çok fazla' anlamındadır ve çok fazla sayıda ölçülen dalga boyu bantlarına karşılık gelmektedir. Hiperspektral görüntüleme, yüzeyde bulunan materyallerden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandı tarafından ölçümüdür. Hiperspektral görüntülerinin önemli karakteristik özellikleri incelendiğinde en başta fazla sayıda spektral bant bilgisi sunmaları sayılabilir. Hiperspektral sensörler bu zengin spektral bilgi içeriğiyle yeryüzü yüzeyinde bulunan nesnelere kolaylıkla ayırt edilebilmesine olanak sağlamaktadır. Elde edilen görüntünün her bir pikselinin spektral bantları, o pikselde bulunan özelliğin spektral imzasını vermektedir. Böylelikle, o pikselde su, toprak ya da bitki örtüsü gibi özelliklerden hangisinin olduğu kolaylıkla ayırt edilebilmektedir [1].

Hiperspektral sensörlerin sunduğu görüntüler, çok bantlı multispektral görüntülerinden farklı olarak çok daha fazla bantta sahiptirler. Ayrıca bu bantlar dar ve birbirine yakın bir şekilde bulunmaktadır. Her bir piksel için sensör elektromanyetik enerji miktarını kaydeder. Hiperspektral bir veri dendiğinde üç boyutlu bir veri kübünden söz edilmektedir. Bu kübün ilk iki boyutu uzamsal bilgi koordinatlarını, son boyut ise spektral bant bilgisini vermektedir.

Hiperspektral görüntüleme spektroskopik görüntüleme olarak da bilinmektedir. Bu görüntüleme, sahneden yansıyan enerjiyi onlar ya da yüzlerce bant ile ifade edilebilen dalga boylarına ayırmakta, böylelikle ilgili pikselde bulunan söz konusu materyalin doğru bir şekilde karakterize edilebilmesini sağlamaktadır. Bu elde edilen spektral bilgi içeriği sınıflandırma ve tespit gibi bir çok kullanım alanında büyük bir avantaj sağlamaktadır.

Hiperspektral görüntülemenin kullanım alanları arasında; orman bitki örtüsünün haritalandırılması ve sınıflandırılması, şehircilik ve arazi kullanımı, su kaynakları ve tarımsal ürünlerin türünün belirlenmesi, madencilik, jeoloji, mineral tespiti, şehir ve bölge planlama, tıp, mikrobiyoloji, endüstriyel kalite kontrolü gibi pek çok sivil ve askeri uzaktan algılama alanları sayılabilmektedir. Son yıllarda uzaktan algılama sensörlerinden elde edilen spektral bant sayısının fazlalığı, yeryüzünde bulunan objelerin daha ayrıntılı bir şekilde incelenmesine olanak sağlamaktadır. Uzaktan algılama alıcıları, bir sahneden, uzamsal çözünürlüğü yüksek pankromatik (PAN) ve/veya spektral çözünürlüğü yüksek çok bantlı (multispektral/hiperspektral-MS/HS) görüntüler elde etmek için kullanılmaktadır. Uzamsal çözünürlük, bir görüntüdeki fark edilebilir en küçük yapı ya da detay olarak tanımlanmaktadır. Bir alıcının uzamsal çözünürlüğü onun tasarım aşamasında belirlenmektedir. Spektral çözünürlük ise, spektrumdaki özellikleri açıklama yeteneği olarak tanımlanmaktadır. Spektral çözünürlüğün artması, uzamsal çözünürlüğün azalmasına ve ters yönlü uzamsal çözünürlüğün artması spektral çözünürlüğün azalmasına sebep olmaktadır. Çünkü, gelen sınırlı miktardaki ışık yüzlerce banda ayrıldığında uzamsal çözünürlükten ödün vermektedir. Modern hiperspektral alıcıları yeryüzündeki hedeften yansıyan güneş ışığını dar spektral kanallara örnekleyebilmektedir. Fakat, bu yükselen spektral çözünürlük düşük uzamsal çözünürlüğe sebep olmaktadır. Böylece, spektral bantların fazla olması uzamsal bilginin azalmasına neden olur. Yani, yeni bir spektral kanal eklemek ışığın bu kanala da parçalanması anlamına gelmektedir. Her bir kanalda yeterli miktarda ışığın kullanılabilmesi için alıcıdaki pikselin boyutu büyük olmak zorundadır. Bu durum uzamsal çözünürlüğün düşük olması ile sonuçlanmaktadır. Yani görüntüdeki geometrik detayların miktarında bir azalmaya sebep olmaktadır.

Optik uzaktan algılama alıcıları spektral bantların sayısına göre üç gruba ayrılabilir:

- i. Pankromatik (PAN) alıcı geniş spektral aralıkta tek bir görüntü alır
- ii. Multispektral (MS) alıcılar farklı spektral aralıklarda (bantlarda) eş zamanlı birkaç görüntüyü elde edebilirler
- iii. Hiperspektral (HS) alıcılar geniş spektral aralıkta çok sayıda dar spektral bantları kapsayan görüntüleri sağlarlar

Veri kaynaştırma, çoğunlukla farklı alıcılar ve görüntüleme teknolojileri tarafından elde edilen tek ya da çok boyutlu görüntülerden gelen ilgili bilgileri birleştirme işlemidir. Veri kaynaştırma uzaktan algılama görüntüleme teknolojilerinde önemli bir uygulama ve araştırma alanına sahiptir. Genel olarak veri kaynaştırma, yüksek uzamsal çözünürlüklü görüntüden yüksek frekans detaylarının çıkartılarak bu detayların düşük uzamsal çözünürlüklü görüntüye eklenmesiyle, yüksek uzamsal ve spektral çözünürlüklü görüntü elde etmeyi amaçlamaktadır. En yaygın yaklaşım, yüksek mekansal çözünürlüklü görüntünün yüksek spektral çözünürlüklü bir görüntüyle kaynaştırılmasıdır. Yüksek mekansal çözünürlüklü görüntü bir pankromatik görüntü ise, bu durumda kaynaştırma işlemi "pankeskinleştirme" olarak adlandırılmaktadır. Veri kaynaştırmada pankeskinleştirme, uzamsal çözünürlüğü yüksek olan pankromatik görüntüsünün detaylarının çıkartılarak spektral çözünürlüğü yüksek olan MS/HS görüntüye eklenmesi ile, hem uzamsal hem de spektral çözünürlüğü yüksek MS/HS görüntüsü elde etmeyi amaçlamaktadır. Arazi örtüsünün sınıflandırılması, özellik tespiti, sel, kirlilik kontrolü, haritalama, değişim tespiti ve kentsel alanların tespiti gibi birçok uygulama veri kaynaştırmadan fayda sağlamaktadır. Hiperspektral görüntüler sahnede bulunan nesnelere veya olaylar hakkında diğer birçok görüntü işleme teknolojilerine göre daha ayrıntılı bilgi vermektedir. Bu durum hiperspektral görüntülemenin her geçen gün daha çok kullanım alanı bulması ve tercih edilmesi nedenidir. Hiperspektral görüntüleme teknolojisi kullanılarak görüntülenen sahnenin yüksek uzamsal çözünürlüklü olması daha iyi sınıflandırma ya da tespit yapılabilmesi için istenilen bir durumdur.

RASAT, ilk defa Türkiye'de tasarlanıp, TÜBİTAK-UZAY (TÜBİTAK Space Technologies Research Institute) tarafından üretilen BİLSAT'tan sonra Türkiye'nin ikinci yeryüzü gözlem uydusudur. 2011 yılından bu yana görevini başarıyla gerçekleştirmektedir. RASAT 7,5 metre pankromatik ve 15 metre RGB uzamsal çözünürlüğe sahiptir. GÖKTÜRK-2 ise, Türk Savunma Bakanlığı, TÜBİTAK-UZAY ve Türk Havacılık ve Uzay Sanayii ile ortaklaşa ülkemizde tasarlanıp üretilen Türkiye'nin ilk yüksek çözünürlüklü uydusudur. 18 Aralık 2012'de Çin'in Jinquan şehrinde uzaya fırlatılmıştır. 2.5 metre pankromatik ve 5 metre multispektral uzamsal çözünürlüğüne sahiptir. Standart ve en çok kullanılan pankeskinleştirme yaklaşımları olan Bileşen Ekleme (Component Substitution-CS), Çok Çözünürlüklü Analiz

(Multiresolution Analysis-MRA), Hibrit (Hybrid) ve Varyasyonel (Variational methods) yaklaşımlar RASAT ve GÖKTÜRK-2 görüntüleri üzerinde uygulanmıştır. Deneyle, farklı özelliklere sahip birçok bölgeden alınan RASAT ve GÖKTÜRK-2 uydularının görüntüleri kullanılarak gerçekleştirilmiştir. Deneysel çalışmalar Wald's protokolü de dahil bir kaç protokol kullanılarak gerçekleştirilmiştir. Tez kapsamında pankeskinleştirme yaklaşımlarıyla beraber HS pankeskinleştirmeye özgü olan Bayesian yaklaşımı incelenmiştir.

Matris Faktörizasyonu, Bayesian Veri Kaynaştırması ve hiperspektral süper çözünürlük yaklaşımları AVIRIS sensöründen elde edilen Indian Pines, Moffett ve Cuprite veri setleri üzerinde MS-HS veri kaynaştırması amacıyla uygulanmıştır. Tezin son bölümünde ise, LiDAR-DSM yardımıyla HS verisinden özellik çıkartılarak, LiDAR verisi yardımıyla hiper-graf kısıtlı HS karışım giderimi gerçekleştirilmiştir. Ayrıca, LiDAR verisi kullanılarak HS karışım gideriminde spectral değişkenliğin azaltılması çalışması literatürde ilk defa gerçekleştirilmiştir.

Pankeskinleştirme ve veri kaynaştırma sonuçlarının değerlendirilmesinde niteliksel ve niceliksel olarak 7 tane değerlendirme kriteri kullanılmıştır. Niteliksel olarak görsel sonuçlar ve niceliksel sonuçlar ise, Kök Ortalama Karesel Hata (Root Mean Square Error - RMSE), Korelasyon Katsayısı (Correlation Coefficient - CC), Spektral Açık Eşleme (Spectral Angle Mapper - SAM), Boyutsuz Global Göreli Sentez Hatası (Erreur Relative Globale Adimensionnelle de Synthèse - ERGAS), Sinyalin Gürültüye Oranı (Peak Signal to Noise Ratio - PSNR), Yapısal Benzerlik İndeksi (Structural Similarity Index-SSIM) ve Evrensel Görüntü Kalite İndeksi (Universal Image Quality Index - UIQI) metodlarının kullanılmasıyla tablolar halinde sunulmuştur.

RMSE, SAM ve ERGAS için küçük sayısal değerler daha iyi performansı ifade ederken, CC, PSNR, SSIM ve UIQI için ise, büyük sayısal sonuçlar daha iyi performans sonucunu ifade etmektedir.

Bu tezde literatüre yapılan katkılar aşağıdaki şekilde ifade edilebilmektedir:

Tez çalışmasında pankeskinleştirme yöntemlerinin genel bir karşılaştırması yapılmış, karşılaştırmada RASAT ve GÖKTÜRK-2 uydu görüntüleri kullanılmıştır.

GÖKTÜRK-2 alıcısının MTF ve SRF değerleri bu değerleri kullanan pankeskinleştirme yaklaşımlarında literatürde ilk defa kullanılmıştır. Kümeleme temelli pankeskinleştirme yaklaşımı literatürde ilk defa hiperspektral pankeskinleştirmeden önce uygulanmış ve deneysel sonuçları paylaşılmıştır. MS-HS kaynaştırmasında Eşlemeli Negatif Olmayan Matris Ayırıştırma ile Görüntü Kaynaştırması koduna [82] yeni kısıtlar tanımlanarak yöntemin başarımı artırılmıştır. LiDAR verisi ile hiperspektral görüntülerin kaynaştırılması ile karışım giderimi probleminde farklı bir çözüm önerilmiştir. Ayrıca hiperspektral karışım giderimi için LiDAR verisi kullanılarak spectral değişkenliğin azaltılmasına yönelik etkin bir yöntem önerilmiştir.


Bu tez aşağıdaki gibi düzenlenmiştir:

Bölüm 1’de, Pankeskinleştirme Temelli hiperspektral karışım giderimi sunulmuştur. Pankeskinleştirmeye ilgili literatürde en çok ve en yeni olarak kullanılan pankeskinleştirme yöntemleri kapsamlı bir şekilde incelenmiş ve RASAT ile GÖKTÜRK-2 uydu görüntüleri üzerinde deneysel çalışmalar yapılarak bu yaklaşımların performans analizi gerçekleştirilmiştir. Ayrıca karışım giderimi anlatılarak, AVIRIS alıcısından elde edilen Indian Pines, Moffett ve Cuprite ile HYDICE alıcısından elde edilen Washington, D.C veri setleri üzerinde PAN-HS pankeskinleştirilmesi gerçekleştirilmiştir. Bölüm 2’de, CNMF [82] üzerine yeni kısıtlamalar eklenerek karışım giderimi başarımı artırılmıştır. Bölüm 3’de ise, LiDAR verisi yardımıyla hiperspektral görüntüsünden özellik çıkarımı gerçekleştirilmiş ve böylece hiperspektral görüntünün uzamsal çözünürlüğünü artıran etkili bir yöntem önerilmiştir. Yapılan deneyler, görsel sonuçlar ve tablo şeklinde ilgili bölümün sonunda sunulmuştur. Son bölümde, Tez kapsamındaki tüm çalışmaların ortak bir amaç için değerlendirilmesi yapılarak genel bir karşılaştırma yapılmaktadır.

1. PANKESKİNLEŞTİRME TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

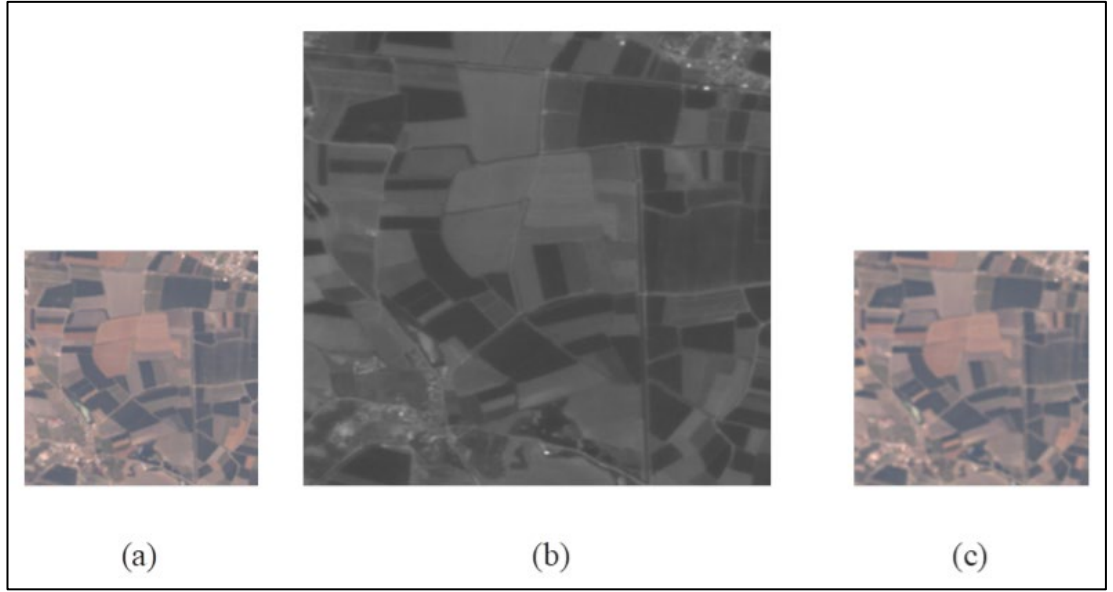
1.1 Pankeskinleştirme Yaklaşımları

Hiperspektral görüntülerin uzamsal çözünürlüğünün artırılması birçok uygulamada oldukça büyük bir önem taşımaktadır. Bu amaçla bu tezde, hiperspektral görüntülerin çözünürlüğünün artırılması için öncelikle PAN-MS görüntülerinin pankeskinleştirilmesi çalışılmış, daha sonra MS-HS ve LiDAR-HS görüntülerinin kaynaştırılması karışım giderimi temelli yaklaşımlar kullanılarak gerçekleştirilmiştir. Şekil 1.1.'de tez kapsamının amacı blok şeması şeklinde ifade edilmektedir.

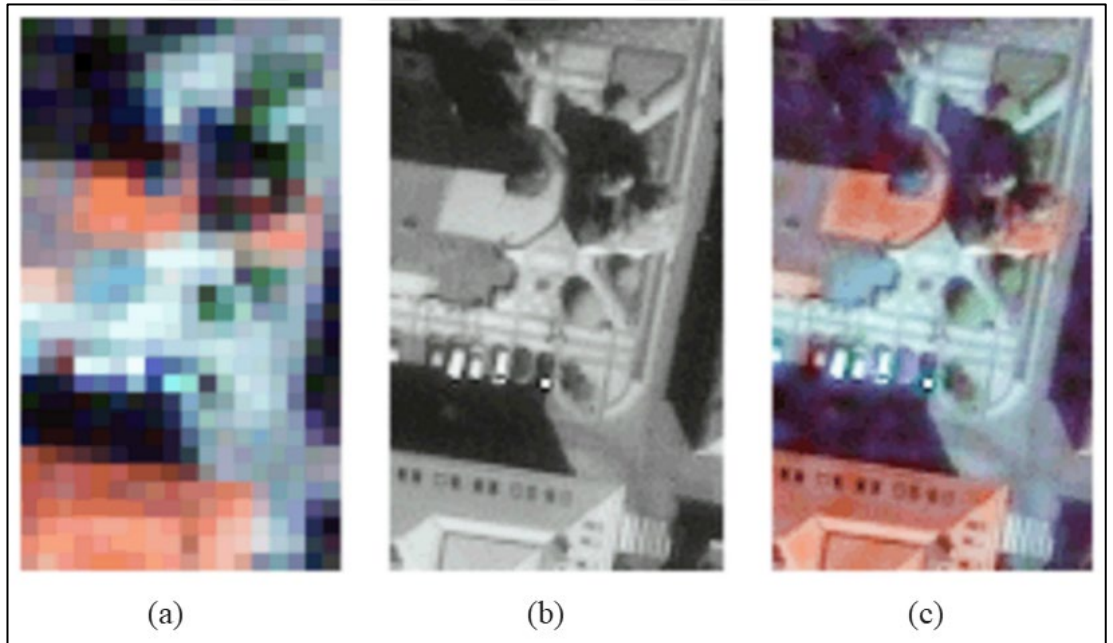


Şekil 1.1. Tez kapsamının blok şeması.

Pankeskinleştirme, çeşitli teknik sınırlamalardan dolayı doğrudan görüntü algılayıcılarından elde edilemeyen, yüksek mekansal ve yüksek spektral çözünürlüğe sahip görüntülerin oluşturulmasını amaçlayan bir yöntemdir. Pankeskinleştirme yaklaşımı uzamsal çözünürlüğü yüksek olan pankromatik görüntünün uzamsal detaylarının çıkartılıp, multispektral/hiperspektral görüntüye eklenerek, yüksek uzamsal çözünürlüklü multispektral/hiperspektral görüntü elde etme mantığına dayanmaktadır [3]. Pankeskinleştirme uzun zamandır önemli bir araştırma alanı olmuştur. Pankeskinleştirme işlemi öncelikle; pankromatik görüntülerle çok bantlı multispektral görüntülerine yüksek uzamsal çözünürlüklü multispektral görüntü elde etmek için uygulanmıştır, daha sonra PAN-HS görüntüleri ile MS-HS veri kaynaştırmasını içerecek şekilde geliştirilmiştir. Şekil.1.2 ve Şekil.1.3.'de pankeskinleştirme işleminin girdileri ve çıktısını gösterilmektedir:



Şekil 1.2. RASAT Mersin verisi için pankeskinleştirme girdi ve çıktı sonucu (a) RASAT verisi Mersin RGB görüntüsü, (b) RASAT verisi Mersin PAN görüntüsü, (c) RASAT verisi Mersin pankeskinleştirilmiş görüntü.



Şekil 1.3. Pankeskinleştirme işlemi girdileri a), b) ve çıktı sonucu c), a) MS görüntü, b) PAN görüntü, c) pankeskinleştirilmiş görüntü [4].

PAN-MS Pankeskinleştirme Literatür Çalışmalarına baktığımızda birçok pankeskinleştirme yaklaşımlarını inceleme çalışmaları olduğunu görebiliriz. Garzelli A. vd. [5], çeşitli pankeskinleştirme yaklaşımlarını QuickBird alıcı verileri için incelemiş ve içeriğe dayalı yaklaşımların en iyi sonuç verdiğini göstermişlerdir. HPF, IHS, SDM ve CBD yaklaşımlarının performansını karşılaştırmış ve CBD

yaklaşımının en iyi pankeskinleştirme sonucunu verdiğini belirtmişlerdir. Claire T. vd. [6], Yapı Enjeksiyonu ile Mekansal Çözünürlüğü Artırma (ARSIS) yaklaşımının spektral bozulmayı önlediğini vurgulamış ve veri kaynaştırması yöntemlerinin gruplarını tanıtmışlardır. Jinghui vd. [7] pankeskinleştirmeyi; bileşen ekleme, çok çözünürlüklü analiz ve modülasyon tabanlı teknik olmak üzere veri kaynaştırma mekanizmalarına göre üç kategoriye ayırmışlardır. Amro vd. [8], pankeskinleştirme yaklaşımlarını kullanım mekanizmalarına göre sınıflandırmışlardır.

Zhang Y. ve Mishra R. K., [9] pankeskinleştirme yaklaşımlarının bir sınıflandırması gerçekleştirilmiştir. Yun Z. ve Rakesh M. K., [10], IKONOS, QuickBird, GeoEye-1 ve WorldView-2 alıcılarından alınan görüntüler üzerinde, ticari yazılım paketleri kullanarak pankeskinleştirme yaklaşımlarının performanslarını karşılaştırılmış ve en iyi pankeskinleştirme kalitesini temel bileşen analizi (PCA) yaklaşımının verdiği sonucuna varmışlardır. Javier M. vd. [11], sekiz tane pankeskinleştirme yaklaşımını çeşitli uzamsal ve spektral kalite değerlendirme metriklerini kullanarak incelemiş ve Atrous_IHS, Atrous_PCA, IHS ve eFIHS yaklaşımlarının en iyi uzamsal-spektral ödünleşimi sağladığını belirtmişlerdir. Vivone G. vd. [12], on yedi tane en yeni olarak kullanılan gelişmiş pankeskinleştirme yaklaşımlarını multispektral/hiperspektral pankeskinleştirme için hesaplamış, IKONOS-2 ve WorldView-2 alıcılarından alınmış görüntüler üzerinde yapılan çalışmalar neticesinde MTF-GLP-HPM ve BDSB yaklaşımlarının en iyi pankeskinleştirme sonucunu verdiğini göstermişlerdir.

Gemine V. vd. [13], IKONOS-2 ve WorldView-2 alıcılarından alınan görüntülere, ileri düzeyde geliştirilmiş Generalized Laplacian Pyramid with MTF-matched filter ve Context-Based Decision injection scheme (MTF-GLP-CBD) gibi pankeskinleştirme yaklaşımlarını uygulamış ve en iyi sonucu MTF-GLP-HPM yönteminden elde etmişlerdir.

Loncan L. vd. [14], on bir farklı pankeskinleştirme yaklaşımını karşılaştırmış ve Bayesian sparse yaklaşımının en iyi performansı verdiğini göstermişlerdir. Vaiopoulos A. D. ve Karantzas K. [15]'da, yirmi bir tane pankeskinleştirme yaklaşımını tanıtmış ve VNIR ile SWIR bantları için sonuçlar hesaplamışlardır. Sonuç olarak, MTF-GLP-CBD yaklaşımının en iyi sonuç verdiğini göstermişlerdir.

Literatürde HS-PAN veya HS-MS veri kaynaştırma yaklaşımları hakkında çeşitli çalışmalar bulunmaktadır. [16]'da, negatif olmayan matris faktörizasyonu (Non-Negative Matrix Factorization - NMF) metoduna dayalı uzaydaki ve yer yüzündeki mid-IR teleskobundan alınan görüntüler üzerinde kaynaştırma gerçekleştirilerek hassasiyet, spektral içerik ve açısal çözünürlük bakımından üstün pankeskinleştirilmiş görüntü oluşturulmuştur. Üç tane farklı veri seti üzerinde, Brovey, BDS, GSA, ATWT, MTF-GLP-HPM, MTF-GLP-CBD, CNMF ve Hysure metodları karşılaştırılmıştır. [17]'de 11 farklı son teknoloji pankeskinleştirme yöntemi HS görüntülerine uyarlanmış, Bayesian Sparse yaklaşımının PAN-HS pankeskinleştirmesi için en iyi performansı sağladığı gösterilmiştir. [38]'de bileşen ekleme ve çok çözünürlüklü analiz grubuna giren bazı klasik pankeskinleştirme teknikleri Hyperion/ALI and CHRIS-Proba/QuickBird sensörlerinden alınan HS görüntülerinin pankeskinleştirilmesi için kullanılmıştır. PCA, GS1, GSA, SFIM, GLP-MTF ve MTF-HPM pankeskinleştirme yaklaşımlarının başarımları iki farklı veri seti üzerinde gerçekleştirilmiştir. [18]'de uzaktan algılama görüntü kaynaştırmasından MS-HS veri kaynaştırmasına bir çözüm oluşturan 'hypersharpener' adında yeni bir paradigma sunulmaktadır. SIM-GA görüntüleyicisinden alınan görüntüler üzerinde denemek üzere iki farklı 'hypersharpener' yaklaşımı VNIR ve SWIR veri setleri üzerine uygulanmış, hypersharpener'in pansharpener'e göre daha etkili olduğu sonucuna varılmıştır. [19]'de, saf materyal imzalarını içeren son elemanların alt uzay çıkarımı için, seyrek karışım giderimi yaklaşımı (sparse unmixing technique) kullanılmış, Bayesian veri kaynaştırma modeliyle birleştirilerek veri kaynaştırmada global başarımlar elde edilmiştir. [20]'de, bir görüntü için bölütleme gerçekleştirilerek HS pankeskinleştirme görüntüleri üzerinde global ve lokal kazanç faktörü belirlenmiştir. [21]'de, spektral açı kısıtlaması kullanılarak pankromatik ve hiperspektral görüntüleri üzerinde modülasyon tabanlı pankeskinleştirme algoritması gerçekleştirilmiştir. [22]'de, uzamsal ve spektral kalite kısıtlaması optimizasyonuna dayalı, QNR kalite değerlendirme indeksi kullanılarak pankeskinleştirme algoritması gerçekleştirilmiştir. [23]'de, tekli ya da çoklu platformlardan gelen görüntülerin kaynaştırma sonuçları verilmiş ve EXP, PCA, GSA, AWLP, MTF-GLP-HPM, HySure ve CNMF metodlarının performansı karşılaştırılmıştır. [24]'de, sentetik hiperspektral bantlarının ağırlıklarını hesaplamak için, pankromatik ve hiperspektral bantları farklı gruplara ayrılarak, aralarında çoklu lineer regresyon

analizi yapılmıştır. Bu ağırlıklar kullanılarak düşük çözünürlüklü pankromatik görüntü sentezlenmekte, pankromatik görüntü bu sentez görüntüye bölünerek oran iyileştirmeyle hiperspektral pankeskinleştirme gerçekleştirilmiştir. [25]'de, modele dayalı analiz (model based analysis) kullanılarak karışım giderimi temelli MS-PAN görüntülerine pankeskinleştirme algoritmaları uygulanmıştır. [26]'da bir tane multispektral bandı ile hiperspektral bantları arasında pankeskinleştirme yaklaşımları gerçekleştirilmiştir.

RASAT Alıcısının pankeskinleştirme yaklaşımları hakkında bazı çalışmalar bulunmaktadır. Bunlar şu şekilde özetlenebilir: Teke M. vd. [27] farklı pankeskinleştirme yaklaşımlarını, altı tane değerlendirme kalite metriği kullanarak RASAT görüntüleri için hesaplamış, HCS ve HPF yaklaşımlarının en iyi pankeskinleştirme sonucunu verdiğini göstermişlerdir. Teke M. vd. [28], otomatik görüntü işleme akış diyagramını RASAT ve GÖKTÜRK-2 alıcı görüntüleri için hazırlamışlardır. Ozendi M. vd. [29], IHS, Brovey ve PCA pankeskinleştirme yaklaşımlarının performansını RASAT ve GÖKTÜRK-2 görüntüleri için hesaplamışlardır.

GÖKTÜRK-2 görüntülerinin pankeskinleştirilmesi ile ilgili literatürde bazı çalışmalar bulunmaktadır. Bunlar şu şekilde özetlenebilmektedir: Ozendi M. vd. [30], IHS, Brovey ve PCA pankeskinleştirme yaklaşımlarını RASAT ve GÖKTÜRK-2 alıcı görüntüleri için analiz etmiş ve RASAT için PCA'nın, GÖKTÜRK-2 için ise, BT tekniğinin en iyi sonucu verdiğini göstermişlerdir. [31-33]'da GÖKTÜRK-2 alıcısı için, ortorektifikasyon ve radyometrik kalibrasyon çalışmaları ve [34-36]'da bazı pankeskinleştirme yaklaşımları incelenmiştir. Evrensel bir sınıflandırma olmamasına rağmen, pankeskinleştirme yaklaşımları temel olarak dört ana grupta incelenebilmektedir: Bunlar; Bileşen Ekleme (Component Substitution - CS), Çok Çözünürlüklü Analiz (Multi Resolution Analysis - MRA), Hibrit (Hybrid) ve Varyasyonel (Variational) yaklaşımlardır. Bu yöntemler kısaca aşağıda açıklanmaktadır.

1.1.1. Bileşen ekleme (Component substitution - CS)

Bileşen ekleme yaklaşımında düşük uzamsal çözünürlüklü multispektral/hiperspektral görüntüsü farklı bir uzaya yansıtılarak orada yüksek

uzamsal bilgiye sahip olan bileşen pankromatik görüntüsü ile yer değiştirilir ve son olarak ters dönüşüm ile gerçek uzaya geri dönülerek pankeskinleştirilmiş görüntü elde edilmektedir:

$$\begin{bmatrix} I \\ \vdots \\ C_{n-1} \end{bmatrix} = \begin{bmatrix} c_{11} & \cdots & c_{n1} \\ \vdots & \ddots & \vdots \\ c_{1n} & \cdots & c_{nm} \end{bmatrix} \begin{bmatrix} MS_1^1 \\ \vdots \\ MS_n^1 \end{bmatrix} \quad (1.1)$$

Bileşen ekleme adımları kısaca şu şekilde sıralanabilmektedir:

1. MS/HS görüntüsü, PAN görüntüsünün çözünürlüğüne dönüştürülür.
2. MS/HS görüntüsü yeni özellik uzayına (1.1) formülü kullanılarak dönüştürülür. Buradaki I bileşeni düşük uzamsal çözünürlüğe sahip PAN görüntüsüne benzer niteliğe sahiptir.
3. Bu yeni uzayda I bileşeni (görüntüsü) kendisi ile histogram eşitleme yapılan PAN görüntüsü ile yer değiştirilir.
4. Ters dönüşüm uygulanarak orijinal uzaya geri dönülür ve pankeskinleştirilmiş MS/HS görüntüsü elde edilir,

$$\begin{bmatrix} MS_1^h \\ \vdots \\ MS_n^h \end{bmatrix} = \begin{bmatrix} w_{11} & \cdots & w_{n1} \\ \vdots & \ddots & \vdots \\ w_{1n} & \cdots & w_{nm} \end{bmatrix} \begin{bmatrix} PAN \\ \vdots \\ C_{n-1} \end{bmatrix} \quad (1.2)$$

burada c ve w ileri ve geri dönüşüm matrisinin elemanlarıdır. İleri ve geri yönde matris hesaplamasından dolayı klasik bileşen ekleme metodları yüksek hesaplama karmaşıklığına sahiptir.

Aşağıdaki basit linear denklem kullanılarak bu dezavantajın üstesinden gelinmektedir. CS metodu aşağıdaki denklem kullanılarak daha basit bir şekilde formüle edilebilmektedir [37],

$$\begin{aligned} \begin{bmatrix} MS_1^h \\ \vdots \\ MS_n^h \end{bmatrix} &= \begin{bmatrix} w_{11} & \cdots & w_{n1} \\ \vdots & \ddots & \vdots \\ w_{1n} & \cdots & w_{nm} \end{bmatrix} \begin{bmatrix} I+(PAN-I) \\ \vdots \\ C_{n-1} \end{bmatrix} \\ &= \begin{bmatrix} w_{11} & \cdots & w_{n1} \\ \vdots & \ddots & \vdots \\ w_{1n} & \cdots & w_{nm} \end{bmatrix} \begin{bmatrix} I \\ \vdots \\ C_{n-1} \end{bmatrix} + \begin{bmatrix} w_{11} \\ \vdots \\ w_{11} \end{bmatrix} (PAN-I) \\ &= \begin{bmatrix} MS_1^1 \\ \vdots \\ MS_n^1 \end{bmatrix} + \begin{bmatrix} w_{11} \\ \vdots \\ w_{11} \end{bmatrix} .(PAN-I) \end{aligned} \quad (1.3)$$

Bu matris denklem gösterimi aşağıdaki linear denklem şeklinde kısaca gösterilebilmektedir,

$$\widehat{MS}_k = \widehat{MS}_k + g_k (P - I_L) = \widehat{MS}_k + w\delta_k \quad k= 1, \dots, N. \quad (1.4)$$

$$I_L = \sum_{k=1}^N \varphi_k \widehat{MS}_k \quad (1.5)$$

Burada \widehat{MS}_k pankeskinleştirmiş görüntüyü, N toplam bant sayısını, \widehat{MS}_k pankromatik görüntüsüne çözünürlüğü yükseltilmiş multispektral/hiperspektral görüntüsünü, I_L multispektral/hiperspektral görüntüsünden sentezlenmiş görüntüyü, g_k kazanç faktörünü, w_k modülasyon katsayısını ve δ ise, pankromatik görüntüsünün uzamsal detayını ifade etmektedir.

Bileşen eklemeye dayalı pankeskinleştirme yaklaşımları hesaplama olarak hızlı, implemente edilmesi kolay ve uzamsal olarak iyi görsel sonuçlar vermesine rağmen, temel dezavantajı spektral bantlarda bozulmaya sebep olmasıdır. Aşağıdaki bölümde standart ve en çok kullanılan bileşen ekleme yaklaşımları incelenmektedir.

1.1.1.1. Işıklılık, renk tonu, doygunluk (Intensity hue saturation - IHS)

Işıklılık, Renk Tonu, Doymunluk yaklaşımı standart bileşen ekleme yaklaşımlarındandır. Işıklılık bileşeni bütün multispektral/hiperspektral bantlarının ortalamasını alarak elde edilmektedir. Daha sonra bu görüntü kendisi ile histogram eşitlemesi yapılan pankromatik görüntüsünden çıkartılarak, uzamsal detay matrisi oluşturulmaktadır. Bu detaylar her bir multispektral/hiperspektral bandına ayrı ayrı eklenerek pankeskinleştirilmiş görüntü elde edilmektedir [38].

1.1.1.2. Brovey dönüşümü (BT)

BT tekniğinde, sentetik pankromatik görüntü multispektral/hiperspektral bantlarının ortalaması alınarak oluşturulmaktadır.

Pankromatik görüntü, elde edilen bu sentetik görüntüye bölünerek herbir multispektral/hiperspektral bandıyla çarpılmaktadır. Böylelikle pankeskinleştirilmiş görüntü elde edilmektedir [39].

1.1.1.3. Temel bileşen analizi (Principal component analysis - PCA)

PCA yaklaşımında temel bileşenleri elde etmek için multispektral/hiperspektral görüntü yeni özellik uzayına dönüştürülmektedir. İlk temel bileşenin en çok enerji ve en çok uzamsal bilgiyi içerdiği kabul edilmektedir. Bu bileşen kendisi ile histogram eşitlemesi yapılan pankromatik görüntü ile yer değiştirilir. Ters PCA dönüşümü uygulanarak pankeskinleştirilmiş görüntü elde edilmektedir [40]. PCA dönüşümü temel bileşen ekleme formatında (1.4) ifade edilebilmektedir [38].

1.1.1.4. Gram Schmidt (GS)

GS pankeskinleştirme tekniğinde sentetik pankromatik görüntü çeşitli modlar kullanılarak elde edilmektedir. Bu modlar üç tanedir: İlk modda, multispektral/hiperspektral görüntünün ortalaması sentetik pankromatik görüntü olarak alınmaktadır. İkinci modda, pankromatik görüntünün alçak geçiren filtrelenmiş versiyonu sentetik pankromatik görüntü olarak alınmaktadır. Son mod olarak ise, multispektral/hiperspektral ve pankromatik görüntü arasında en küçük kareler regresyon analizi (Gram Schmidt Least Square, GS-LS) yapılarak sentetik pankromatik görüntü elde edilmektedir. Elde edilen bu sentetik pankromatik görüntü orijinal pankromatik görüntüden çıkartılarak uzamsal detaylar elde edilmektedir. Pankromatik görüntünün çözünürlüğüne yükseltelen MS görüntüsünün her bir bandına elde edilen detaylar eklenerek pankeskinleştirilmiş görüntü elde edilmektedir. Genel bileşen ekleme denklemindeki (1.4) kazanç faktörü g_k değeri GS pankeskinleştirme yaklaşımında aşağıdaki gibi tanımlanmaktadır [41],

$$g_k = \frac{\text{cov}(\overline{MS}_k, I_L)}{\text{var}(I_L)} \quad k=1, \dots, N. \quad (1.6)$$

burada $\text{cov}(\cdot)$ kovaryans matrisi ve $\text{var}(\cdot)$ varyans değeridir.

1.1.1.5. Hiperküre renk uzayı (Hyperspherical color space - HCS)

Hiperküre Renk Uzayı yaklaşımında, multispektral/hiperspektral görüntü n-boyutlu renk uzayına dönüştürülmektedir. Daha sonra pankromatik görüntünün karesi ile ışıklılık bileşeninin karesi arasında histogram eşitlemesi yapılmaktadır. Histogram eşitlemesi yapılan pankromatik görüntü ışıklılık bileşeni ile yer değiştirilmektedir.

Pankeskinleştirilmiş görüntü ters HCS dönüşümü uygulanarak elde edilmektedir [42]. HCS pankeskinleştirme yaklaşımı kolaylıkla bileşen ekleme genel formatında (1.4) ifade edilebilmektedir [43].

1.1.1.6. Yüksek geçiren filtre (High pass filter - HPF)

HPF pankeskinleştirme yaklaşımında pankromatik görüntüden yüksek frekans detayları, yüksek geçiren filtre kullanılarak çıkartılmaktadır. Daha sonra bu detaylar bir katsayı ile çarpılarak multispektral/hiperspektral görüntünün bantlarına ayrı ayrı eklenerek pankeskinleştirilmiş görüntü elde edilmektedir [44].

1.1.1.7. University of New Brunswick (UNB)

UNB pankeskinleştirme tekniğinde, öncelikle pankromatik ve multispektral/hiperspektral bantları arasında regresyon analizi kullanılarak ağırlık değerleri elde edilmektedir. Daha sonra bu ağırlık değerleri kullanılarak sentetik pankromatik görüntü, multispektral/hiperspektral bantlarının ağırlıklı toplamı şeklinde elde edilmektedir.

Pankeskinleştirilmiş görüntüyü elde etmek için pankromatik görüntü sentetik pankromatik görüntüye bölünerek her bir multispektral/hiperspektral bandıyla çarpılmaktadır [45]. Bu çalışmada regresyon analizi olarak Tam Kısıtlı En Küçük Kareler (Fully Constraint Least Squares - FCLS) Algoritması kullanılmıştır.

1.1.1.8. Kısmi yer değiştirmeye dayalı bileşen ekleme (Partial replacement adaptive component substitution - PRACS)

PRACS tekniği ilk olarak yüksek ve alçak çözünürlüklü sentetik bileşen görüntüsünü, kısmi yer değiştirme kullanarak multispektral/hiperspektral ve pankromatik görüntüleri arasında linear regresyon ve korelasyon katsayıları cinsinden elde etmektedir.

Daha sonra, pankromatik ve multispektral/hiperspektral bantları arasındaki farkı minimize etmek için bazı katsayılar hesaplanmaktadır. PRACS yaklaşımı aşağıdaki şekilde förmüle edilebilmektedir [46],

$$MS_k^h = MS_k^h + w_k \delta_k L_{l_k} \quad k=1, \dots, N. \quad (1.7)$$

Burada w_k istatistiksel oran digital sayı DN (digital numbers) değerlerini, δ_k yüksek ve alçak çözünürlüklü sentetik bileşen görüntüsünün kendisi ve ortalama değerleri arasındaki farkı ve L_{1_k} ise, regularizasyon parametresini ifade etmektedir.

1.1.1.9. Gram Schmidt Gaussian Laplacian Pyramid - GS2-GLP

Normal GS pankeskinleştirme yaklaşımından farklı olarak GS2-GLP pankeskinleştirme yaklaşımında, alıcı SRF değerleri kullanılarak pankromatik görüntü Gauss alçak geçiren süzgeçten geçirilmektedir. Diğer bütün adımlar GS pankeskinleştirme yaklaşımıyla aynıdır [47].

1.1.1.10. Banda bağlı uzamsal detay (Band dependent spatial detail – BDS)

BDS yaklaşımında, en küçük ortalama karesel hata (Minimum Mean Square Error – MMSE) anlamında MS-PAN arasında pankeskinleştirme gerçekleştirilmektedir. Bu yaklaşımda, uzamsal olarak bozulmuş multispektral/hiperspektral görüntü ile aynı oranda bozulmuş pankromatik görüntünün karesel hatasını minimize ederek çözüm oluşturulmaktadır [48].

1.1.2. Çok çözünürlüklü analiz (Multiresolution analysis - MRA)

Bileşen ekleme yaklaşımlarının spektral bozulmaya sebep olan dezavantajından kurtulabilmek için MRA yaklaşımları geliştirilmiştir. MRA yaklaşımlarında, multispektral/hiperspektral ve pankromatik görüntüleri frekans bileşenlerine ayrılmaktadır. Daha sonra pankromatik görüntünün yüksek frekans bileşenlerinden gelen detaylar pankromatik görüntünün çözünürlüğüne yükseltilmiş multispektral/hiperspektral görüntünün frekans bantlarına eklenmektedir. Çok çözünürlüklü analize dayalı pankeskinleştirme yaklaşımları, bileşen ekleme metodlarına göre spektral bilgiyi daha iyi korumaktadır. Çok çözünürlüklü analiz yöntemlerinden en çok kullanılanları arasında Wavelet Dönüşümü, Laplacian Pyramid sayılabilmektedir [49].

Her iki dönüşüm de bir piramit yapısına sahiptir. Uzamsal çözünürlüğü yapısal ekleme ile artırma olarak bilinen bu yapı (Amélioration de la Résolution Spatiale par Injection de Structures-Improving Spatial Resolution by Structure Injection - ARSIS) kavramı olarak adlandırılmaktadır [50]. ARSIS kavramı, multispektral/hiperspektral

görüntünün eksik olan uzamsal bilgisini, pankromatik görüntünün piramit üzerindeki yüksek frekanslarından (seviye-0 ve seviye-1 arasından) elde etmektedir. Çok çözünürlüklü analiz yaklaşımları kısaca aşağıdaki formül ile ifade edilebilmektedir [49],

$$\widehat{MS}_k = \widehat{MS}_k + G_k(P-I_L) \quad k=1,\dots,N. \quad (1.8)$$

Burada \widehat{MS}_k pankromatik çözünürlüğüne yükseltilmiş multispektral/hiperspektral görüntüyü, \cdot eleman-eleman çarpımı, P_L ise, pankromatik görüntünün alçak-geçiren süzgeçten geçirilmiş şeklini ifade etmektedir.

MRA'ya dayalı pankeskinleştirme yaklaşımları zamansal uyumluluk, spektral tutarlılık ve örtüşmeye karşı gürbüzlük avantajlarına sahiptir. Yüksek karmaşıklığa sahip olması, çok çözünürlüklü analiz yaklaşımlarının dezavantajı olarak sayılabilmektedir [51].

1.1.2.1. Yumuşatma süzgeci tabanlı yoğunluk modülasyonu (Smoothing filter based intensity modulation - SFIM)

Yumuşatma Süzgeci Tabanlı Yoğunluk Modülasyonu tekniği, pankromatik ve onun alçak geçiren süzgeçlenmiş versiyonu arasındaki oranı kullanan bir pankeskinleştirme yaklaşımıdır. Sonrasında bu oran her bir multispektral/hiperspektral bandıyla ayrı ayrı çarpılarak pankeskinleştirilmiş görüntü elde edilmektedir [52].

1.1.2.2. Spektral simülasyon renk normalizasyonu (Spectral simulation color normalization -SSCN)

Spektral Simülasyon Renk Normalizasyonu pankeskinleştirme yaklaşımında, alıcı SRF değerleri kullanılmaktadır. Pankromatik ve multispektral/hiperspektral görüntülerin SRF değerleri arasında FCLS regresyon analizi kullanılarak ilgili ağırlık değerleri hesaplanmaktadır. Simüle edilmiş pankromatik görüntü bu ağırlıklar kullanılarak elde edilmektedir. Pankromatik ve pankromatik ile histogram eşitlemesi yapılmış simüle pankromatik görüntülerin birbirlerine oranı, her bir multispektral/hiperspektral bandı ile çarpılarak pankeskinleştirilmiş görüntü elde edilmektedir [53].

1.1.2.3. Wavelet dönüşümü (Wavelet transform - WT)

Wavelet dönüşümü bir görüntüyü yüksek ve alçak frekans bileşenlerine ayırmaktadır. Wavelet dönüşümüne dayalı pankeskinleştirmede pankromatik ve her bir multispektral/hiperspektral bandı arasında histogram eşitlemesi gerçekleştirilmektedir. Daha sonra Wavelet dönüşümü histogram eşitlemesi yapılan pankromatik görüntüye uygulanmaktadır. Wavelet parçalaması sonucu elde edilen görüntülerden sadece bulanık (blur) görüntü alınarak, diğer bileşenler sıfıra eşitlenmektedir. Ters WT uygulanarak orijinal uzayda düşük çözünürlüklü pankromatik görüntü elde edilmektedir. Elde edilen düşük çözünürlüklü görüntü orijinal pankromatik görüntüden çıkartılarak detay matrisi elde edilmektedir. Bu detay matrisinin her bir multispektral/hiperspektral bandına eklenmesi ile pankeskinleştirilmiş görüntü elde edilmektedir [54].

1.1.2.4. Eklemeli Dalgacık Parlaklığı (Additive Wavelet Luminance - AWL)

Eklemeli Dalgacık Parlaklığı yaklaşımı çok çözünürlüklü pankeskinleştirme yaklaşımlarından biridir.

İlk olarak üç bantlı (RGB) görüntüler için tanımlanmıştır [55]. AWL yaklaşımında yüksek çözünürlük detayları multispektral/hiperspektral görüntünün parlaklık bileşenine eklenmektedir. Bunun için RGB uzayından IHS renk uzayına dönüşüm uygulanmaktadır. Pankromatik ve ışıklılık bileşeni arasında histogram eşitlemesi gerçekleştirilmektedir. Daha sonra, pankromatik ve ışıklılık bileşeni Wavelet düzlemlerine ayrılmaktadır. Pankromatik görüntünün yüksek uzamsal detayları ışıklılık bileşeninin Wavelet katsayılarına eklenmektedir. Detay eklenmiş olan ışıklılık bileşeni üzerinde ters Wavelet ve ters IHS dönüşümü uygulanarak pankeskinleştirilmiş görüntü elde edilmektedir.

Orijinal AWL yaklaşımı üç banttan fazla bant içeren görüntüler için aşağıdaki gibi genelleştirilebilmektedir [56],

$$\widehat{MS}_k = \widehat{MS}_k + \frac{\widehat{MS}_k}{\frac{1}{N} \sum_{n=1}^N \widehat{MS}_k} (P-I_L) \quad k=1, \dots, N. \quad (1.9)$$

Burada \overline{MS}_k pankromatik görüntünün çözünürlüğüne yükseltilmiş olan multispektral / hiperspektral görüntüyü ifade etmektedir. Herbir multispektral / hiperspektral bandı toplam multispektral / hiperspektral bantlarının ortalamasına bölünerek kazanç faktörü elde edilmektedir. Bu değerın uzamsal detay bilgisi ile çarpılması spektral imza özelliğini korumaktadır. Bu tekniğe Oransal AWL yaklaşımı adı verilmektedir (Proportional AWL - AWLP).

1.1.2.5. A tróus Wavelet dönüřümü (A tróus wavelet transform - ATWT)

A Tróus Dalgacık dönüřümü, çok çözünürlüklü ve durađan dalgacık dönüřümü kullanılan wavelet ayrıştırma algoritmasıdır. A tróus WT pankeskinleştirme yaklaşımı orijinal WT'ye çok benzerdir, sadece kullanılan dönüřüm farklıdır.

A tróus WT önemli ölçüde azaltılmayan (undecimated) wavelet dönüřümüdür ve onun alçak geçiren süzgeç çekirdeđi ařađıdaki gibi tanımlanmaktadır [55],

$$h = \frac{1}{256} \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \quad (1.10)$$

1.1.2.6. Laplacian Piramit (Laplacian Pyramid - LP)

Burt and Adelson Gaussian Piramidi'ni (GP) kullanarak ilk olarak Laplacian Piramidi'ni (LP) tanımlamışlardır. GP'nin seviyeleri sırasıyla görüntünün alçak geçiren süzgeçlenmiş halini içermektedir. LP ise, aynı seviyedeki görüntüden genişletilmiş (interpole edilmiş) alçak geçiren süzgeçlenmiş şeklinin çıkartılmasıyla elde edilen detay görüntülerini içermektedir. Genişletilmiş LP (Enhanced LP-ELP), orijinal LP'ye sıfırncı seviye entropi ve düşük korelasyon özelliklerinin eklenmesiyle elde edilmektedir [57]. ELP'de LP'ye benzemeden genişletme ve azaltma (expansion and reduction) için farklı türde çekirdeklerin oluşturulması mümkündür. Genelleştirilmiş LP (Generalized LP-GLP), oran değerinin rasyonel sayı olması özelliđi katılarak ELP'den türetilmiştir. GLP kullanılarak pankeskinleştirme işlemi, LP kullanılarak pankromatik görüntüden detay elde etme işlemi ve bu detayların pankromatik çözünürlüğüne yükseltilmiş multispektral/hiperspektral görüntüye eklenmesiyle gerçekleştirilmektedir. GLP yaklaşımının A Tróus Dalgacık

dönüşümüne göre daha çok avantajlı olduğu gösterilmiştir [58]. Ölçüm oranı $p = 2$ olduğunda, örneğin; frekans octave parçalanması, 3, 7, 11, 15, 19 and 23. dereceden polinom çekirdekleriyle beraber katsayılar hesaplanabilmektedir [59]. Literatürde bütün bu LP'ye dayanan pankeskinleştirme yaklaşımlarının ismi olarak GLP kullanılmaktadır. Farklı çekirdeklerin Frekans Yanıt Fonksiyon (Frequency Response Function) değerleri dikkate alındığında düşük seviyeli görüntülerin genişletilmesi için 23tap süzgecinin literatürde LP'i oluşturmak için önerildiği görülmektedir [60]. Bu çalışmada da 23tap süzgeci kullanılmıştır. MTF, nokta yayılım fonksiyonu (Point Spread Function) sisteminin genlik spektrum değeridir. Görüntüleme sistemlerinin MTF değerleri multispektral/hiperspektral ve pankromatik görüntüleri için birbirinden farklıdır. Modülasyon Transfer Fonksiyonu Eşlemeli Genelleştirilmiş Laplacian Piramidi (Generalized Laplacian Pyramid with MTF - matched filter, MTF-GLP) diğer bir MRA'ya dayalı pankeskinleştirme yaklaşımıdır. MTF-GLP yaklaşımında, görüntüleme alıcısının MTF değerleri, GLP indirgeme süzgeci tasarlanırken kullanılmaktadır. MTF kullanılarak pankromatik görüntü üzerine GLP indirgeme süzgeci işlemi uygulandıktan sonra interpolasyon işlemi histogram eşitlemesi yapılan pankromatik görüntü üzerinde 23-tap süzgeci kullanılarak gerçekleştirilmektedir. Daha sonra detay görüntüsü, elde edilen düşük çözünürlüklü pankromatik görüntünün orijinal pankromatik görüntüden çıkartılması ile elde edilmektedir. Sonuç olarak bu detaylar orijinal multispektral/hiperspektral bantlarına eklenerek pankeskinleştirilmiş görüntü elde edilmektedir [61]. Modülasyon Transfer Fonksiyonu Eşlemeli Genelleştirilmiş Laplacian Piramidi Yüksek Geçiren Modülasyon (Generalized Laplacian Pyramid with MTF - matched filter High Pass Modulation, MTF-GLP-HPM) pankeskinleştirme yaklaşımı ise, MTF-GLP yaklaşımının adımlarını takip eder, sadece en son aşamada yüksek geçiren modülasyon metodu uygulanarak pankeskinleştirilmiş görüntü elde edilmektedir [62].

1.1.3. Hibrid yaklaşımlar (Hybrid approaches)

Bu yaklaşımda hem bileşen ekleme hem de çok çözünürlüklü analiz yöntemlerinin en uygun özelliklerinin birleştirilerek daha yüksek değerde uzamsal çözünürlüğe sahip pankeskinleştirilmiş görüntü elde edilmesi amaçlanmaktadır [63]. Ehlers fusion,

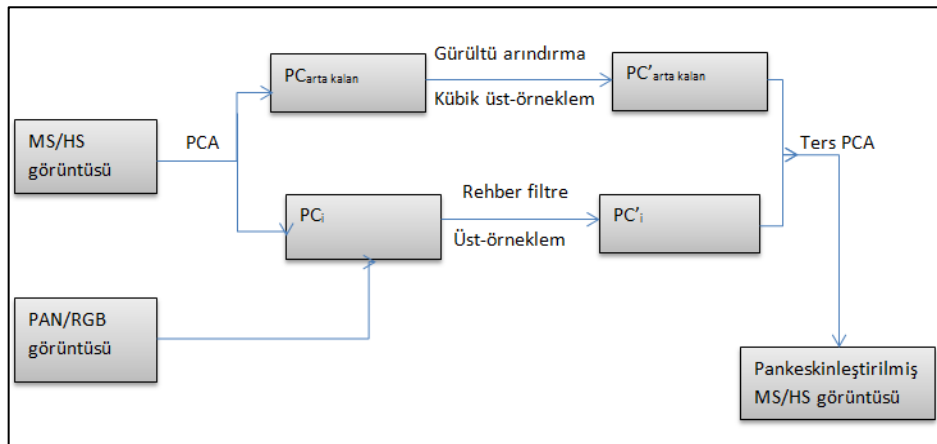
Rehber Süzgeç (Guided Filter PCA - GFPCA) ve IHS based wavelet dönüşümü sayılabilmektedir [64].

1.1.3.1. Ehlers veri kaynaştırma (Ehlers fusion)

Ehlers veri kaynaştırma yaklaşımı bir hibrid pankeskinleştirme yaklaşımıdır. Ehlers yaklaşımı, IHS dönüşümünü ve süzgeçleme olarak da Fourier uzayını kullanmaktadır. İlk olarak, multispektral / hiperspektral bantları IHS uzayına dönüştürülmektedir. Bu uzayda elde edilen ışıklılık bileşeni ve orijinal pankromatik görüntü, Fourier uzayına süzgeçlenmek amacıyla dönüştürülmektedir. Işıklılık bileşeni alçak geçiren süzgeçten ve pankromatik görüntü ise, yüksek geçiren süzgeçten geçirildikten sonra her iki filtreleme sonucuna ters Fourier dönüşümü uygulanmaktadır. Filtrelenmiş pankromatik görüntü, filtrelenmiş ışıklılık bileşenine eklenerek yeni ışıklılık bileşeni oluşturulmaktadır. Ters IHS dönüşümü uygulanarak pankeskinleştirilmiş görüntü elde edilmektedir [65].

1.1.3.2. Rehber süzgeç PCA (Guided filter PCA - GFPCA)

GFPCA pankeskinleştirme yaklaşımında, orijinal multispektral/hiperspektral görüntü temel bileşenlerine ayrılmaktadır. Kullanıcının belirleyebildiği ilk birkaç temel bileşen üst örneklenmiş pankromatik görüntü kullanılarak rehber süzgeçten geçirilmektedir. Kalan diğer temel bileşenler üzerine kübik üst-örneklem ve gürültü arındırma işlemi uygulanmaktadır. Elde edilen bu yeni temel bileşenler ters PCA dönüşümü uygulanarak pankeskinleştirilmiş görüntüyü oluşturmaktadır. GFPCA pankeskinleştirme yaklaşımı aşağıdaki gibi kısaca ifade edilebilmektedir [66]:



Şekil 1.4. Rehber Süzgeç Yaklaşımı (Guided Filter PCA – GFPCA) [55].

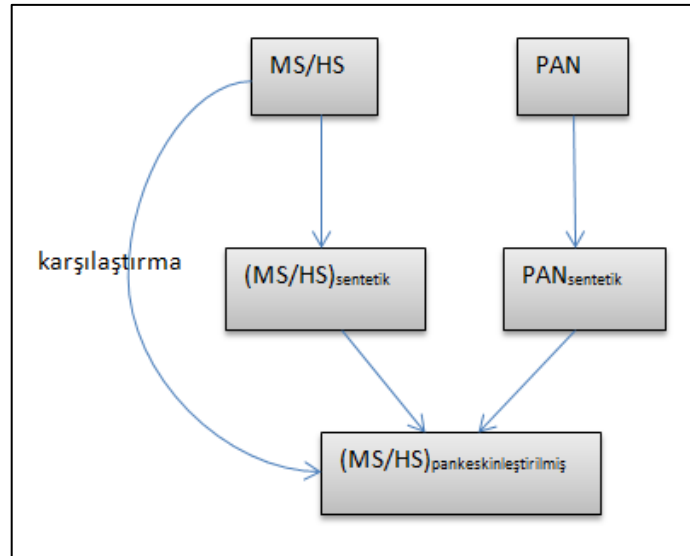
1.1.4. Varyasyonel yaklaşımlar (Variational approaches)

1.1.4.1. P+XS

P+XS yaklaşımı, iki görüntüde aynı topografik yapının korunduğundan yola çıkarak, spektral kanallar ile pankromatik görüntü arasındaki ilişkiyi ve çözünürlük farkını da dikkate alarak oluşturulan enerji fonksiyonunu minimize etmeye dayalı bir pankeskinleştirme yöntemidir. Kısaca, Gradient Descent algoritmasını kullanarak enerji fonksiyonunu en küçükmeye çalışmaktadır [67].

1.2. Wald's Protokolü

Pankeskinleştirme yaklaşımlarının performansını niceliksel olarak hesaplamak için bir referans görüntüsü ile pankeskinleştirilmiş görüntünün karşılaştırılması gereklidir. Her zaman bir referans görüntüsünün bulunması mümkün değildir. Literatürde performans karşılaştırmasında böyle bir durumun üstesinden gelmek için çeşitli yaklaşımlar sunulmuştur. Bu yaklaşımlardan en çok kullanılanı Wald's Protokolüdür [68]. Bu tez kapsamında kullanılan Wald's Protokolü'ne göre, multispektral/hiperspektral ve pankromatik görüntülerin uzamsal çözünürlükleri ilk olarak indirgenmektedir ve pankeskinleştirme yaklaşımları bu indirgenmiş çözünürlükteki görüntüler üzerinde uygulanmaktadır. Sonuç pankeskinleştirme görüntüsü orijinal multispektral/hiperspektral görüntü ile karşılaştırılarak pankeskinleştirme performansı yorumlanmaktadır.




Şekil 1.5. Wald's Protokolü blok şeması.


1.3. Pankromatik-Multispektral Pankeskinleştirme Temelli Uzamsal Çözünürlük Artırımı

1.3.1. RASAT alıcı görüntüleri üzerinde pankeskinleştirme yaklaşımları ve deneysel sonuçlar

RASAT görüntüleme alıcısı, BİLSAT alıcısından sonra ülkemizin ikinci uzaktan algılama uydusudur ve TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü (TÜBİTAK UZAY) tarafından Türkiye’de tasarlanıp üretilmiş olan ilk yerli gözlem uydusudur. Tasarım ömrü üç yıl olarak tahmin edilmesine rağmen, yörüngede beşinci yılını başarıyla tamamlamıştır. RASAT, 7,5m. uzamsal çözünürlükte pankromatik görüntü ve 15m. uzamsal çözünürlükte üç renkli (R,G,B) görüntü sunmaktadır. Tezin bu bölümünde, RASAT alıcısından elde edilen görüntüler üzerinde bir çok pankeskinleştirme yaklaşımı denenmiş ve elde edilen sonuçlar niteliksel ve niceliksel olarak görsel sonuçlar ve tablolar şeklinde sunulmaktadır. Tezin bu kısmında kullanılan veri setleri RASAT uzaktan algılama alıcısından çekilen Türkiye'nin farklı bölgelerini içeren görüntülerden oluşmaktadır. Veri setleri GEZGİN portalı [69] kullanılarak alınmıştır. Hesaplama karmaşıklığını azaltmak için portaldan alınan görüntülerin birer alt örnekleme kullanılmıştır. Multispektral görüntüler üç bant (RGB) şeklinde 150×150 piksel ve pankromatik görüntüler ise, aynı bölgeyi görüntüleyen 300×300 piksel şeklinde tek bant olarak alınmıştır. Buradaki piksel boyutları çözünürlük oranının 2 olması nedeniyle bu şekilde alınmıştır. Çünkü, multispektral görüntünün uzamsal çözünürlüğü 15m, pankromatik görüntünün ise, 7,5m.'dir. RASAT alıcı görüntüleri üzerinde yapılan deneyler üç parçadan oluşmaktadır. Veri setleri görüntüledikleri bölgenin özelliğine göre özenle seçilmiştir. İlk görüntü 15.06.2015 tarihinde Mersin bölgesinden alınmış, geniş tarla bölgelerini içeren bir görüntüdür. Bu görüntü, her biri homojen parçalardan ve kenarları keskin geçişlerden oluşan alanları içermektedir. İkinci görüntü ise, 12.01.2014 tarihinde İstanbul'dan alınmıştır ve şehir bölgesini yoğun bir şekilde içerdiği için uzamsal frekans değerleri yüksek olan bir görüntüdür. Ayrıca bu görüntü üzerinde kıyı-sahil geçişi de gözlemlenebilmektedir. Üçüncü görüntü ise, 31.08.2015 tarihinde Sinop bölgesinden alınmış, yollar, kara bölgesi ve deniz yüzeyini içeren bir görüntüdür. Renkli ve gri seviye multispektral ve pankromatik görselleri aşağıdaki Şekil 1.6, Şekil 1.7 ve Şekil 1.8'de görülmektedir.



Şekil 1.6. RASAT Mersin veri seti için RGB ve PAN görüntüleri [58].



Şekil 1.7. RASAT İstanbul veri seti için RGB ve PAN görüntüleri [58].



Şekil 1.8. RASAT Sinop veri seti için RGB ve PAN görüntüleri [58].

Wald protokolü kullanılarak gerçekleştirilen deneylerin sonuçları bu bölümde sunulmaktadır. Üç tane veri seti kullanılmıştır ve deneysel sonuçlar görsel ve niceliksel olarak sunulmuştur. Mersin, İstanbul ve Sinop şehirlerinin farklı özelliklere sahip bölgelerinden üç tane veri kümesi için on yedi tane pankeskinleştirme yaklaşımı kullanılmış ve sonuç pankeskinleştirme görüntüsü yedi tane kalite değerlendirme metriği kullanılarak performans karşılaştırılması uygulanmıştır. Elde edilen sonuçlar Tablo. 1.1., 1.2. ve 1.3.'de sunulmuştur. Mersin, İstanbul ve Sinop illerinden alınan görüntülerden oluşan veri setlerinin görsel sonuçları ise, Şekil 1.9., Şekil 1.10., ve Şekil 1.11.'da gösterilmiştir.

Tablo 1.1. Mersin veri seti için niceliksel pankeskinleştirme sonuçları.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	4,10	0,98	<0,01	1,51	35,0	0,97	0,97
PCA	4,07	0,98	<0,01	1,50	35,2	0,98	0,97
GS1	4,06	0,98	<0,01	1,50	35,1	0,97	0,97
GS2	4,76	0,97	<0,01	1,76	33,8	0,97	0,96
GS3	4,07	0,98	<0,01	1,50	35,1	0,97	0,97
HCS	4,08	0,98	<0,01	1,51	35,1	0,97	0,97
HPF	4,60	0,97	<0,01	1,70	34,0	0,97	0,96
BT	3,86	0,98	<0,01	1,43	35,5	0,98	0,98
SFIM	3,62	0,98	<0,01	1,33	36,4	0,98	0,98
UNB	4,02	0,98	<0,01	1,49	35,1	0,97	0,97
SSCN	4,13	0,98	<0,01	1,53	34,9	0,97	0,97
ATWT	3,24	0,99	<0,01	1,20	37,1	0,99	0,98
GLP	4,28	0,98	<0,01	1,58	34,8	0,97	0,97
MTF-GLP	2,73	0,99	<0,01	1,01	38,4	0,99	0,99
MTF-GLP-HPM	2,71	0,99	<0,01	1,01	38,5	0,99	0,99
Ehlers	4,91	0,97	<0,01	1,81	33,6	0,96	0,96
PXS	3,59	0,98	<0,01	1,33	36,2	0,98	0,98

Tablo 1.1. ve 1.2. yakından incelendiğinde en son ve en yeni olarak kullanılan tekniklerden olan MTF-GLP-HPM yaklaşımının en iyi sonuçları verdiği görülmektedir. Bu sonuçları yakın olarak MTF-GLP ve ATWT takip etmektedir. Pankeskinleştirme işlemi gerçekleştirilirken alıcı MTF değerlerinin kullanılmasının, klasik yaklaşımlara göre daha iyi sonuç vermesi beklenen bir durumdur [60]. Tablolar dikkatlice incelendiğinde ATWT yaklaşımı temel GLP yaklaşımından iyi olmasına rağmen, MTF değerlerinin kullanıldığı GLP'den (MTF-GLP) daha kötü sonuç verdiği görülmektedir.

Tablo 1.2. İstanbul veri seti için niceliksel pankeskinleştirme sonuçları.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	4,10	0,96	<0,02	2,77	34,5	0,95	0,93
PCA	4,06	0,96	<0,02	2,74	34,5	0,95	0,93
GS1	4,08	0,96	<0,02	2,75	34,5	0,95	0,93
GS2	4,57	0,95	<0,02	3,08	33,5	0,93	0,91
GS3	4,07	0,96	<0,02	2,75	34,5	0,95	0,93
HCS	4,21	0,96	<0,02	2,84	34,3	0,95	0,93
HPF	4,31	0,95	<0,02	2,91	34,1	0,95	0,93
BT	3,89	0,96	<0,02	2,62	34,9	0,96	0,95
SFIM	3,69	0,97	<0,02	2,50	35,6	0,96	0,95
UNB	4,07	0,96	<0,02	2,74	34,5	0,95	0,93
SSCN	4,12	0,96	<0,02	2,77	34,4	0,95	0,93
ATWT	3,41	0,97	<0,02	2,30	36,1	0,97	0,96
GLP	4,48	0,95	<0,02	3,02	33,7	0,94	0,92
MTF-GLP	3,12	0,97	<0,01	2,10	36,8	0,97	0,96
MTF-GLP-HPM	3,10	0,98	<0,01	2,08	36,8	0,97	0,96
Ehlers	5,02	0,94	<0,02	3,39	32,7	0,92	0,90
PXS	3,74	0,96	<0,02	2,52	35,3	0,96	0,95

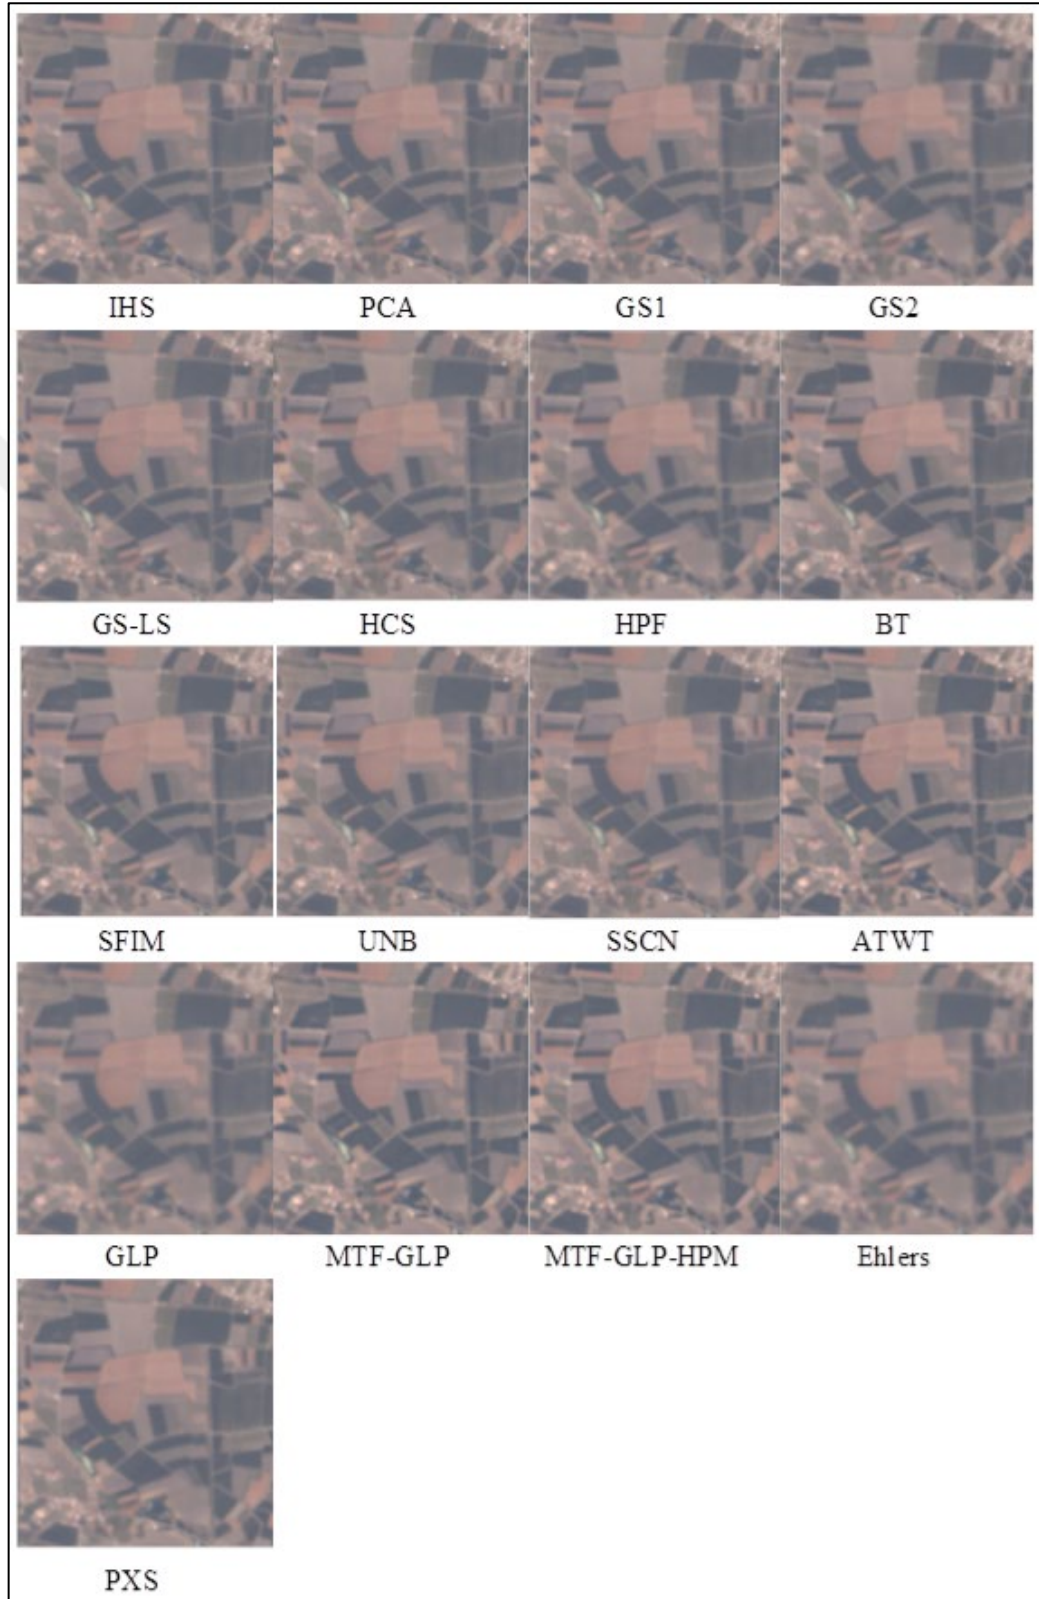
Tablo 1.3. incelendiğinde, Tablo 1.1. ve Tablo 1.2. de elde edilen sonuçlar ile paralellik gösterdiği görülmektedir.

Tablo 1.3. Sinop veri seti için niceliksel pankeskinleştirme sonuçları.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	5,92	0,98	<0,01	3,18	32,4	0,97	0,97
PCA	6,13	0,98	<0,02	3,29	32,2	0,97	0,97
GS1	5,97	0,98	<0,01	3,20	32,4	0,97	0,97
GS2	6,14	0,98	<0,01	3,29	32,1	0,97	0,97
GS3	6,22	0,98	<0,02	3,33	32,1	0,97	0,97
HCS	7,05	0,98	<0,01	3,77	30,8	0,96	0,95
HPF	5,27	0,98	<0,01	2,82	33,5	0,98	0,98
BT	5,67	0,98	<0,01	3,04	32,8	0,98	0,98
SFIM	4,56	0,99	<0,01	2,44	34,9	0,99	0,98
UNB	5,81	0,98	<0,01	3,11	32,5	0,97	0,97
SSCN	6,51	0,97	<0,01	3,48	31,5	0,97	0,96
ATWT	4,37	0,99	<0,01	2,34	35,3	0,99	0,99
GLP	6,09	0,98	<0,01	3,26	32,2	0,97	0,97
MTF-GLP	3,98	0,99	<0,01	2,14	36,0	0,99	0,99
MTF-GLP-HPM	3,91	0,99	<0,01	2,10	36,2	0,99	0,99
Ehlers	6,77	0,97	<0,01	3,63	31,3	0,96	0,96
PXS	5,02	0,98	<0,01	2,69	33,9	0,98	0,98


Şekil 1.9., Şekil 1.10. ve Şekil 1.11. şekillerindeki görsel sonuçların niceliksel hesaplama sonuçlarıyla uyumlu olduğu kolaylıkla görülebilmektedir. MTF-GLP-HPM yaklaşımı herhangi bir renk bozulması olmadan en keskin pankeskinleştirilmiş görüntüyü sunmaktadır. Bu sonucu MTF-GLP, ATWT ve SFIM görsel sonuçları takip etmektedir. Klasik yaklaşımlar arasından alıcı özelliklerini kullanmayan CS kategorisinde olanlar daha çok blur ve biraz renk bozulmasına neden olmuş sonuçlar

vermektedir. Şekil 1.9.'deki tarla kenarlarında uzamsal bozulma olan blur görüntü ve biraz olan renk bozulması kolaylıkla görülebilmektedir.




Şekil 1.9. RASAT Mersin veri seti için pansharpenleme görsel sonuçları.

Şekil 1.10.'da ise, ana yol ve binalar bulunmaktadır. Şekil 1.11.'de deniz-kıyı sınırı ve küçük yapılar vardır. Söz edilen etkiler Ehlers, GLP ve GS2 yaklaşımlarının görsel sonuçlarında da görülmektedir.



Şekil 1.10. RASAT İstanbul veri seti için pankeskinleştirme görsel sonuçları.



Şekil 1.11. RASAT Sinop veri seti için pankeskinleştirme görsel sonuçları.

Belirtilmesi gereken bir diğer önemli nokta ise, Mersin görüntülerinin Sinop görüntülerinden daha iyi sonuç vermesidir. Bu durum beklenen bir durumdur. Çünkü, Sinop görüntüsünde yüksek frekans bileşenlerinin varlığı bu görüntüyü


Mersin görüntüsü ile karşılaştırıldığında çalışılması daha zor bir veri yapmaktadır. Amro I. [8], HPF ve HCS yaklaşımlarının diğer kullanılan yaklaşımlarla karşılaştırıldığında en iyi pankeskinleştirme performansını verdiğini kanıtlamıştır. Bu durum bu tezde yapılan çalışmalarla uyum içindedir. Açıkgöz S. vd. [70], PCA yaklaşımının niceliksel olarak en iyi sonucu verdiğini belirtmişlerdir. BT yaklaşımının RASAT uydu görüntüleri için en iyi görsel sonuçları verdiğini göstermişlerdir. Fakat, bizim deneyimizde niceliksel ve kalite bakımında BT yaklaşımı IHS ve PCA yaklaşımına göre daha iyi pankeskinleştirme sonucu vermektedir. Vivone G. vd. [49], en son kullanılan pankeskinleştirme yaklaşımlarını IKONOS-2 ve WorldView-2 uydu görüntüleri üzerine uygulamış, ve MTF-GLP-HPM yaklaşımının bizim çalışmamızda da olduğu gibi en iyi sonucu verdiğini göstermişlerdir.

Bu deneyin amacı, günümüze kadar en çok kullanılan pankeskinleştirme yaklaşımlarından 17 tanesinin RASAT uydu görüntüleri üzerinde uygulamak ve performans karşılaştırmasını gerçekleştirmektir. Literatürle uyumlu olarak kullanılan Wald's protokolü deneyler için kullanılmıştır. Farklı özelliklere sahip olan bölgelerden alınan görüntüler üzerinde gerçekleştirilen deneylerin sonuçları tablo ve şekil biçiminde sunulmuştur. CS, MRA, hibrid ya da varyasyonel olan bütün kategorilerde alınan pankeskinleştirme yaklaşımlarından MTF-GLP-HPM yaklaşımının niceliksel ve kalite analizi bakımından en iyi sonucu verdiği gösterilmiştir. Pankeskinleştirmede alıcı MTF değerlerinin kullanılması dikkate değer bir performans artışına neden olmaktadır. Ayrıca MRA'ya dayalı pankeskinleştirme yaklaşımlarının CS ya da diğer yaklaşımlara göre daha büyük bir performans sağladığı gözlemlenmiştir. P+XS varyasyonel yaklaşımının SFIM ile performans bakımından yarıştığı, Ehlers yaklaşımının ise diğer bir çok metodu geçtiği gözlemlenmiştir.


1.3.2. GÖKTÜRK-2 alıcı görüntüleri üzerinde pankeskinleştirme yaklaşımları ve deneysel sonuçlar

Tezin bu bölümünde, GÖKTÜRK-2 alıcı görüntüleri üzerinde detaylı bir pankeskinleştirme çalışması sunulmaktadır. GÖKTÜRK-2, BİLSAT ve RASAT alıcılarından sonra, Türkiye Cumhuriyeti'nin üçüncü uzaktan algılama uydusudur.


Türk Hava Kuvvetleri, TÜBİTAK UZAY ve Türk Havacılık ve Uzay Sanayii A.Ş. tarafından ülkemizde tasarlanıp üretilen 2.5 metre pankromatik ve 5 metre dört bantlı (R,G,B,NIR) multispektral uzamsal çözünürlüğüne sahip olan GÖKTÜRK-2 alıcısı, Aralık 2012 tarihinde yörüngeye fırlatılmıştır. GÖKTÜRK-2 alıcısından alınan ilk görüntü İstanbul'dan, 26.02.2015 tarihinde alınan 512×512 piksel büyüklüğünde bir görüntüdür. Pankromatik ve RGB (multispektral'in ilk üç bandı) veri setinin görselleri Şekil 1.12.'de gösterilmektedir. Bu görüntü şehir ve kırsal bölgenin karışık özelliklerini yüksek frekans bileşenleriyle içermektedir. İkinci veri seti, İstanbul - Büyükkada'dan yine aynı tarihte alınan (26.02.2015), 300×300 piksel büyüklüğünde bir görüntüdür pankromatik ve RGB (multispektral'in ilk üç bandı) görüntüleri Şekil 1.13. 'de gösterilmektedir. Bu görüntü farklı tür ürünler ve bir küçük kasabayla bir çiftlik alanını içermektedir. Üçüncü veri seti ise, Alanya Tepebaşı'ndan 12.11.2014 tarihinde 300×300 piksel büyüklüğünde alınmış bir görüntüdür ve pankromatik ile RGB (multispektral'in ilk üç bandı) görüntüleri Şekil 1.14.'de gösterilmektedir.



Şekil 1.12. a) MS veri seti b) PAN veri seti İstanbul, GÖKTÜRK-2.



Şekil 1.13. a) MS veri seti b) PAN veri seti Büyükkada, GÖKTÜRK-2.



Şekil 1.14. a) MS veri seti b) PAN veri seti
Alanya Tepebaşı, GÖKTÜRK-2.

Bu görüntü şehir ve dağlık alan bölgelerini içermektedir. Veri seti görüntüleri üzerinde herhangi bir renk doğrulama ya da düzenleme yapılmamıştır.

Tezin bu kısmında, GÖKTÜRK-2 uydu görüntüleri için standart ve güncel pankeskinleştirme yaklaşımlarının detaylı bir performans karşılaştırması sunulmuştur.

Deneysel çalışmalar için GÖKTÜRK-2'den alınan multispektral ve pankromatik görüntülerin uzamsal olarak çözünürlüğü düşürülmüştür. Bunun için Gaussian alçak geçiren süzgeç kullanılmıştır. Bu süzgeçten geçirilen görüntüler üzerinde daha sonra örnek seyreltme işlemi pankromatik ve multispektral görüntülerin çözünürlük oranlarına göre gerçekleştirilmiştir. GÖKTÜRK-2 için bu oran 2'dir.

Pankeskinleştirme yaklaşımlarının gerçekleştirilmesi için multispektral görüntü, pankromatik görüntünün çözünürlüğüne üst örneklenmelidir. Bunun için sentezlenmiş multispektral görüntü, sentezlenmiş pankromatik görüntünün boyutuna $interp23tap$ [60] süzgeci kullanılarak getirilmiştir. Sentezlenmiş multispektral ve pankromatik görüntüleri üzerinde, bu bölümün başında anlatılan pankeskinleştirme yaklaşımları uygulanmış ve pankeskinleştirilmiş multispektral görüntü orijinal multispektral görüntü ile bir çok performans metriği kullanılarak karşılaştırılmıştır.

Üç tane veri seti için niceliksel sonuçlar Tablo 1.4., 1.5. ve 1.6'da, görsel sonuçlar ise, Şekil 1.15, Şekil 1.16. ve Şekil 1.17.'de sunulmaktadır. Tablo 1.4. yakından incelendiğinde MRA pankeskinleştirme yaklaşımlarının bu veri setleri için daha iyi sonuçlar verdiği görülmektedir. En iyi performansı SFIM yaklaşımı vermektedir.

Bunu ATWT takip etmektedir. En kötü pankeskinleştirme performansını CS tekniklerinden olan HCS, PCA ve BT yaklaşımları vermektedir. CS kategorisinden olan PRACS yaklaşımı, en iyi performansı vermektedir.

Tablo 1.4. İstanbul veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	5,12	0,96	1,98	4,65	32,18	0,94	0,93
BT	5,16	0,96	1,90	4,63	32,19	0,94	0,93
PCA	5,25	0,96	2,00	4,75	32,08	0,94	0,93
GS1	5,14	0,96	1,98	4,65	32,26	0,94	0,93
GS2	4,60	0,97	1,88	4,16	33,08	0,95	0,94
GS-LS	4,53	0,97	1,90	4,10	33,34	0,95	0,95
HCS	5,35	0,95	1,90	4,79	31,83	0,93	0,92
HPF	4,74	0,96	1,89	4,29	32,77	0,95	0,94
UNB	4,79	0,96	1,90	4,29	32,88	0,95	0,95
PRACS	4,15	0,97	1,84	3,75	34,24	0,96	0,96
SFIM	3,65	0,98	1,90	3,29	35,87	0,97	0,97
AWLP	4,01	0,97	1,95	3,56	34,83	0,97	0,97
ATWT	3,91	0,98	1,83	3,52	35,08	0,97	0,97
GLP	4,53	0,97	1,91	4,11	33,33	0,95	0,95
PXS	5,03	0,96	1,90	4,55	32,18	0,94	0,93

Tablo 1.5. daha iddialı bir veri setinin sonuçlarını içermektedir. Bu görüntü için kullanılan yaklaşımların performansının düştüğü görülmektedir. Yine en kötü performans HCS ve PCA yaklaşımlarının verdiği görülmektedir. Bu durumu GS1 takip etmektedir. CS kategorisinde en güçlü yaklaşım, PRACS'tır ve MRA'ya dayalı olan SFIM metodunu biraz geçmektedir. SFIM yaklaşımının PRACS metodunu

ERGAS metriği kullanıldığında geçmesine rağmen, her iki yaklaşım ATWT yaklaşımını PSNR metriğine göre geçmektedir.

Tablo 1.5. Büyükada veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	9,63	0,96	3,74	9,01	27,58	0,90	0,89
BT	10,42	0,95	2,41	8,65	27,49	0,88	0,87
PCA	14,30	0,91	6,77	13,23	26,97	0,89	0,88
GS1	10,85	0,95	5,20	10,10	28,81	0,92	0,92
GS2	6,69	0,98	2,36	6,33	31,72	0,96	0,95
GS-LS	6,63	0,98	2,53	6,24	32,20	0,96	0,96
HCS	10,32	0,96	2,41	8,64	27,54	0,86	0,85
HPF	6,84	0,98	2,36	6,49	31,72	0,96	0,96
UNB	8,62	0,97	2,41	7,24	29,08	0,93	0,92
PRACS	6,32	0,98	2,33	5,93	32,62	0,97	0,97
SFIM	6,36	0,98	2,41	5,52	32,36	0,96	0,96
AWLP	7,45	0,98	2,60	6,77	32,55	0,97	0,97
ATWT	7,17	0,98	2,66	6,59	32,97	0,97	0,97
GLP	7,52	0,98	2,44	7,01	30,00	0,94	0,93
PXS	7,39	0,98	2,41	7,04	30,71	0,95	0,94

Alanya veri seti için, Tablo 1.6.'daki sonuçlar, Büyükada veri setinin sonuçları ile büyük benzerlik göstermektedir.

PRACS, RMSE, CC ve SAM metriği ile ATWT yaklaşımının PSNR metriği dışında en iyi performansı veren yaklaşımdır. Bütün veri setleri için varyasyonel olan P+XS yaklaşımı orta bir performansa sahiptir.

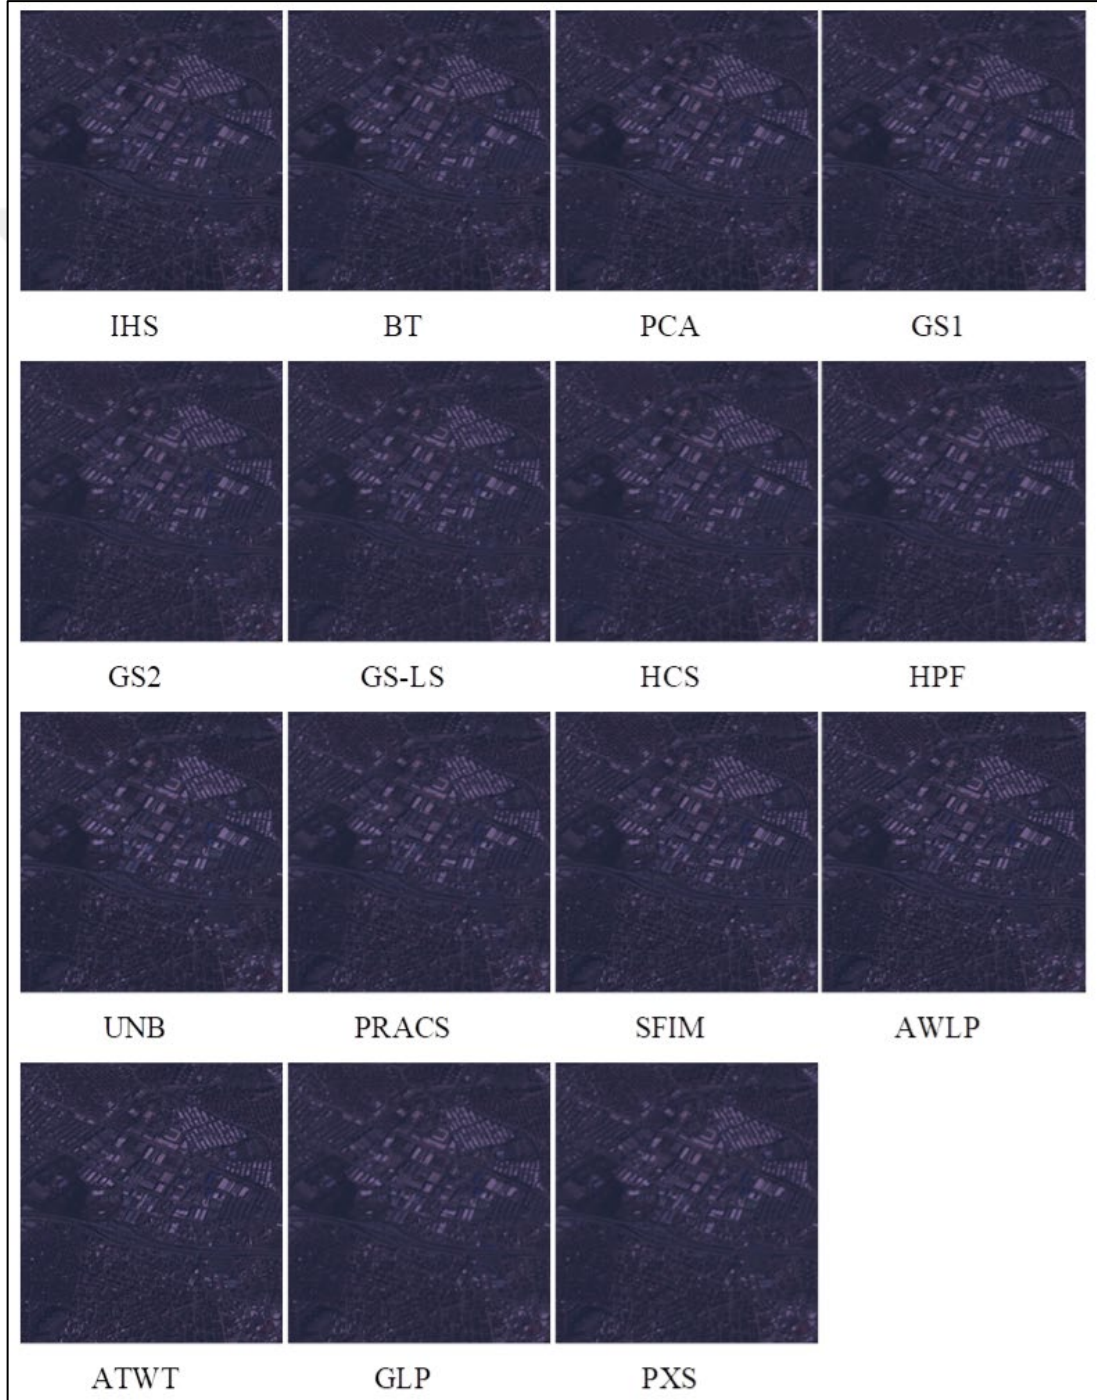
Tablo 1.6. Alanya Tepebaşı veri seti için pankeskinleştirme sonuçları, GÖKTÜRK-2.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	9,32	0,95	4,15	8,88	29,01	0,87	0,86
BT	10,11	0,94	3,23	8,16	29,19	0,87	0,85
PCA	14,68	0,86	6,96	11,28	28,21	0,81	0,79
GS1	9,96	0,94	4,63	8,66	29,78	0,88	0,87
GS2	6,73	0,97	3,15	6,05	32,71	0,94	0,93
GS-LS	6,31	0,98	3,11	5,60	33,43	0,95	0,94
HCS	11,30	0,92	3,23	9,18	28,11	0,82	0,80
HPF	6,73	0,97	3,15	6,08	32,74	0,94	0,93
UNB	8,46	0,96	3,23	6,78	30,81	0,92	0,91
PRACS	6,09	0,98	3,05	5,23	34,06	0,96	0,95
SFIM	6,19	0,98	3,23	4,82	34,10	0,96	0,95
AWLP	7,41	0,97	3,62	5,58	33,97	0,96	0,95
ATWT	6,37	0,98	3,16	5,04	34,79	0,97	0,96
GLP	6,96	0,97	3,18	6,39	31,88	0,93	0,92
PXS	8,57	0,96	4,02	6,88	32,33	0,94	0,93

Şekil 1.15., 1.16. ve 1.17.'daki görsel sonuçlar hemen hemen bütün yaklaşımlarda benzer özellikler göstermektedir. PRACS, SFIM, ATWT ve AWLP yaklaşımları daha net ve keskin sonuçlar vermektedir. Fakat, IHS, BT, PCA, GS1 ve HCS metodları daha blur veya biraz renk bozulması olan sonuçlar vermektedir.

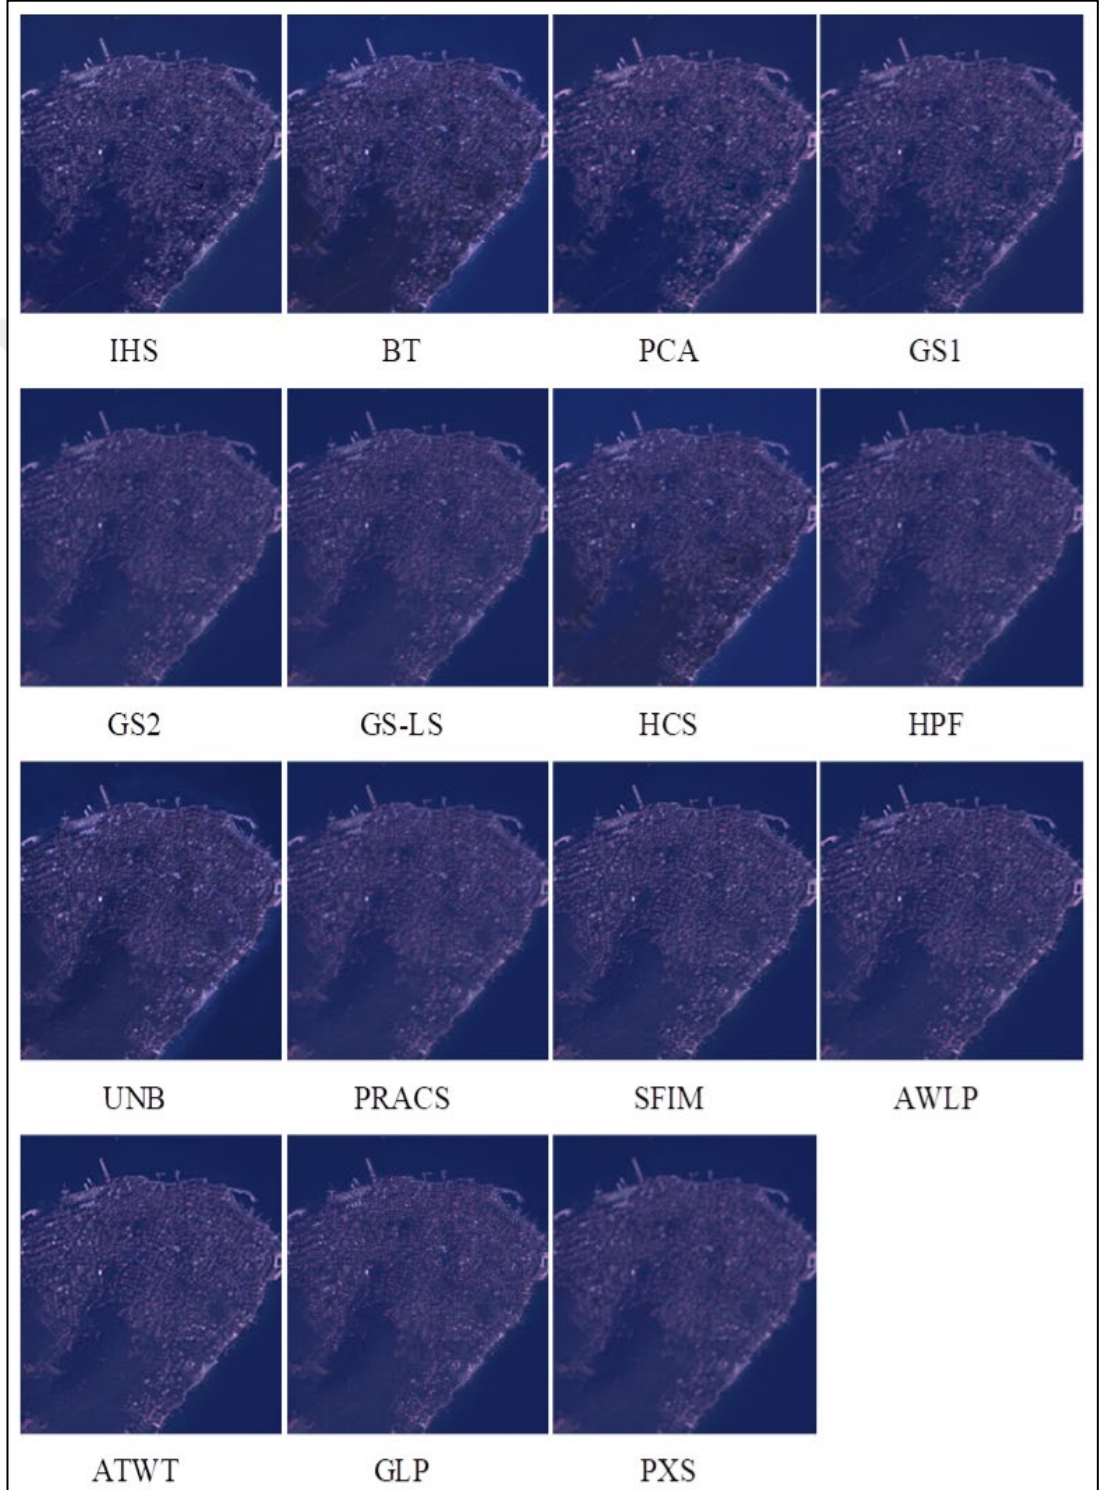
Genel olarak, CS kategorisindeki PRACS yaklaşımı ve MRA kategorisindeki SFIM metodu kullanılan GÖKTÜRK-2 uydu görüntüleri üzerinde en iyi pankeskinleştirme performansını sunmaktadır. Bu durumu MRA'ya dayalı ATWT takip etmektedir. En kötü performansı PCA, BT ve HCS yaklaşımları vermektedir. Çünkü, bu yaklaşımlar

basittir ve kolay gereklenebilmektedir. Elde edilen bu sonular grntlerin temin edildiĐi alıcıya baĐlıdır. DiĐer alıcılarda, bu sonular multispektral bantların spektral aralıĐı ve bant sayısı gibi zelliklerin de deĐiŐebilmesinden dolayı farklı sonular elde edilebilecektir. Ayrıca pankromatik ve multispektral grntlerin spektral bantlarının st ste gelmesi de pankeskinleŐtirmeyi direk olarak etkileyen en nemli faktrlerdendir.

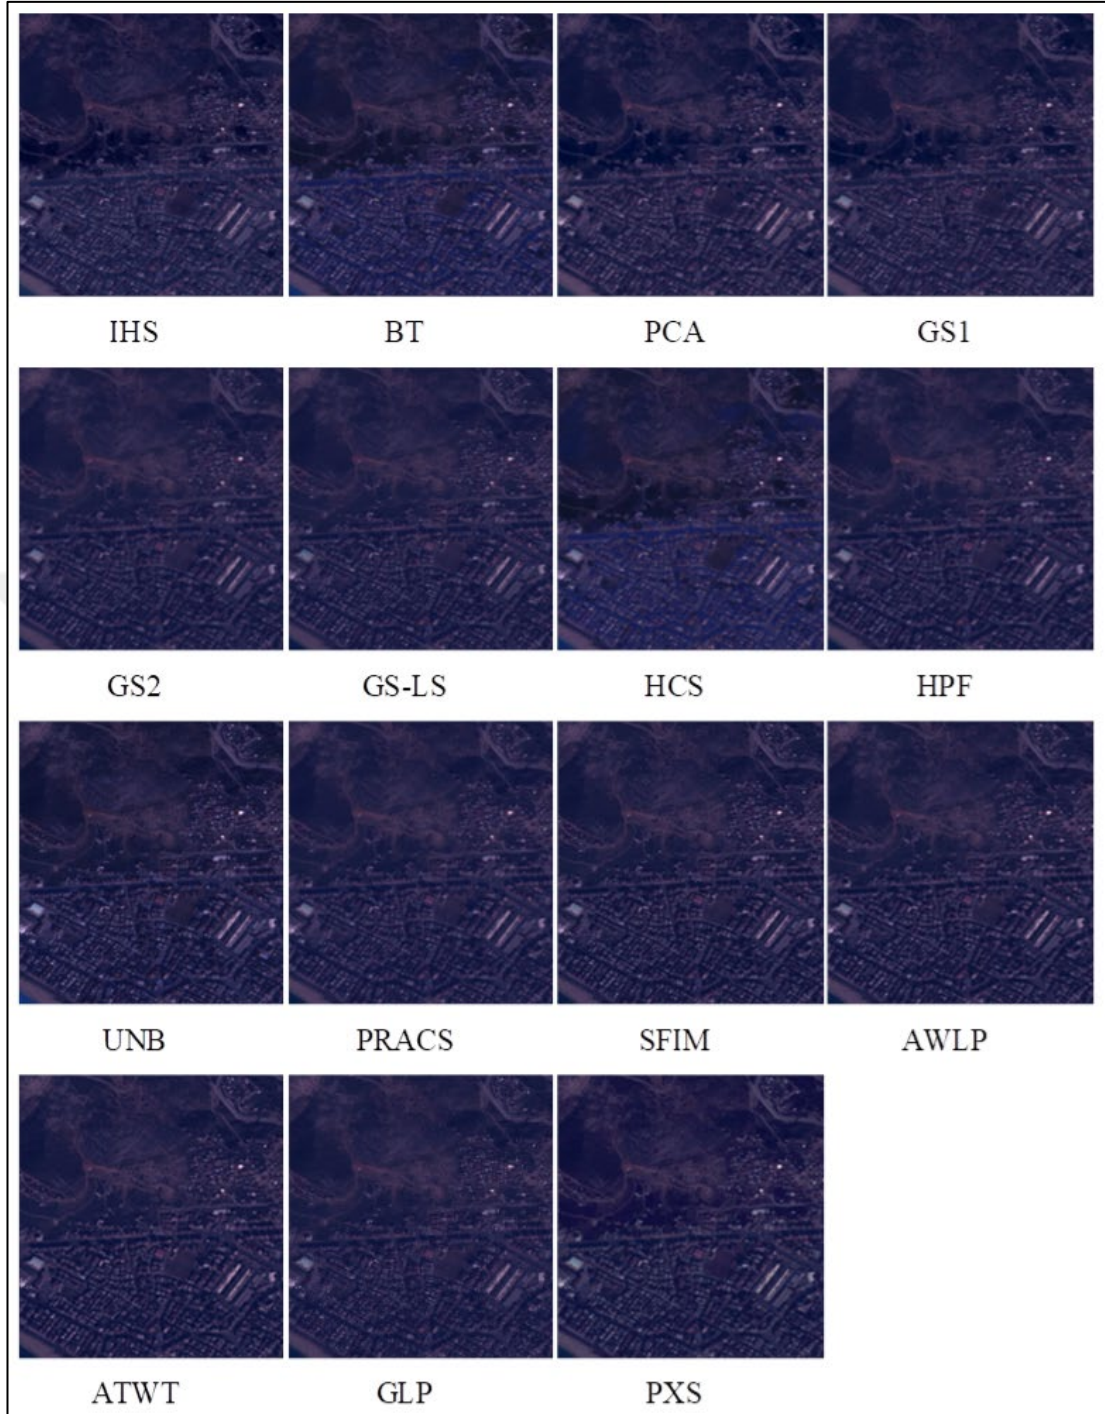


Őekil 1.15. İstanbul veri seti için pankeskinleŐtirme grsel sonuĐları, GKTRK-2.

Diğer ilginç bir nokta ise, bazı CS'ye dayalı yaklaşımlar birkaç MRA'ya dayalı yaklaşımı iki tane kullanılan veri seti için performans bakımından aşmıştır. GÖKTÜRK-2 uydu görüntüleri Landsat gibi daha çok bant sayısına sahip olmadığı için böyle bir sonucun elde edildiğini düşünmekteyiz.



Şekil 1.16. Büyükada veri seti için pankeskinleştirme görsel sonuçları, GÖKTÜRK-2



Şekil 1.17. Alanya-Tepebaşı veri seti için pankeskinleştirme görsel sonuçları, GÖKTÜRK-2.

1.3.3. GÖKTÜRK-2 görüntüleri için MTF ve SRF değerlerini içeren pankeskinleştirme yaklaşımlarının başarımlarını ve deneysel sonuçlar

Bu bölümde, Hava Kuvvetleri Komutanlığı, Keşif Uydu Tabur Komutanlığı'ndan temin edilen GÖKTÜRK-2 alıcısının MTF ve SRF değerleri, bu değerlerin içerildiği


pankeskinleştirme yaklaşımlarının gerçekleşmesi amacıyla kullanılmıştır. Bu nedenle literatürde ilk defa GÖKTÜRK-2 uydusunun MTF ve SRF değerleri kullanılmıştır. Bu sayede GÖKTÜRK-2 alıcısı görüntülerinden sentetik multispektral ve pankromatik görüntüler gerçekçi bir şekilde elde edilmiş ve pankeskinleştirme yöntemleri ile elde edilen kaynaştırma sonuçları orijinal görüntüler ile tutarlı şekilde karşılaştırılmıştır.

Birden çok GÖKTÜRK-2 verisi üzerinde çıkarılan sayısal ve görsel sonuçlar sonucunda, güncel çok-çözünürlüklü analiz yöntemlerinin standart bileşen değişimi yöntemlerine göre daha yüksek başarı sağladığı ve alıcı hakkında önsel bilgileri kullanan en yeni yöntemlerin beklendiği üzere en iyi pankeskinleştirme başarımlarını verdiği gösterilmiştir.

Bu çalışmada, GÖKTÜRK-2 alıcısının MTF ve SRF değerleri, sentetik veri oluşturma adımında ve bu bilgilere önsel bilgi olarak ihtiyaç duyan pankeskinleştirme yöntemlerinin gerçekleşmesinde kullanılmıştır. Bu anlamda, tezin bu bölümünde gerçekleştirilen bu çalışma literatürde GÖKTÜRK-2 görüntüleri üzerinde pankeskinleştirme için MTF ve SRF değerlerini de hesaba katan ilk çalışma olduğu gibi, aynı zamanda en çok sayıda ve en güncel yöntemleri kullanan inceleme çalışmasıdır.

Gerçek veriden sentetik veri sentezlenmesinde bu bilgilerin kullanılması, süreci gerçekçi bir analize dönüştürürken, bu önsel bilgileri hesaba katan yöntemlere de bir ayrıcalık ve avantaj tanımaktadır. Ayrıca uygun olan her yöntemde pankromatik görüntü ile multispektral görüntü arasında histogram eşitleme işlemi gerçekleştirilmiştir. Histogram eşitlemenin avantajları [71]'de incelenmiştir.

GÖKTÜRK-2 uydu görüntüleri üzerinde yapılan bu çalışmada her biri farklı özelliklere sahip üç görüntü kullanılmıştır. Birinci görüntü İstanbul şehrinden alınan 500×500 piksel boyutunda, binalar ve ormanlık alanı içeren bir görüntüdür. İkinci görüntü yine İstanbul şehrinden alınan 500×500 piksel boyutunda, binalar ve yolları içeren bir görüntüdür. Üçüncü görüntü ise, Kumluca Yeniköy'den alınan 200×200 piksel boyutunda olan daha çok tarla sınırlarını içeren bir görüntüdür. Şekil 1.18.'de, kullanılan GÖKTÜRK-2 görüntülerinin orijinal RGB ve pankromatik görselleri görülmektedir.



Şekil 1.18. GÖKTÜRK-2 uydu verisi görselleri a) İstanbul-1 RGB, b) İstanbul-2 RGB, c) Kumluca Yeniköy RGB d) İstanbul-1 PAN e) İstanbul-2 PAN f) Kumluca Yeniköy PAN.

Pankeskinleştirme yaklaşımlarının başarımları analizi yapılırken Wald Protokolü izlenmiştir. Bu protokol kapsamında, orijinal multispektral ve pankromatik görüntüleri GÖKTÜRK-2 MTF değerleri kullanılarak alçak geçiren Gauss süzgeçlerinden geçirilmiştir. Daha sonra multispektral görüntü üzerinde örnek seyreltme ve interp23tap filtresi [60] ile üst örnekleme gerçekleştirilmiştir.

Çözünürlüğü indirgenmiş multispektral ve pankromatik görüntüleri pankeskinleştirme yaklaşımlarına girdi olarak verilir, elde edilen pankeskinleştirilmiş görüntüler orijinal multispektral görüntü ile karşılaştırılmıştır. Sayısal sonuçlar RMSE, CC, SAM, ERGAS, PSNR ve UIQI kullanılarak ölçülmüştür.

Deney sonuçlarının ifade edildiği İstanbul-1 verisi için Tablo 1.7.'de CS yaklaşımlarından GS2-GLP yaklaşımının, MRA yaklaşımlarından ise, MTF-GLP-HPM ve MTF-GLP yaklaşımlarının en iyi sayısal sonuçları verdiği görülmektedir. Bu yaklaşımları, AWLP ve ATWT yaklaşımları hem CC hem de UIQI metrikleri göz önüne alındığında performans bakımından takip etmektedir.

Tablo 1.7. GÖKTÜRK-2 İstanbul-1 verisi için niceliksel sonuçlar.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	0,02	0,95	2,27	5,22	31,22	1,00	0,91
BT	0,02	0,95	2,24	5,23	31,22	1,00	0,91
PCA	0,02	0,95	2,28	5,28	31,16	1,00	0,90
GS	0,02	0,95	2,27	5,23	31,24	1,00	0,91
GSA	0,02	0,96	2,17	4,83	31,76	1,00	0,94
GS2-GLP	0,02	0,97	2,12	3,79	34,50	1,00	0,96
HPF	0,02	0,95	2,22	5,15	31,22	1,00	0,91
UNB	0,02	0,96	2,24	4,64	32,38	1,00	0,93
PRACS	0,02	0,96	2,18	4,76	31,97	1,00	0,92
BDSB	0,02	0,96	2,07	4,40	32,77	1,00	0,94
SFIM	0,02	0,97	2,24	4,19	33,55	1,00	0,95
AWLP	0,02	0,97	2,25	3,91	34,07	1,00	0,96
ATWT	0,02	0,97	2,11	3,85	34,21	1,00	0,96
GLP	0,02	0,95	2,22	5,02	31,51	1,00	0,91
MTF-GLP	0,02	0,97	2,11	3,84	34,24	1,00	0,96
MTF-GLP-HPM	0,02	0,97	2,14	3,83	34,32	1,00	0,96
SSCN	0,02	0,97	2,24	4,79	31,93	1,00	0,92
GFPCA	0,02	0,94	2,69	5,50	30,91	1,00	0,89
PXS	0,02	0,94	2,24	5,40	30,74	1,00	0,90

Tablo 1.8'deki İstanbul-2 verisi için elde edilen sonuçlara bakıldığında, SFIM yaklaşımının MRA tabanlı yaklaşımlardan en iyi performansı sağladığı görülmektedir. Bunu takiben MTF-GLP-HPM ve MTF-GLP yaklaşımları iyi

pankeskinleştirme sonucu ile izlemektedir. Tablo 1.9’da Kumluca Yeniköy verisi için GS2-GLP'nin tüm yöntemler arasında en iyi sonucu verdiği görülmektedir.

Tablo 1.8. GÖKTÜRK-2 İstanbul-2 verisi için niceliksel sonuçlar.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	0,03	0,92	3,34	7,48	31,20	1,00	0,84
BT	0,03	0,92	3,09	7,33	31,52	1,00	0,84
PCA	0,04	0,87	4,07	8,91	30,21	1,00	0,78
GS	0,03	0,92	3,40	7,39	31,56	1,00	0,85
GSA	0,02	0,96	3,37	5,43	34,27	1,00	0,93
GS2-GLP	0,02	0,96	3,03	4,61	36,34	1,00	0,95
HPF	0,02	0,95	3,06	6,01	33,38	1,00	0,90
UNB	0,03	0,94	3,09	6,42	32,54	1,00	0,91
PRACS	0,02	0,95	2,97	5,81	33,53	1,00	0,90
BDSB	0,02	0,96	2,82	4,99	35,09	1,00	0,94
SFIM	0,02	0,97	3,09	4,45	36,35	1,00	0,95
AWLP	0,02	0,96	3,16	4,82	35,72	1,00	0,94
ATWT	0,02	0,97	2,87	4,57	36,13	1,00	0,95
GLP	0,02	0,95	3,05	5,78	33,78	1,00	0,90
MTF-GLP	0,02	0,97	2,88	4,55	36,17	1,00	0,95
MTF-GLP-HPM	0,02	0,97	2,91	4,56	36,25	1,00	0,95
SSCN	0,03	0,97	3,09	6,99	31,62	1,00	0,86
GFPCA	0,03	0,94	3,72	6,55	32,80	1,00	0,87
PXS	0,03	0,94	3,09	6,40	32,74	1,00	0,88

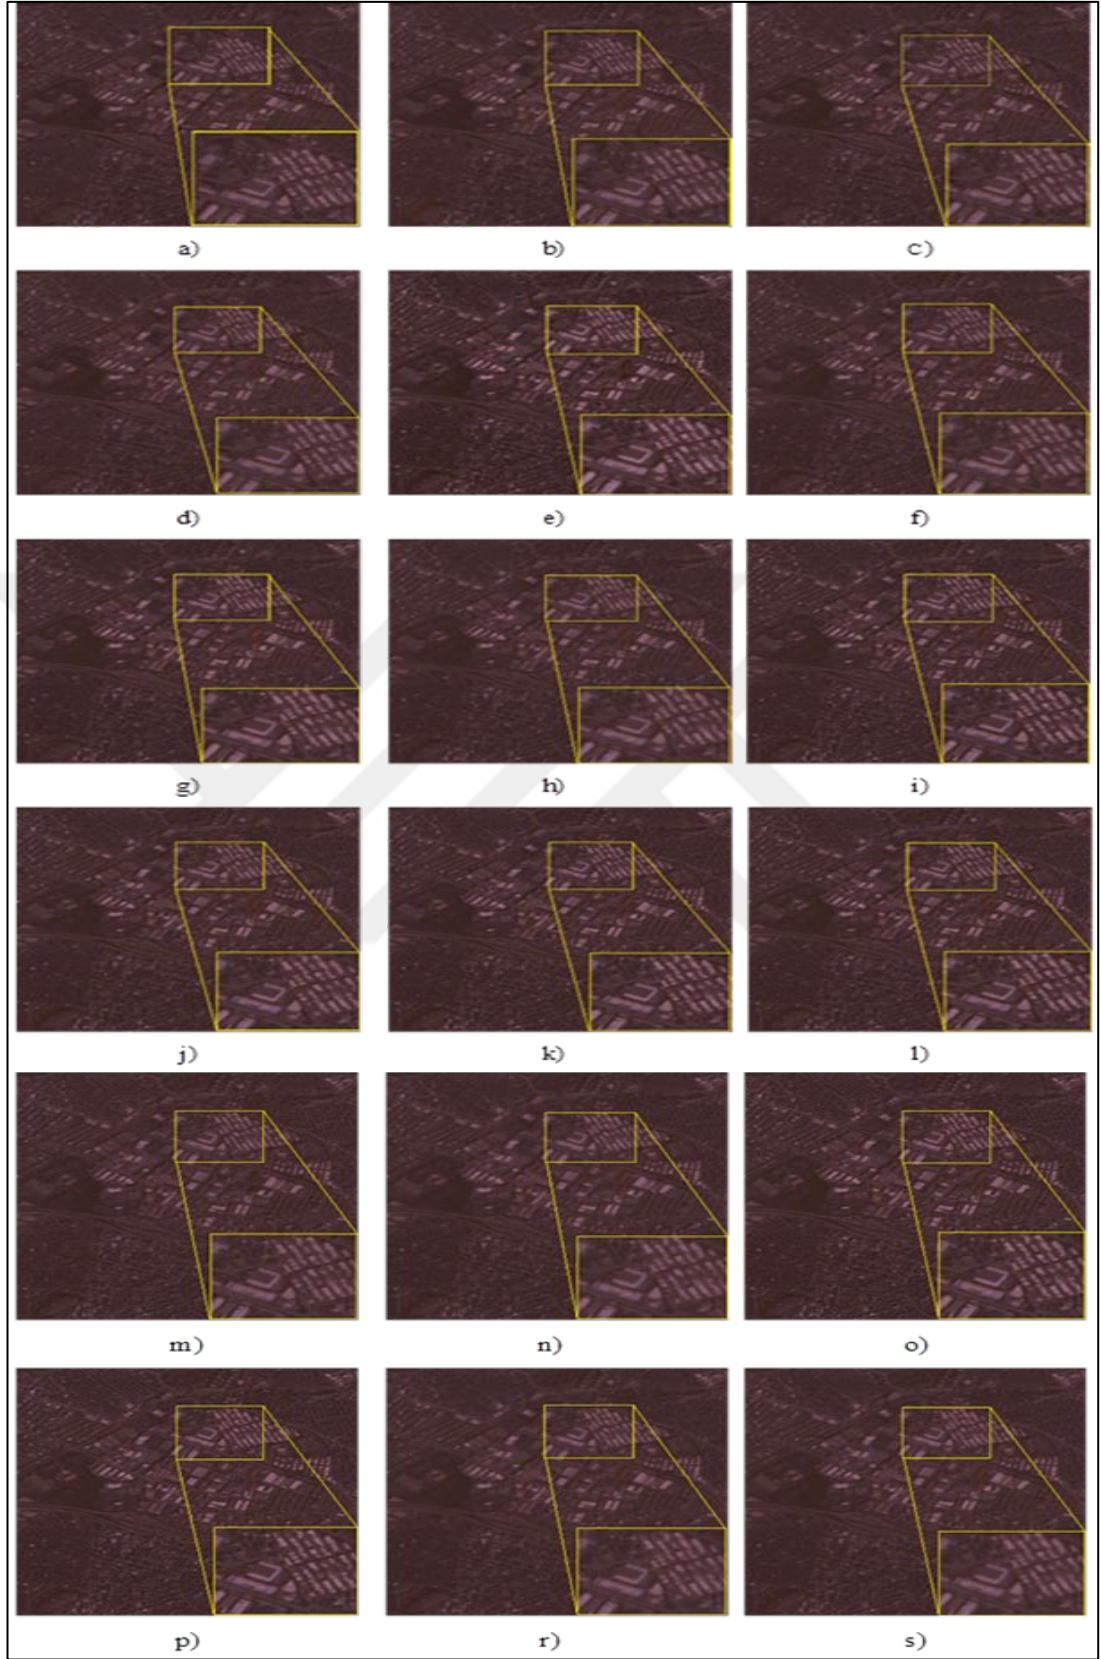
Beklendiği üzere, genel olarak MRA yaklaşımları CS yaklaşımlarına üstün gelmekle beraber, BDSB ve GS2-GLP gibi güncel CS yaklaşımları daha eski CS yaklaşımlarından iyi başarımlar verebilmektedir. Ancak her durumda, alıcı önsel bilgilerini kullanan pankeskinleştirme yaklaşımları diğer yöntemlere göre net bir üstünlük sağlamaktadır. Bu durum, pankeskinleştirme yaklaşımı kullanılmasında

amaçlanan alıcı için, ilgili alıcının MTF ve SRF değerlerini kullanan, GS2-GLP veya MTF-GLP-HPM gibi yaklaşımların geleneksel yaklaşımlara göre yüksek başarımları sağlayacağını doğrulamaktadır.

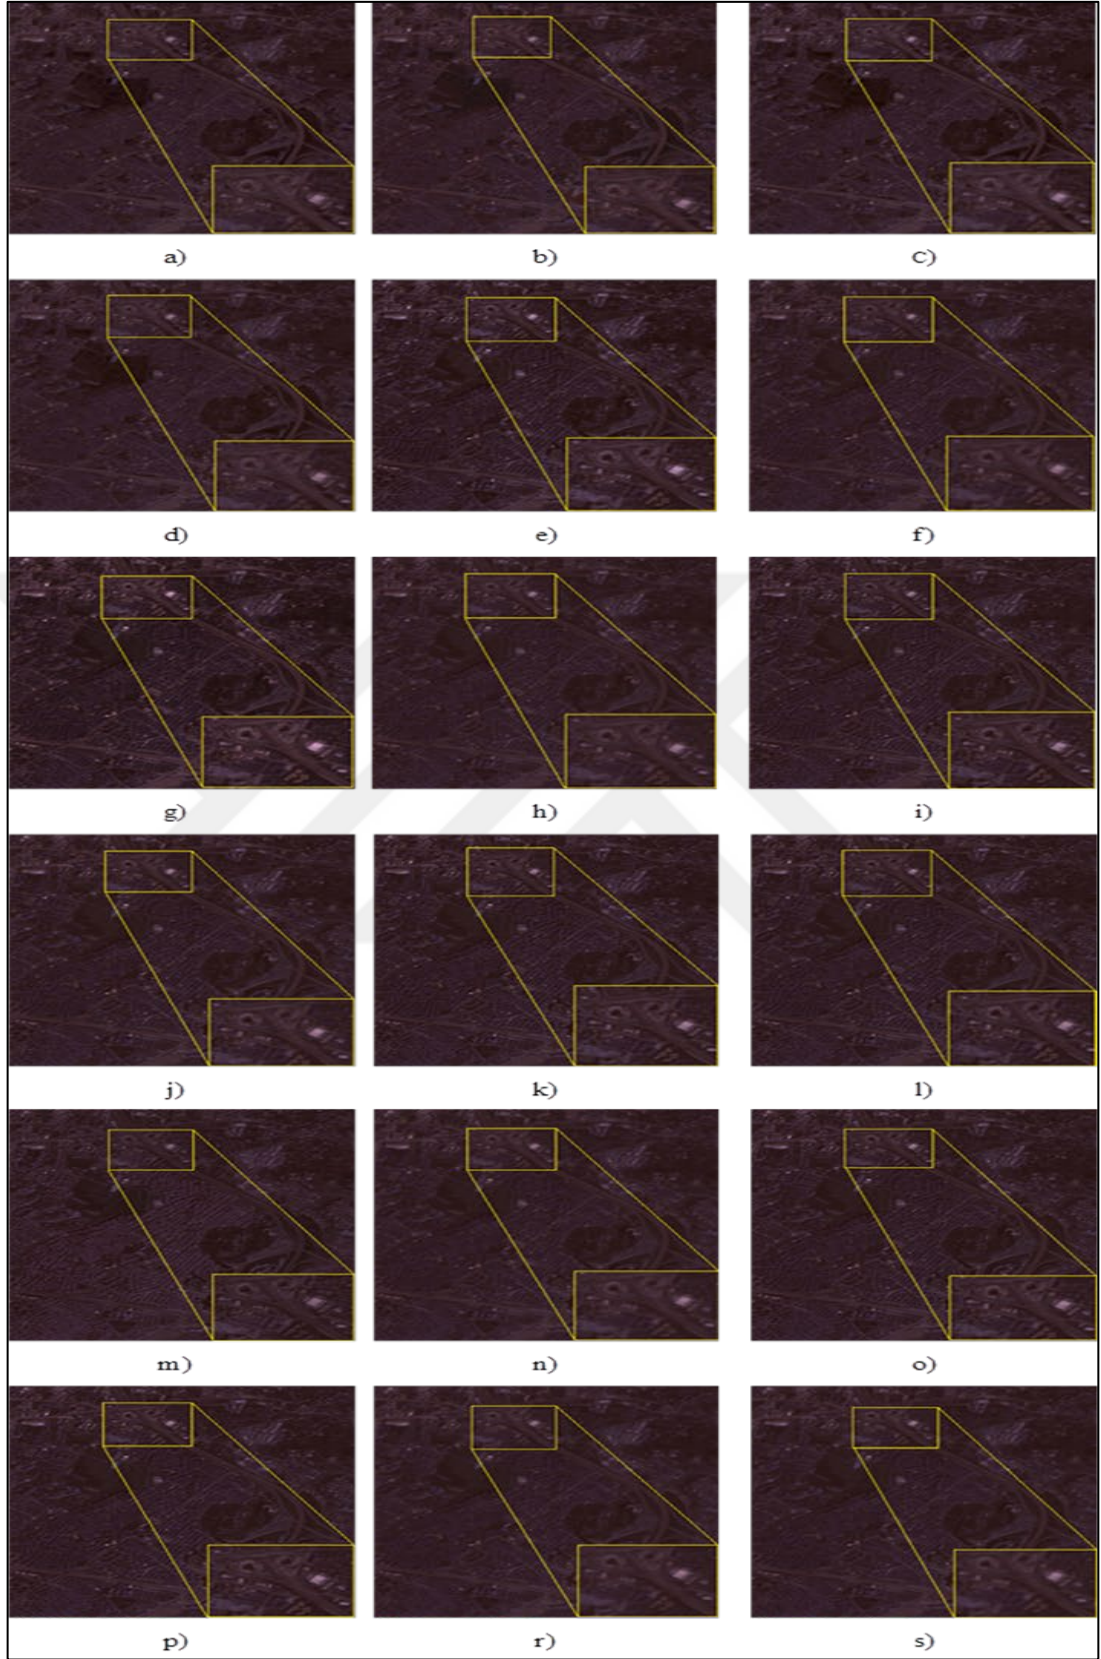
Tablo 1.9. GÖKTÜRK-2 Kumluca Yeniköy verisi için niceliksel sonuçlar.

	RMSE	CC	SAM	ERGAS	PSNR	SSIM	UIQI
IHS	0,02	0,98	2,48	6,17	30,53	1,00	0,89
BT	0,02	0,97	2,00	5,50	30,79	1,00	0,87
PCA	0,02	0,98	3,18	5,31	31,80	1,00	0,92
GS	0,02	0,98	2,57	6,44	30,40	1,00	0,89
GSA	0,01	0,99	1,97	3,81	34,56	1,00	0,96
GS2-GLP	0,01	0,99	1,65	3,07	36,30	1,00	0,97
HPF	0,01	0,99	1,92	3,83	34,43	1,00	0,95
UNB	0,04	0,94	2,06	7,59	28,07	1,00	0,83
PRACS	0,02	0,99	1,97	3,90	33,98	1,00	0,95
BDS	0,01	0,99	1,81	3,61	35,00	1,00	0,96
SFIM	0,01	0,99	2,00	3,52	35,57	1,00	0,96
AWLP	0,02	0,99	2,18	3,74	34,98	1,00	0,96
ATWT	0,01	0,99	1,96	3,33	35,70	1,00	0,96
GLP	0,01	0,99	1,95	3,93	34,23	1,00	0,95
MTF-GLP	0,01	0,99	1,95	3,28	35,82	1,00	0,96
MTF-GLP-HPM	0,01	0,99	1,94	3,29	35,84	1,00	0,96
SSCN	0,02	0,99	2,00	4,95	31,70	1,00	0,90
GFPCA	0,02	0,99	2,22	4,31	33,40	1,00	0,94
PXS	0,02	0,99	2,00	4,35	33,47	1,00	0,94

İstanbul verilerinin birer alt-kümeleri için görsel sonuçlar Şekil 1.19 ve 1.20'de paylaşılmıştır. Görsel sonuçların da sayısal sonuçlar ile paralellik taşıdığı görülmektedir. Kumluca Yeniköy verisi için görsel sonuçlar diğer İstanbul verilerinin görsel sonuçlarının yorumlarıyla uyumlu olduğu için teze eklenmemiştir.



Şekil 1.19. GÖKTÜRK-2 İstanbul-1 verisi pankeskinleştirme görsel sonuçları a) IHS, b) BT, c) PCA, d) GS, e) GSA, f) HPF, g) UNB, h) PRACS, i) GS2-GLP, j) BDSD, k) ATWT, l) AWLP, m) SSCN, n) GLP, o) MTF-GLP, p) MTF-GLP-HPM, r) GFPCA, s) PXS.

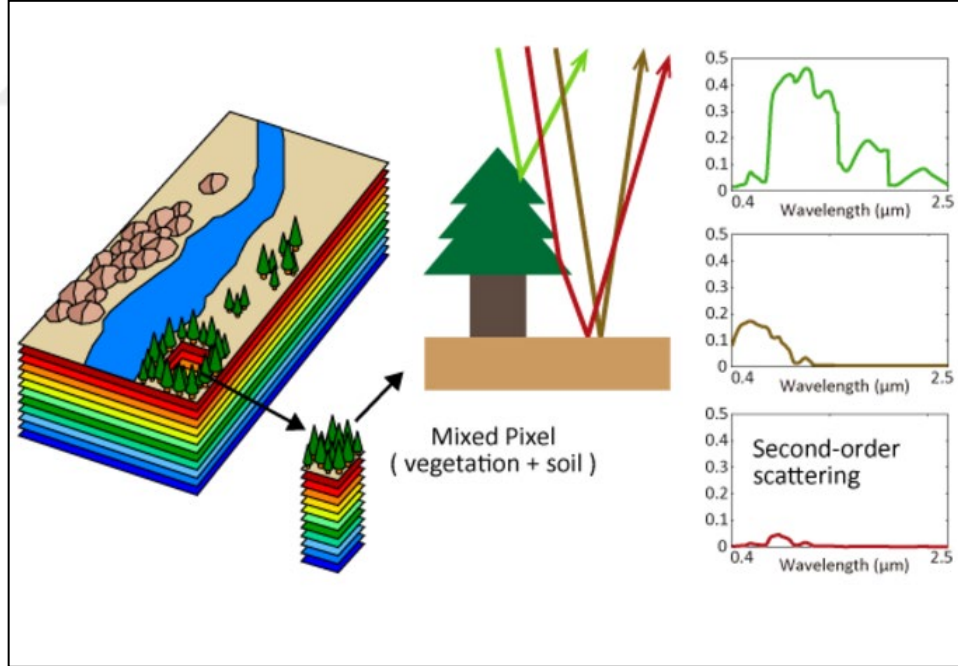


Şekil 1.20. GÖKTÜRK-2 İstanbul-2 verisi pankeskinleştirme görsel sonuçları a) IHS, b) BT, c) PCA, d) GS, e) GSA, f) HPF, g) UNB, h) PRACS, i) GS2-GLP, j) BDSD, k) ATWT, l) AWLP, m) SSCN, n) GLP, o) MTF-GLP, p) MTF-GLP-HPM, r) GFPCA, s) PXS.

Tezin bu bölümde, GÖKTÜRK-2 uydu görüntüleri üzerinde standart ve en güncel olarak kullanılan pankeskinleştirme yaklaşımlarının kapsamlı bir analizi yapılmıştır. Ayrıca bu bölümde GÖKTÜRK-2 verilerinin pankeskinleştirme analizi için MTF ve SRF değerleri ilk defa kullanım bulmuştur. Bu sayede gerçekçi bir analiz yapılarak, pankeskinleştirme yöntemlerinin gerçek GÖKTÜRK-2 verileri üzerinde sağlayacağı başarımın tespit edilmesi mümkün olmuştur. MRA yaklaşımları genel olarak CS yaklaşımlarına üstün gelmekle beraber, alıcı önsel bilgilerini hesaba katan GS2-GLP, MTF-GLP ve MTF-GLP-HPM gibi güncel yöntemler, daha klasik ve geleneksel yaklaşımlara göre fark edilir bir başarım üstünlüğü sağlamaktadır.

1.4. Karışım Giderimi (Unmixing) ile Veri Kaynaştırma

Karışım giderimi son elemanlar ve bolluk haritaları olmak üzere gözlemlenen spektrumu parçalara ayıran bir tekniktir ve temel olarak iki adımdan oluşmaktadır. Bunlar; son elemanların çıkartılması ve onların bolluk haritalarının elde edilmesi aşamalarıdır. Şekil 1.21.'de karışım giderimi anlatılmaktadır:



Şekil 1.21. Spektral karışım giderimi [72].

Son elemanların çıkartılması için konveks geometriye dayalı yaklaşımlar son eleman çıkartımında, her bir son eleman için en az bir saf pikselin varlığını kabul ettiklerinden dolayı en yaygın kullanılan yöntemlerdendir. Elde edilen veriyi en iyi şekilde kullanmak için hiperspektral karışım giderimi gerekli bir prosedür haline

gelmiştir. Lineer ve lineer olmayan karışım giderimi yöntemleri mevcuttur. Lineer karışım modeli en çok kullanılan yaklaşımdır. Bu tez kapsamında lineer karışım modeli yaklaşımı kullanılmıştır. Karışım giderimi yaklaşımının hiperspektral ve multispektral veri kaynaştırmasında kullanılması fiziksel olarak da anlamlıdır.

1.4.1. Lineer karışım modeli - LKM (Linear mixing model - LMM) ile hiperspektral karışım giderimi

Lineer karışım modelinde son elemanların birbirlerinden bağımsız olduğu ve bir hiperspektral görüntünün son elemanlar ve onlara karşılık gelen bolluk haritalarından meydana geldiği kabul edilmektedir.

$$X = WH + E \quad (1.11)$$

Burada W son elemanları, H son elemanlara karşılık gelen bolluk oranlarını ve E gürültüyü ifade etmektedir. Lineer karışım modelinde dikkat edilmesi gereken iki önemli kısıtlama vardır:

- Son elemanların bolluklarının pozitif olma kısıtı (abundance nonnegativity constrained-ANC)
- Son elemanların bir pikseldeki oranlarının toplamının bir olması kısıtı (abundance sum-to-one constrained-ASC),

$$\text{ANC: } H_i \geq 0, \quad i=1, \dots, P \quad (1.12)$$

$$\text{ASC: } \sum_{i=1}^P H_i = 1 \quad (1.13)$$

Buna göre genel olarak hiperspektral karışım giderimi iki adımdan oluşmaktadır:

1. Son eleman çıkarımı ve
2. Karışım halindeki pikselin bolluk oranlarının belirlenmesi

Son eleman çıkarımı için piksel saflık indeksi (Pixel Purity Index - PPI) [73], N-FINDR [74], köşe bileşeni analizi (Vertex Component Analysis - VCA) [75], tek yönlü büyüme algoritması (Simplex Growing Algorithm - SGA) [76]...vb. gibi algoritmalar kullanılmaktadır. Son eleman çıkarımından sonra bu son elemanların ne kadar miktarda olduğunun bulunması için ise, Tam Kısıtlı En Küçük Kareler

Yaklaşımı (Fully Constrained Least Squares - FCLS) [77] ve bağımsız bileşen analizi (Independent Component Analysis - ICA) [78-79] gibi yaklaşımlar kullanılmaktadır.

Lineer karışım modeli, verilen hiperspektral görüntünün son elemanlarının karşılık geldiği bolluk oranları ile ağırlıklandırılmış bir şekilde ifade edilmesi mantığına dayanır ve bu model farklı son elemanların birbirinden farklı olduğunu kabul etmektedir. Dolayısıyla lineer karışım modelinde hiperspektral görüntü, son elemanların spektral imzalarından ve onların sıfırdan büyük eşit olan bolluk miktarlarından oluşmaktadır.

1.4.2. Matris faktörizasyonu (Matrix factorization)

Literatürde lineer karışım modeli altında tanımlanmış olan bir çok hiperspektral karışım giderimi yaklaşımı sunulmuştur. Bu yaklaşımlar arasında negatif olmayan matris faktörizasyonu (Non Negative Matrix Faktörizasyon - NMF) yaklaşımı yüksek derecede karışım halinde bulunan hiperspektral görüntüleri üzerine iyi bir performansla karışım giderimini gerçekleştirdiği için bir çok araştırmacı tarafından büyük bir ilgi ile çalışılmış ve geliştirilmiştir. NMF, veriyi iki tane sıfırdan farklı matrise parçaladığından dolayı, sıfırdan farklı olma kısıtını doğal olarak sağlamaktadır. Bir hiperspektral görüntüde saf piksellerin varlığı gerçekçi olmadığından istatistik bakış açısında bir çok yaklaşım geliştirilmiştir. Bunlar arasında ICA ve NMF en iyi özelliklere sahip olanlardır. Son on yılda NMF, yüksek başarıma sahip bir karışım giderimi yaklaşımı olarak ortaya atılmıştır. NMF, lineer spektral karışım modellerinde sensör özelliklerini kullanması ve kolay gerçekleştirilmesi nedeniyle çok fazla tercih edilmektedir. Beynin bir görüntü üzerindeki nesnelere algıladığı gibi, NMF temel olarak, bir görüntüyü parça parça ifade etme mantığını kullanmaktadır. İteratif algoritmayı kullanarak NMF, verilen verinin iki tane negatif olmayan matris ifadesini aramaktadır. Fakat, objektif fonksiyonun konveks olmaması nedeniyle, çok fazla lokal minimum değerleri elde edilmektedir. Eğer NMF üzerine bir kısıtlama getirilmezse, sadece NMF kullanılarak istenilen sonucun elde edilmesi mümkün değildir. NMF performansını artırmak için çeşitli kısıtlamalar dikkate alınmaktadır.

Genel matris faktörizasyon problemleri için, tekil değer parçalaması (Singular Value Decomposition - SVD) [80], QR decomposition ve LU faktörizasyon gibi geleneksel

matris hesaplama araçları kullanılabilir. Fakat, bu araçlar hiperspektral karışım giderimine direkt olarak uygulanamaz. Çünkü, iki tane kısıtlama üzerinde düşünülme zorundadır. Lineer spektral karışım modelinde maliyet fonksiyonunun hesaplanması için Rezidual matrisin Frobenous normunun hesabı en çok kullanılmaktadır.

NMF yaklaşımı X olarak adlandırılan hiperspektral verisini W_h ve H_h olmak üzere negatif olmayan iki tane matrise parçalamaktadır. Lineer spektral karışım modeline göre, hiperspektral ve multispektral görüntüleri aşağıdaki şekilde ifade edilebilmektedir,

$$X = W_h H_h + E_h \quad (1.14)$$

$$\text{minimum } C(W_h, H_h) = \frac{1}{2} \|X - W_h H_h\|_F^2 \quad (1.15)$$

kısıtı altında $W_h \geq 0, H_h \geq 0$.

Benzer şekilde multispektral görüntü için NMF yaklaşımı, lineer karışım giderimi modeline göre aşağıdaki şekilde tanımlanmaktadır:

$$Y = W_m H_m + E_m \quad (1.16)$$

$$\text{minimum } C(W_m, H_m) = \frac{1}{2} \|Y - W_m H_m\|_F^2 \quad (1.17)$$

kısıtı altında $W_m \geq 0, H_m \geq 0$.

1.4.2.1. NMF için çarpımsal iteratif güncelleme algoritması

NMF problemlerini çözen en popüler algoritmalar iteratif olanlardır. Bunlar (1.15)'de verilen maliyet fonksiyonunu minimize yapmaktadır. Euclidean Distance kullanılarak maliyet fonksiyonu aşağıdaki gibi tanımlanmaktadır,

$$C(W, H) = \frac{1}{2} \|X - WH\|_2^2 = \sum_{ij} (X_{ij} - (WH)_{ij})^2 \quad (1.18)$$

Lee and Seung, standart NMF için çarpımsal güncelleme kuralı oluşturmuşlardır. Ayrıca bu NMF'nin yakınsaması ispatlanmıştır [81]. Bu çarpımsal güncelleme kuralı

geleneksel Gradient Descent Algoritması'ndan çıkarılmaktadır. Toplayarak güncelleme kuralına karşı çarpımsal güncelleme kuralı Gradient Descent Algoritması kullanılarak açıklanabilir. Maliyet fonksiyonunun W ve H'ye göre türevleri alınıp sifıra eşitlenecek olursa,

$$\frac{\partial C(W,H)}{\partial W} = -XH^T + WHH^T \quad (1.19)$$

$$\frac{\partial C(W,H)}{\partial H} = -W^T X + W^T W H \quad (1.20)$$

elde edilmektedir. Geleneksel Gradient Descent Algoritması'nın güncelleme kuralı yazılacak olursa,

$$W \leftarrow W + n_W \cdot (XH^T - WHH^T) \quad (1.21)$$

$$H \leftarrow H + n_H \cdot (W^T X - W^T W H) \quad (1.22)$$

elde edilmektedir. Burada Gradient vektörünün tersi yönünde çok az değerinde bir adım atılarak gerçek minimum değerini yakalama hedeflenmektedir. Bu nedenle, W ve H'e göre Gradient'in tersi alınmıştır. Burada, atılacak adım uzunluğu aşağıdaki gibi tanımlanabilmektedir,

$$n_W = W ./ (WHH^T) \quad (1.23)$$

$$n_H = H ./ (W^T W H) \quad (1.24)$$

Bu değerler yukarıdaki denklemde yerine yazılacak olursa, çarpımsal güncelleme kuralı aşağıdaki şekilde elde edilmektedir,

$$W \leftarrow W \cdot (XH^T) ./ (WHH^T) \quad (1.25)$$

$$H \leftarrow H \cdot (W^T X) ./ (W^T W H) \quad (1.26)$$

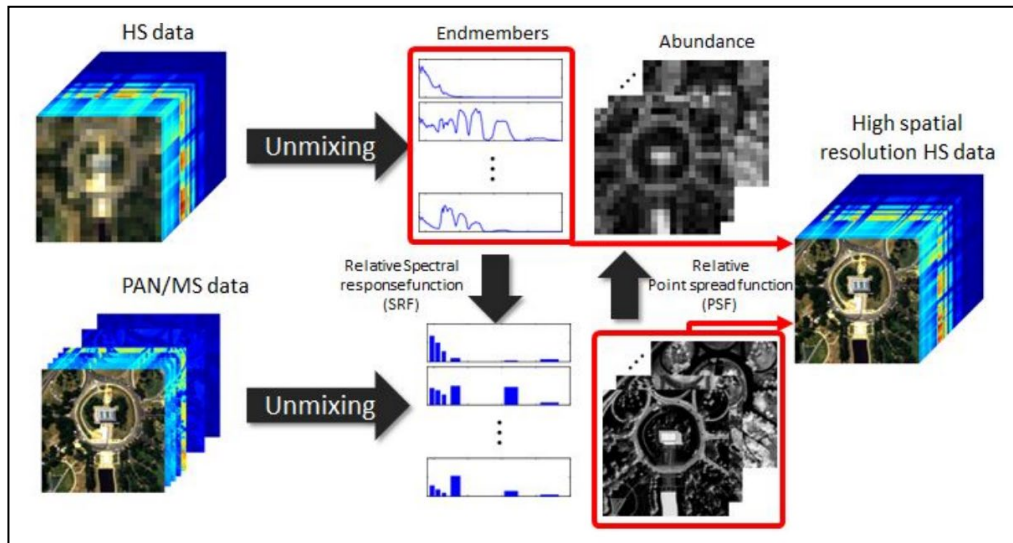
Çarpımsal güncelleme kuralı hızlı ve gerçekleşmesi kolay olduğundan dolayı maliyet fonksiyonunu minimize yapmak için etkili bir yoldur. Literatürde kullanılan NMF algoritmaları temel olarak bu yapı üzerine kurulmuştur. Aşağıdaki Tablo 1.10.'de NMF'nin sözde kodu verilmiştir.

Tablo 1.10. NMF Algoritmasının sözde kodu.

Algoritma 1, (NMF) W ve H matrislerinin hesapla $X \sim WH$	
girdiler: $m \times n$ matris $X \geq 0$ ve son eleman sayısı $M \ll \min(m,n)$	
çıktılar:	$W_{ij} \leftarrow$ negatif olmayan matris $H_{ij} \leftarrow$ negatif olmayan matris
yakınsama ya da durma şartı sağlanasaya kadar tekrar et:	
$W \leftarrow W .* (XH^T) ./ (WHH^T)$	
$H \leftarrow H .* (W^T X) ./ (W^T W H)$	
W'nun kolonlarının toplamını bire eşitle	

1.4.3. Eşlemeli negatif olmayan matris faktörizasyonu (Coupled non-negative matrix factorization - CNMF)

CNMF yaklaşımı [82], düşük uzamsal çözünürlüklü hiperspektral görüntü ile yüksek uzamsal çözünürlüklü multispektral görüntünün veri kaynaştırması sonucu yüksek uzamsal çözünürlüklü hiperspektral görüntü elde etmek için geliştirilmiş bir tekniktir. Özel bir durum olarak HS-PAN görüntülerinin veri kaynaştırması için uygulanabilmektedir. Burada yüksek uzamsal çözünürlüklü görüntü tek bir banttan oluşmaktadır. CNMF veri kaynaştırması gerçekleştirilecek olan her iki veriye de karışım giderimi uygulamakta, son elemanları ve bolluk haritalarını elde etmektedir. Şekil 1.22.'de CNMF yaklaşımı blok şema şeklinde gösterilmektedir.



Şekil 1.22. CNMF kavramı [82]

CNMF yaklaşımında, Şekil 1.22.'de görüldüğü gibi ilk olarak hiperspektral ve pankromatik/multispektral görüntüleri son elemanlar ve onlara karşılık gelen bolluk haritalarına ayrılmaktadır. Daha sonra, pankromatik/multispektral görüntünün bolluk haritaları hiperspektral görüntünün karışım giderimine girdi olarak verilmekte, gerçekleştirilen hiperspektral karışım gideriminin çıktısı olan son elemanlar, pankromatik/multispektral görüntünün karışım analizi için girdi olarak verilmektedir. Bu durum, iteratif olarak belli bir iterasyon sayısı ya da belli bir eşik değeri yakalanana kadar devam etmektedir.

CNMF, hiperspektral ve multispektral veri setleri üzerinde NMF kullanarak karışım giderimi uygulamaktadır. CNMF algoritmasında, lineer spektral karışım modeline dayanarak hem hiperspektral hem de multispektral görüntüleri, son elemanlar ve onlara karşılık gelen bolluk haritalarına ayrılmaktadır. Alıcı gözlem modellerinden SRF, CNMF algoritmasının başlatma aşamasında kullanılmaktadır. CNMF basit bir güncelleme yapısına sahip olduğu için gerçekleşmesi kolay bir algoritmadır. Yapılan çalışmalarda, CNMF'nin yüksek çözünürlüklü hiperspektral veriyi elde etmesiyle sınıflandırma ve tespit için oldukça önemli bir katkı sağladığı kanıtlanmıştır [83].

Hiperspektral ve multispektral veri kaynaştırmasının amacı, yüksek uzamsal ve spektral çözünürlüklü veriyi $Z \in \mathbb{R}^{\lambda_h \times L_m}$, gözlemlenen düşük uzamsal çözünürlüklü hiperspektral verisi $X \in \mathbb{R}^{\lambda_h \times L_h}$ ve yüksek uzamsal çözünürlüklü multispektral verisini $Y \in \mathbb{R}^{\lambda_m \times L_m}$ kullanarak tahminlemektir. Burada L_h ve L_m toplam piksel sayısını, λ_h ve λ_m ise, hiperspektral ve multispektral alıcılarının spektral bantlarını ifade etmektedir. Alıcı Gözlem Modelleri; Düşük uzamsal çözünürlüklü hiperspektral verisi multispektral görüntünün çözünürlüğüne düşürüldüğü ve multispektral görüntü, yüksek uzamsal çözünürlüklü hiperspektral verinin formunda spektral olarak bozulduğunda hiperspektral ve multispektral görüntüleri aşağıdaki gibi modellenebilmektedir,

$$X = ZS + E_s \quad (1.27)$$

$$Y = RZ + E_r \quad (1.28)$$

Burada $S \in \mathbb{R}^{L_m \times L_h}$ uzamsal yayılım dönüşüm matrisi (Spatial Spread Transform Matrix), $R \in \mathbb{R}^{\lambda_m \times \lambda_h}$ spektral yanıt dönüşüm matrisi (Spectral Response Transform

Matrix) olarak tanımlanmaktadır. E_s ve E_r rezidual değerleridir. Lineer spektral karışım modelinin, fiziksel olarak etkin ve matematiksel olarak basit yapısından dolayı karışım giderimi yaklaşımları arasında en çok kullanılan modellerden biri olduğu, yukarıda belirtilmiştir. LKM, herbir pikselin birkaç tane son elemanın lineer karışımına göre ifade edilebiliyor olduğunu kabul etmektedir. Kaynaştırılmış görüntü Z , hiperspektral görüntünün son elemanı ve multispektral görüntünün ise, bolluk oranlarının lineer kombinasyonu şeklinde aşağıdaki gibi ifade edilebilmektedir,

$$Z = W_h H_m + N \quad (1.29)$$

Burada $W \in R^{\lambda_h \times D}$ spektral imza matrisini ve $H \in R^{D \times L_m}$ bolluk oranlarını, D son eleman sayısını ve $N \in R^{\lambda_h \times L_m}$ ise, residual değerlerini ifade etmektedir;

$$X \sim W_h H_h \quad (1.30)$$

$$Y \sim W_m H_m \quad (1.31)$$

Yaklaşık olarak alınarak ve Denklem (1.29)'u Denklem (1.27) ve Denklem (1.28)'de yerine yazacak olursak;

$$H_h \sim H_m S \quad (1.32)$$

$$W_m \sim R W_h \quad (1.33)$$

Ön kısıtlama kuralları elde edilmektedir.

CNMF, kaynaştırılmış Z görüntüsünü sentezlemek için sırasıyla, X ve Y görüntülerine NMF yaklaşımını uygulamakta ve daha sonra Denklem (1.32) ve Denklem (1.33) kısıtları altında kısıtlı optimizasyon problemini iteratif olarak çözmektedir. CNMF, kısıtlı optimizasyon problemi altında sırasıyla W_h ve H_m değerlerini tahminlemek için X ve Y görüntülerine karışım giderimi uygulamaktadır. CNMF için güncelleme kuralı aşağıdaki gibi ifade edilebilmektedir,

$$W_h \leftarrow W_h \cdot * (X H_h^T) ./ (W_h H_h H_h^T) \quad (1.34)$$

$$H_h \leftarrow H_h \cdot * (W_h^T X) ./ (W_h^T W_h H_h) \quad (1.35)$$

$$W_m \leftarrow W_m .* (YH_m^T) ./ (W_m H_m H_m^T) \quad (1.36)$$

$$H_m \leftarrow H_m .* (W_m^T Y) ./ (W_m^T W_m H_m) \quad (1.37)$$

CNMF algoritmasının özetlenmiş şekli aşağıdaki sözde kodda ifade edilebilmektedir:

Tablo 1.11. CNMF Algoritması'nın sözde kodu [82].

Algoritma 2. HS ve MS görüntülerinin veri kaynaştırması için CNMF karışım giderimi
girdiler: HS verisi $X \in R^{\lambda_h \times L_h}$ ve MS verisi $Y \in R^{\lambda_m \times L_m}$
çıktılar: $W \in R^{\lambda_h \times D}$ ve $H \in R^{D \times L_m}$
<p>Adım 1: X için NMF</p> <p>a) VCA ile W_h'i başlat, W_h'i sabit tutarak, H_h'i (7.9)'i kullanarak güncelle</p> <p>b) W_h ve H_h'i (7.11) ve (7.12)'i kullanarak optimize et</p> <p>Adım 2: Y için NMF</p> <p>a) W_m'i (7.10)'yi kullanarak başlat, W_m'i sabit tutarak, H_m'i (7.14)'ü kullanarak güncelle</p> <p>b) W_m ve H_m'i (7.13) ve (7.14)'i kullanarak optimize et</p> <p>Adım 3: Müteakip X için NMF</p> <p>a) H_h'i (7.9)'yi kullanarak başlat, H_h'i sabit tutarak, W_h'i (7.11)'i kullanarak güncelle</p> <p>b) W_h ve H_h'i (7.11) ve (7.12)'i kullanarak optimize et</p> <p>Adım 4: 2 ve 3 Adımlarını tekrar et</p>

1.4.4. Bayesian veri kaynaştırma yaklaşımı

Bayesian yaklaşımı, sonsal dağılımlar aracılığıyla veri kaynaştırma işlemini gerçekleştirmektedir. Veri kaynaştırma problemi kötü konumlanmış olduğu için Bayesian metodolojisi uygun önsel dağılımlar tanımlayarak veri kaynaştırma problemini düzenlemeyi amaçlamaktadır. Bayesian veri kaynaştırması temel olarak, ileri bir model (forward model), istatistiksel varsayımlar ve Gaussian önsellerini problem çözümü için kullanmaktadır. Bayesian yaklaşımı, uygun önsel dağılım ve olabilirlik fonksiyonlarını tanımlayarak sonsal dağılımı hesaplamaya dayalı bir yaklaşımdır. Elde edilen sonsal dağılımlara göre, Bayesian kestiricileri

oluşturulmaktadır. Gözlemlerin olabilirlikleri kullanılarak sonsal dağılımlar tahminlenmektedir. Farklı Bayes kestiricilerini tanımlamak mümkündür. Olabilirlikleri maksimize etmek için hesaplama karmaşıklığını azalttığı ve iterasyon içermediği için, Sylvester denklemi kullanılabilir. Gözlemler (X_h, X_m) veri çiftinden oluşmaktadır. Yüksek uzamsal çözünürlüklü hiperspektral görüntünün düşük uzamsal çözünürlüklü uzayda bulunabileceği varsayılmaktadır. En Küçük Ortalama Kare Hata (Minimum Mean Square Error – MMSE) ve Maksimum Deneysel Sonsal (Maximum A Posteriori - MAP) kestiricileri tanımlanabilmektedir. MMSE kestiricisi, sonsal dağılımın ortalama değeri olarak tanımlanmaktadır. MAP kestiricisi ise, sonsal dağılımın mod değeri olarak tanımlanmaktadır [84].

Genel olarak sonsal dağılımı maksimize etmeye dayalı optimizasyon algoritmaları lokal ekstremum değerine takılma konusunda sıkıntı çekerler. Fakat, MMSE kestiricisi, yüksek hesaplama maliyetine rağmen bu lokal ekstremum probleminin üstesinden gelebilmektedir. Gaussian ve L_1 -norm önselleri, çeşitli kestiricileri oluşturmak için kullanılmaktadır. Temel olarak sonsal dağılımı maksimize yapmak için optimizasyon algoritmaları tasarlanmaktadır. Bu algoritmalar hesaplama karmaşıklığı bakımından etkindir. Fakat, lokal ekstrem değerlerine takılma konusunda sıkıntı yaşarlar. Bu durum sonsalın gerçek maksimum değerine ulaşma garantisini engellemektedir.

Gözlemlenmiş sahnenin sonlu sayıda makroskobik materyalden oluştuğu hipotezi güvenilirdir. Bayes veri kaynaştırması sonsal dağılımı kullanarak veri kaynaştırma sürecine sezgisel bir yorumlama getirmektedir. Bayes metodolojisi, uygun önsel dağılımları tanımlayarak karışım giderimi problemini regülarize hale getirmektedir. Gözlem modeli aşağıdaki gibi yazılabilmektedir:

Lineer karışım modeli $Z=EH$ olmak üzere;

$$X_h = ZBS + N_h \quad (1.38)$$

$$X_m = RZ + N_m \quad (1.39)$$

olarak tanımlanmaktadır. Burada Z , yüksek çözünürlüklü hedef görüntüyü, X_h ve X_m spektral ve uzamsal olarak bozulmuş hiperspektral ve multispektral görüntüleri

temsil etmektedir. R, multispektral görüntü alıcısının spektral SRF değeri ve S ise uniform alt örnekleme operatörüdür. Burada gürültü matrislerinin (N_h, N_m) normal dağılıma sahip oldukları kabul edilmektedir ve aşağıdaki şekilde tanımlanmaktadır,

$$N_h \sim MN_{n_\lambda n} (0_{n_\lambda n}, \Delta_H, I_n) \quad (1.40)$$

$$N_m \sim MN_{m_\lambda m} (0_{m_\lambda m}, \Delta_M, I_m) \quad (1.41)$$

Matris normal dağılımının olasılık yoğunluk fonksiyonu aşağıdaki gibi tanımlanmaktadır;

$$p(X|M, \Sigma_r, \Sigma_c) = \frac{\exp\{-\text{tr}[\Sigma_c^{-1}(X-M)^T \Sigma_r^{-1}(X-M)]\}}{(2\pi)^{\frac{rc}{2}} |\Sigma_c|^{\frac{r}{2}} |\Sigma_r|^{\frac{c}{2}}} \quad (1.42)$$

Bu durumda, birleştirilmiş karışım giderimi modeli aşağıdaki şekli almaktadır. İstatistiksel özellikler kullanılarak aşağıdaki eşitlik yazılabilmektedir;

$$p(X_h|E, H) = MN_{m_\lambda m} (EHBS, \Delta_H, I_m) \quad (1.43)$$

$$p(X_m|E, H) = MN_{n_\lambda n} (REH, \Delta_M, I_n) \quad (1.44)$$

X_h ve X_m koşullu olarak bağımsızdır. Gözlemlenmiş verinin birleşik olabilirlik fonksiyonu aşağıdaki şekilde tanımlanmaktadır;

$$p(X_m, X_h|E, H) = p(X_m|E, H) \cdot p(X_h|E, H) \quad (1.45)$$

Örnekleme yapmak için sonsal dağılımın negatif logaritması alınmaktadır. Olabilirliğin negatif logaritması alındığında aşağıdaki eşitlik elde edilmektedir;

$$\begin{aligned} -\log p(X_m, X_h|E, H) &= -\log p(X_m|E, H) - \log p(X_h|E, H) + C \\ &= \frac{1}{2} \left\| \Lambda_H^{-\frac{1}{2}} (X_h - EHBS) \right\|_F^2 + \frac{1}{2} \left\| \Lambda_M^{-\frac{1}{2}} (X_m - REH) \right\|_F^2 + C \end{aligned} \quad (1.46)$$

Buradaki Frobenous normu aşağıdaki şekilde tanımlanmaktadır;

$$\|X\|_F = \sqrt{\text{trace}(X^T X)} \quad (1.47)$$

Son elemanlar için önsel bilgi değerleri aşağıdaki gibidir. Herbir eleman 0 - 1 arasında olmalıdır. $0 \leq E \leq 1$. Bu son elemanların kısıtını E bölgesinde bir uniform dağılım olarak ifade edebiliriz;

$$p(E) = \begin{cases} c_E, & \text{eğer } E \in E \\ 0, & \text{diğer} \end{cases} \quad (1.48)$$

Burada $E = \{R | 0 \leq R \leq 1\}$ ve $C_E = \frac{1}{\text{vol}(H)}$ olarak tanımlanmaktadır. Bolluk oranları için ise, önsel bilgi değerleri aşağıdaki şekilde tanımlanmaktadır. Bir sahnede bulunan materyallerin bolluk haritaları için ASC ve ANC aşağıdaki şekilde tanımlanmaktadır;

$$\begin{aligned} a_i &\geq 0 \\ \forall j &= \{1, \dots, N\} \\ A &\geq 0 \quad 1_p^T H = 1_n^T \end{aligned} \quad (1.49)$$

Buna ek olarak, ANC ve ASC kısıtı H bölgesinde uniform dağılım şeklinde ifade edilebilmektedir;

$$p(H) = \begin{cases} c_H, & \text{eğer } H \in H \\ 0, & \text{diğer} \end{cases}$$

$$H = \{H | H \geq 0, 1_p^T H = 1_n^T\}, \quad C_H = \frac{1}{\text{vol}(H)} \quad \text{ve} \quad \text{vol}(H) = \int_{H \in H} dH \quad (1.50)$$

Sonsal (Kısıtlı Optimizasyon); Yukarıdaki belirtilen olabilirlik ve önselleri birleştirecek olursak, Bayes teoremine göre, E ve H'nin sonsal dağılımı aşağıdaki şekilde tanımlanmaktadır [90];

$$p(E, H | X_m, X_h) \propto p(X_h | E, H) p(X_m | E, H) p(E) p(H) \quad (1.51)$$

Burada \propto ilişkilidir anlamındadır. Dolayısıyla, karışım giderimine dayalı veri kaynaştırma problemi E ve H'nin sonsal dağılımının maksimizasyonu olarak tanımlanmaktadır. $p(E, H | X_m, X_h)$ 'nin negatif logaritması alınarak (E, H) için MAP kestiricisi aşağıdaki minimizasyon problemi çözülerek elde edilmektedir;

$$\min_{E, H} L(E, H) \quad \text{s.t.} \quad A \geq 0 \quad \text{ve} \quad 1_p^T H = 1_n^T \quad (1.52)$$

$$0 \leq E \leq 1$$

$$L(E,H)=\frac{1}{2}\left\|\Lambda_{\frac{1}{2}}^{-1}(X_h-EHBS)\right\|_F^2+\frac{1}{2}\left\|\Lambda_{\frac{1}{2}}^{-1}(X_m-REH)\right\|_F^2 \quad (1.53)$$

Bu formülasyonda veri kaynaştırma problemi genelleştirilmiş karışım giderimi problemi olarak görülmektedir. Bu $\min L(E,H)$ problemi E ve H'ye göre konveks olmasına rağmen bu iki matrisin birleşik durumu için konveks değildir. Bu nedenle, birden fazla çözümü vardır. Çarpanların Alternatif Yön Yaklaşımı (Alternating Direction Method of Multipliers – ADMM) optimizasyon tekniği kullanılmıştır. ADMM, X'in maximum A posteriori MAP kestiricisini hesaplamaktadır. E şartına göre H ile ilgili optimizasyon ADMM algoritması ile etkili bir şekilde çözülebilmektedir. Naif Gaussian Önseli (Naive Gaussian Prior)'nde; Markov chain Monte Carlo (MCMC) yaklaşımı kullanılarak bazı örneklem değerlerinden gerçek değer tahminlenmeye çalışılmaktadır. Karşılık gelen Bayes kestiricileri bu örneklemeler kullanılarak tahminlenebilmektedir. Seyreklik İçeren Gaussian Önseli (Sparsity Promoted Gaussian Prior)'nde; hiperspektral ve multispektral veri kaynaştırmasında Gaussian önselini ya da düzgün düzenleyiciyi kullanmak yerine, seyrek temsili de kullanılabilir. Gerekli sözlüklerin daha önceki örneklerden oluşturulması yerine gözlemlenen veri setinden oluşturulması veri kaynaştırmada yüksek başarımlar sağlamaktadır. Alt uzaya yansıtılan hedef görüntüsünün görüntü parçaları elemanların seyrek lineer kombinasyonları şeklinde seçilen her bir kolonu atomlardan oluşan sözlük ile ifade edilmektedir. Bu nedenle, adaptif seyrek görüntü bağımsız düzenleyicisi kullanılarak veri kaynaştırma probleminin çözümü için aşağıdaki regülarizasyon düzenleyici terimi tanıtılmaktadır;

$$\Phi(U)\propto-\log p(U)=\frac{1}{2}\sum_{k=1}^{m_\lambda}\|U_k-\varphi(\hat{D}_k,\hat{A}_k)\|_F^2 \quad (1.54)$$

Burada $U_k \in \mathbb{R}^n$ U'nun k.nıncı bandıdır. $\varphi(\cdot):\mathbb{R}^{n_p \times n_{pat}} \rightarrow \mathbb{R}^{n \times 1}$ ise üst üste gelen parçaların ortalamasını alan lineer operatördür. $\hat{D}_k \in \mathbb{R}^{n_p \times n_{at}}$ i.ninci bandın sözlüğü ve $\hat{A}_k \in \mathbb{R}^{n_{at} \times n_{pat}}$ i.ninci bandın kodunu temsil etmektedir. Ayrıca seyreklik ifadesinin önseline dayanarak, kaynaştırma problemi Split Augmented Lagrangian Shrinkage - SALSA Algoritması kullanılarak çözülmektedir. Yukarıda sözü edilen SALSA ve ADMM algoritmalarından daha etkili olan Fast fUsion based on Sylvester Equation (FUSE) tanımlanmıştır [85]. Hızlı bir görüntü kaynaştırma algoritması olarak

Sylvester denklemi verilebilmektedir. Olabilirlikleri maksimize yapmak Sylvester denkleminin çözümüne karşılık gelmektedir. Sylvester denklemi herhangi bir iteratif güncelleme yapmadığından dolayı hesaplama karmaşıklığı diğer var olan algoritmalara göre daha azdır.

1.4.5. Hiperspektral süper çözünürlük (Hyperspectral super resolution - HySure)

Hiperspektral çözünürlük artırımını gerçekleştiren bir diğer yaklaşım ise, HySure'dur. HySure, hiperspektral süper çözünürlük anlamına gelip, iki tane quadratik veri eşleme terimi ve bir tane kenarları koruyan düzenleyici terimi içeren konveks maliyet fonksiyonunu minimize ederek veri kaynaştırma problemini çözmektedir. Optimizasyon formülündeki düzenleyicinin quadratik olmaması ve hiperspektral görüntü bantlarının çok fazla sayıda olması nedeniyle, hiperspektral görüntü bir alt uzaya alınıp orada problemin çözümü gerçekleştirilmektedir. HySure, ADMM ve SALSA yaklaşımını kullanarak optimizasyon problemini gerçekleştirmektedir. HySure yaklaşımına göre, hiperspektral ve multispektral gözlem matrisleri aşağıdaki gibi ifade edilebilmektedir;

$$X_h = ZBM + N_h \quad (1.55)$$

$$X_m = RZ + N_m \quad (1.56)$$

Burada B uzamsal blur matrisi olup sensörün PSF değerini ifade etmektedir. R ise, SRF değerine karşılık gelmektedir. Bu çalışmada B ve R değerleri quadratik optimizasyon problemi formülasyonu kullanılarak bulunmuştur. HySure için boyut azaltımı oldukça önemlidir.

Alt boyutta çalışmanın iki önemli avantajı bulunmaktadır. Birincisi hesaplama karmaşıklığının, ikincisi ise, tahminlenmesi gereken değişken sayısının önemli ölçüde azalmasıdır. Bu nedenle alt uzayda çalışmak daha çok tercih edilmektedir. Hiperspektral veri seti, bantları arasında yüksek derecede ilişkiye sahip olduğu için, daha düşük boyutlu bir uzayda ifade edilebilmektedir;

$$Z = EH \quad (1.57)$$

Burada E alt uzayı geren (span) vektörlerden oluşan matris ve H ise, ifade katsayısıdır. Lineer karışım giderimi yaklaşımında E matrisi spektral imza matrisi ve H bolluk haritalarını ifade etmektedir. Boyut azaltımı için; VCA [75] ya da SVD [80] yaklaşımlarından biri tercih edilerek gerçekleştirilebilmektedir. (1.46) denklemi (1.44) ve (1.45) denklemlerinde yerine yazıldığında aşağıdaki eşitlikler elde edilmektedir;

$$X_h = EHB_M + N_h \quad (1.58)$$

$$X_m = REH + N_m \quad (1.59)$$

HySure, kötü koşullanmış problem olduğu için bir düzenleme parametresine ihtiyaç duymaktadır. Bu regularizasyon Bu regularizasyon terimi, vector toplam varyasyon (vektor total variation) formundadır ve aşağıdaki şekilde ifade edilmektedir;

$$\varphi(HD_h, HD_v) = \sum_{j=1}^{n_m} \sqrt{\sum_{i=1}^{L_s} \left\{ [HD_h]_{ij}^2 + [HD_v]_{ij}^2 \right\}} \quad (1.60)$$

Burada D_h ve D_v görüntünün yatay ve düşey ayırık (discrete) farklarını ifade etmektedir. Bu durumda optimizasyon problemi aşağıdaki şekli almaktadır;

$$\text{minimize } \frac{1}{2} \|X_h - EHB_M\|_F^2 + \frac{\lambda_m}{2} \|X_m - REH\|_F^2 + \lambda_\varphi \varphi(HD_h, HD_v) \quad (1.61)$$

Burada ilk iki terim veri eşleme terimidir ve son terim ise, kenarları koruyan vektör toplam varyasyon formunda bir regularizasyon terimidir. HySure algoritmasının özetlenmiş şekli aşağıda görülmektedir [86];

Tablo 1.12. HySure Algoritması'nın sözde kodu.

Algoritma 3. HySure Algoritması
Adım1: Sensörlerin spektral ve uzamsal yanıt değerlerinin tahminlenmesi, regularizasyon parametresinin ayarlanması
Adım 2: Veri Kaynaştırma algoritmasının çalıştırılması
Ön hesaplamalar
Altuzay öğrenme
ADMM/SALSA

Problem (1.50) konveks olmadığı için çözümü oldukça zordur, bunun için SALSA yaklaşımı kullanılmaktadır. SALSA, orijinal karmaşık optimizasyon problemini daha basit problemlere ayrıştırarak iterasyonlarla çözmektedir. ADMM yaklaşımında orijinal optimizasyon değişkeni X toplam beş değişkene parçalanmaktadır.

1.4.6. Sylvester denklemine dayalı hızlı kaynaştırma (Fast fusion based on Sylvester equaton – FUSE)

FUSE isminin kısaltması olarak tanımlanmıştır. FUSE olabilirliklerin maksimizasyon problemini çözmek için Sylvester denklemini kullanmaktadır. Sylvester denklemi, kapalı formdaki çözüm hesaplama performansını iyileştirmektedir.

FUSE, ADMM ve Block Coordinate Descent – BCD [87] yaklaşımlarını kullanarak, önsel bilgiyi veri kaynaştırma problemi ile ilişkilendirerek Bayesian kestiricilerini genelleylebilmektedir. Bayesian kestiricilerini yaklaşık olarak bulmak için Gaussian önsel dağılımı kullanılarak çeşitli hesaplama stratejileri geliştirilmiştir. X'in Maximum Aposteriori kestiricisini hesaplamak için Markov Chain Monte Carlo-MCMC, ADMM ve SALSA gibi yaklaşımlar geliştirilmiştir [85].

Aşağıdaki gibi tanımlanan model ile birlikte,

$$X_h = ZBS + N_h \quad (1.62)$$

$$X_m = RZ + N_m \quad (1.63)$$

Z = EH olmak üzere, gürültü matrisleri N_h ve X_m 'in istatistiksel özellikleri dikkate alındığında veri kaynaştırma probleminin formülasyonu lineer model ve en küçük kareler anlamında aşağıdaki şekilde tanımlanmaktadır;

$$\arg \min_H L(H) = \arg \min_H d(H) + \phi(H) \quad (1.64)$$

Burada;

$$d(H) = \frac{1}{2} \left\| \Lambda_H^{-1} (X_h - EHBS) \right\|_F^2 + \frac{1}{2} \left\| \Lambda_M^{-1} (X_m - REH) \right\|_F^2 \quad (1.65)$$

$$\emptyset(H) = \frac{1}{2} \left\| \Sigma^{-1} (H - \mu) \right\|_F^2 \quad (1.66)$$

Olarak tanımlanmaktadır. $L(H)$ değerini minimize yapmak $\frac{dL(H)}{dH} = 0$ şartının sağlanması ile mümkündür. Böylece, aşağıdaki matris denklemi elde edilmektedir;

$$\begin{aligned} H^H \Lambda_H^{-1} E H B S (B S)^h + ((R E)^h \Lambda_M^{-1} R E + \Sigma^{-1}) H \\ = H^h \Lambda_H^{-1} E H B S (B S)^h + (R E)^h \Lambda_M^{-1} R + \Sigma^{-1} \mu \end{aligned} \quad (1.67)$$

Bu denklemi çözenin zorluğu U matrisinin yüksek boyutlu olmasından ve alt örneklem matrisi S 'in varlığından kaynaklanmaktadır.

1.4.7. Maksimum deney sonrası / stokastik karışım modelini (Maximum aposterior - MAP / stochastic mixing model - SMM)

Maximum Aposterior yaklaşımı hiperspektral görüntünün uzamsal çözünürlüğünün artırılması için geliştirilmiştir. MAP yaklaşımı, spektral sahnenin içeriğini belirlemek için stokastik karışım modelini (Stochastic Mixing Model - SMM) kullanmaktadır. SMM, gözlemlenen hiperspektral ve multispektral veriyi kullanarak, yüksek uzamsal ve yüksek spektral çözünürlüklü hiperspektral veriyi optimize eden bir maliyet fonksiyonu tanımlayarak, spektral sahnenin karakteristiklerini ya da yüksek çözünürlüklü hiperspektral görüntünün koşullu ortalama vektörü ve kovaryans matrisini, gözlemlenen multispektral görüntüden tahminlemektedir. Ortalama spektrum, kovaryans matrisi ve her bir son elemanın bolluk haritaları düşük çözünürlüklü hiperspektral görüntüden çıkarılmaktadır. Yüksek çözünürlüklü hiperspektral verisini optimize etmek için spektral karışım modeli istatistiklerine dayalı girdi görüntüleriyle ilişkili bir şekilde MAP objektif fonksiyonu tanımlanmaktadır. MAP - SMM yaklaşımı düşük çözünürlüklü hiperspektral görüntünün temel bileşenler alt uzayında gerçekleştirilmektedir [88].

Bir boyutlu pankromatik görüntü $x = [x_1, x_2, \dots, x_N]^T$ ve çok boyutlu hiperspektral görüntü $y = [y_1^T, y_2^T, \dots, y_N^T]^T$ olmak üzere, kaynaştırılmış görüntü Z , $z = [z_1^T, z_2^T, \dots, z_N^T]^T$ şeklinde tanımlanabilmektedir. Bu durumda gözlem modellerinden pankromatik görüntü ile yüksek çözünürlüklü hiperspektral görüntü arasındaki ilişki

$$x = S^T z + \alpha \quad (1.68)$$

ve benzer şekilde düşük çözünürlüklü hiperspektral ile yüksek çözünürlüklü hiperspektral görüntü arasındaki ilişki;

$$y = Hz + \beta \quad (1.69)$$

şeklinde tanımlanabilmektedir. Burada S spektral yanıt matrisi ve H uzamsal yanıt fonksiyonudur. Bu her iki matrisin de tersi alınabilir ve karesel olmadığından dolayı kaynaştırılmış görüntü Z için tek bir çözüm yoktur. MAP tahminleyicisinin amacı yüksek çözünürlüklü hiperspektral görüntünün koşullu olasılığını maksimize yapmaktır;

$$\hat{z} = \arg \max_z [p_z(z | x, y)] \quad (1.70)$$

Bayes kuralı kullanılarak koşullu olasılık yoğunluk fonksiyonu aşağıdaki gibi tanımlanmaktadır;

$$p_z(z | x, y) = \frac{p_{x,y}(x, y | z) p_z(z)}{p_{x,y}(x, y)} \quad (1.71)$$

Gözlemlenmiş görüntülerin koşullu olarak bağımsız olmalarından dolayı bu eşitlik,

$$p_z(z | x, y) = \frac{p_{x,z}(x | z) p_{y,z}(y | z) p_z(z)}{p_{x,y}(x, y)} \quad (1.72)$$

şeklinde yazılabilmektedir. Z'ye bağlı olmayan paydadaki ifade yok sayıldığında kaynaştırılmış görüntü,

$$\hat{z} = \arg \max_z [p_{x,z}(x | z) p_{y,z}(y | z) p_z(z)] \quad (1.73)$$

şeklini almaktadır. Buradaki koşullu yoğunluk olasılık fonksiyonu gözlem modellerinden çıkartılabilmektedir;

$$p_{x,z}(x | z) = \frac{1}{(2\pi)^{\frac{N}{2}}} \frac{1}{\sigma_n^N} \exp \left\{ -\frac{1}{2\sigma_n^N} (x - S^T z)^T (x - S^T z) \right\} \quad (1.74)$$

$$p_{y,z}(y|z) = \frac{1}{(2\pi)^{\frac{MK}{2}}} \frac{1}{|C_n|} \exp \left\{ -\frac{1}{2} (y-Hz)^T C_n^{-1} (y-Hz) \right\} \quad (1.75)$$

Yüksek çözünürlüklü hiperspektral görüntünün yoğunluk fonksiyonu bilinmemektedir. Fakat, burada normal dağılıma sahip olduğu kabul edilmektedir. m , ortalama ve C kovaryans matrisi olmak üzere objektif fonksiyonu aşağıdaki gibi ifade edilebilmektedir;

$$f(z) = \frac{1}{2\sigma_n^N} (x - S^T z)^T (x - S^T z) + \frac{1}{2} (y - Hz)^T C_n^{-1} (y - Hz) - \frac{1}{2} (z - m_z)^T C_n^{-1} (z - m_z) \quad (1.76)$$

Bu fonksiyon basit matematiksel manipulasyonlarla Hessian matrisine dönüştürülebilmektedir.

SMM, lineer karışım modeline benzemektedir. SMM, düşük uzamsal çözünürlüklü hiperspektral görüntüden çıkartılmaktadır ve spektral veriyi son eleman spektrumlarının lineer kombinsyonları şeklinde parçalamaya çalışmaktadır. Gözlemlenmiş hiperspektral görüntüdeki her bir spektrumum rastgele vektör w tarafından tanımlanan karışım sınıfının bir üyesi olduğu kabul edilmektedir;

$$w|q = \sum_{m=1}^{N_c} a_m(q) \varepsilon_m \quad (1.77)$$

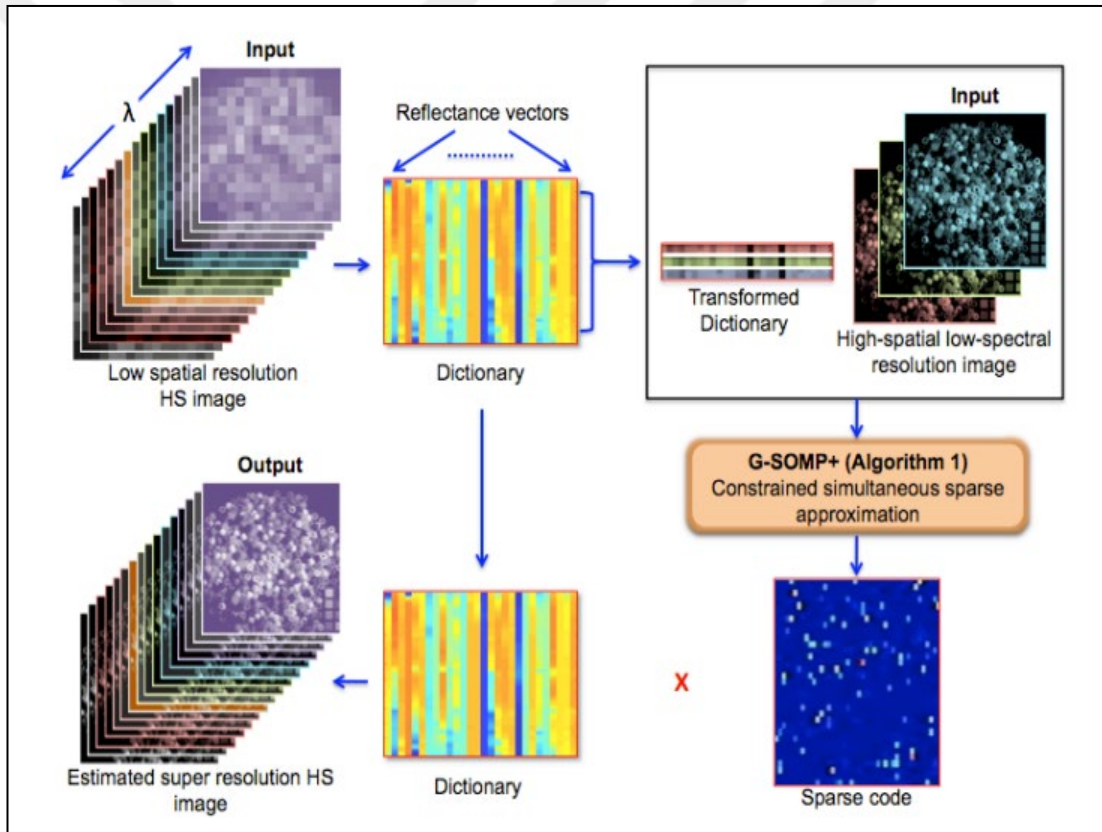
burada $a_m(q)$ son eleman bolluk oranlarını ve ε_m ise son elemanları temsil etmektedir. Dolayısıyla, sınıf koşullu olasılık yoğunluk fonksiyonu aşağıdaki gibi tanımlanmaktadır;

$$p_{w|q}(w|q) = \frac{1}{(2\pi)^{\frac{K}{2}}} \frac{1}{|C(q)|} \exp \left\{ -\frac{1}{2} (w - m(q))^T C^{-1}(q) (w - m(q)) \right\} \quad (1.78)$$

1.4.8. Akhtar'ın metodu

Akhtar ve arkadaşları hiperspektral görüntünün süper çözünürlüğü için seyrek ifadeye dayalı bir yaklaşım sunmuşlardır. Bu yaklaşım ilk olarak sahnenin farklı reflektans spektrallerini, mevcut olan hiperspektral görüntüden çıkartmaktadır. Daha

sonra yüksek uzamsal fakat düşük spektral çözünürlüklü görüntünün yapısı çıkarılan spektrum cinsinden, sinyalin seyrekliği, negatif olmaması ve sahnenin uzamsal yapısı kullanılarak açıklanmaktadır. Bu açıklama (G-SOMP+) Algoritması kullanılarak yapılmaktadır. Bu algoritma, Simultaneous Orthogonal Matching Pursuit (SOMP) algoritmasının genelleştirilmiş halidir. Generalization of simultaneous orthogonal matching pursuit (G-SOMP+) yaklaşımı seyrek kodu öğrenmek için sunulmuştur [89]. Akhtar, son elemanları ve yüksek çözünürlüklü bolluk haritalarını elde etmek için sözlük öğrenmesi ve seyrek kodlamayı uygulamıştır. Son elemanların spektral imzaları online sözlük öğrenme metoduyla elde edilmektedir. Şekil 1.23'de Akhtar'ın metodu blok şema şeklinde görülmektedir.



Şekil 1.23. Akhtar's yaklaşımının şematik görünümü [89].

1.4.9. Lanaras'ın metodu

Lanaras'ın sunduğu yaklaşım, hiperspektral süper çözünürlük ve karışım giderimi problemlerini karşılıklı olarak çözmektedir. Veri Kaynaştırma için Eşlemeli Negatif Olmayan Matris Faktörizasyonu (Coupled Non-Negative Matrix Factorization - CNMF)'na benzer bir şekilde Lanaras'ın algoritması sırası ile iki tane girdi

görüntüsüne karışım giderimi uygulamaktadır. Hiperspektral ve multispektral görüntülerini içeren iki tane karışım giderimi problemini çözerek son elemanların imzalarını ve bunlara karşılık gelen yüksek çözünürlüklü bolluk oranlarını sırasıyla güncellemek için diğer uzaya yansıtılan Gradient yaklaşımı kullanılmaktadır.

Son elemanları başlatmak için Ayrık Genişletilmiş Lagrange ile Simpleks Tanımlama (Simplex Identification via Split Augmented Lagrangian – SISAL) [90] yaklaşımı kullanılmaktadır.

Başlangıç bolluk oranlarını elde etmek için ise, Sparse Unmixing Variable Splitting and Augmented Lagrangian (SUnSAL) yaklaşımı kullanılmaktadır. Ayrıca uzamsal ve spektral sensör karakteristikleri uzamsal olarak bozulmuş son eleman ve bolluk oranlarının başlangıç değerlerinin atanması için gereklidir [91].

Lineer karışım modeline göre verilen bir piksel son elemanlar ve bunlara karşılık gelen bolluk oranlarının çarpımının toplamından oluşmaktadır;

$$z = \sum_{j=1}^P e_j a_j, \quad Z=EA \quad (1.79)$$

Kaydedilen düşük uzamsal çözünürlüklü hiperspektral görüntü, kaynaştırma sonucu olan Z görüntüsünün uzamsal olarak kötüleştirilmiş versiyonudur. Bu durumda aşağıdaki gibi yazılabilmektedir;

$$H \sim ZS = EAS = E\hat{A} \quad (1.80)$$

burada S , alt örneklem operatörü olup sensörün uzamsal yanıt değerini ifade etmektedir. $\hat{A}=AS$ ise, düşük çözünürlükte bolluk değerlerini ifade etmektedir. Benzer şekilde yüksek uzamsal çözünürlüklü multispektral görüntü Z , kaynaştırılmış görüntünün spektral olarak bozulmuş versiyonudur ve aşağıdaki şekilde ifade edilebilmektedir;

$$M \sim RZ = REA = \hat{E}A \quad (1.81)$$

burada R , sensörün spektral yanıt fonksiyonu ve $\hat{E}=RE$ ise, spektral olarak bozulmuş son elemanları ifade etmektedir.

Lanaras'ın yaklaşımındaki temel mantık Denklem (1.70)'de verilen gerçeği kullanarak süper çözünürlüğü artırmaktır. Buna göre, aşağıdaki kısıtlamalar yazılabilmektedir;

$$a_{ij} \geq 0 \quad \forall i,j \quad (\text{negatif olmayan bolluk değeri}) \quad (1.82)$$

$$1^T A = 1^T \quad (\text{bolluk değerinin toplamı } 1) \quad (1.83)$$

$$0 \leq e_{ij} \leq 1 \quad \forall i,j \quad (\text{negatif olmayan sınırlı reflektans}) \quad (1.84)$$

Bu anlatılan süper çözünürlük problemini çözmek için kaynaştırılmış görüntü Z, dolayısıyla E ve A tahminlenebilmektedir.

$$\arg \min_{E,A} \|H-EAS\|_F^2 + \|M-REA\|_F^2 \quad (1.85)$$

$$\text{kısıtı altında} \quad 0 \leq e_{ij} \leq 1 \quad \forall i,j$$

$$a_{ij} \geq 0 \quad \forall i,j$$

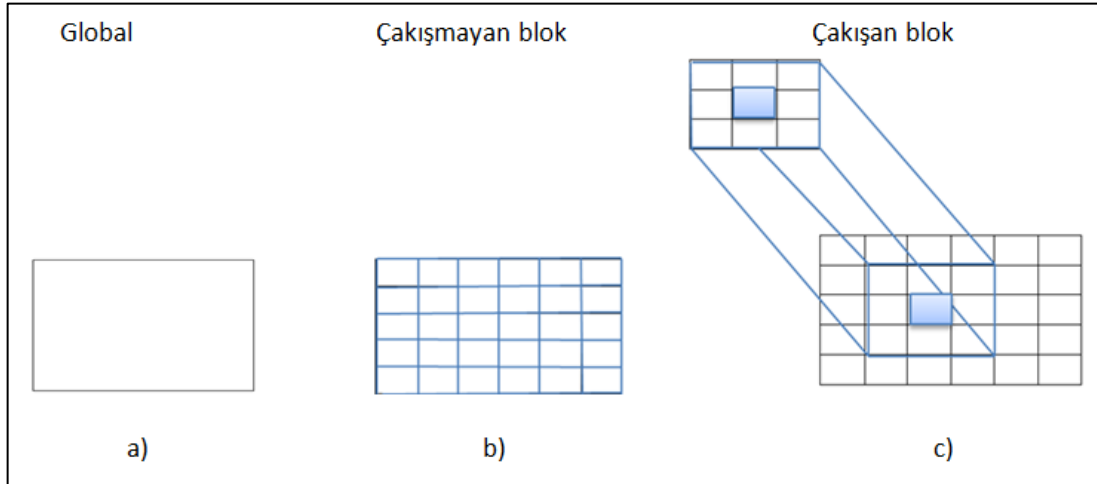
$$1^T A = 1^T \quad \|A\|_0 \leq s \quad (1.86)$$

1.5. Pankromatik - Hiperspektral Pankeskinleştirme Temelli Uzamsal Çözünürlük Artırımı

1.5.1. Blok ve kümeleme tabanlı PAN-HS pankeskinleştirme yaklaşımlarının başarımların analizi

Pankeskinleştirilmiş görüntüler yer yüzü yüzeyinin yüksek uzamsal ve yüksek spektral özelliklerle karakterize edilerek ifade edilmesinde kullanılmaktadır. Pankeskinleştirme temel olarak pankromatik görüntüden yüksek frekans detaylarını çıkartıp, daha sonra elde edilen bu detayların multispektral/hiperspektral görüntüye eklenmesi işlemidir. Birçok pankeskinleştirme yaklaşımında ikinci adım sırasında daha iyi sonuç elde etmek için, elde edilen detaylar kazanç faktörü ile ağırlıklandırılarak eklenmektedir. Detay ekleme, belirlenen katsayı ile gerçekleştirilmektedir. Bu katsayılar global yaklaşımlarla bütün görüntü için ya da içeriğe dayalı yaklaşımlarla küçük piksel grupları için belirlenebilmektedir. İçeriğe

dayalı yaklaşımlarda detay katsayısı görüntü bölütleri boyunca tahmin edilerek belirlenmektedir. Detay ekleme adımı kullanılan yaklaşımda detay katsayısının nasıl tanımlandığına bağlı bir operasyondur. Bu detay katsayısının tanımı bütün görüntü için global olarak yapılabilir ya da içeriğe bağlı bir şekilde lokal olarak da belirlenebilmektedir. Detay ekleme katsayılarının tahminleme prosedürü düşük hesaplama karmaşıklığına sahiptir. Çünkü, detay ekleme katsayıları kayan pencere ya da her bir bölüt boyunca görüntüden lokal bir şekilde çıkartılmaktadır. Bir görüntüyü lokal parçalara ayırmak için üst üste gelmeyen (çakışmayan) ya da çakışan bloklar ile parçalara ayırma teknikleri kullanılabilir. Global değeri detay ekleme katsayısını bütün görüntü için hesaplamaktadır. Blok metodu görüntüyü karesel bloklar şeklinde parçalara ayırmaktadır. Burada her bir blok içerisinde bulunan piksellerin katkıda bulunduğu bir detay ekleme katsayısı hesaplanmaktadır. Bu detay katsayısı her farklı blok için farklı bir değer almaktadır. Çakışan blok yaklaşımı ise, detay ekleme katsayısının kayan pencere boyunca her bir piksel için ayrı ayrı hesaplanması işlemine dayanmaktadır. Örneğin; dikdörtgenel kayan pencere her bir piksel için hangi detay katsayısının geleceğini bulmak için uygulanabilmektedir. Şekil 1.23.'de global, çakışmayan ve çakışan bloklar boyunca hesaplanan detay katsayısının temsili bir gösterimi sunulmaktadır.



Şekil 1.24. Global, çakışmayan ve çakışan blokları içeren pikseller a) global b) çakışmayan blok ve c) kayan pencere şeklinde çakışan blok gösterimleri

Dolayısıyla bu detay ekleme prosedürü global, blok tabanlı ve kümeleme tabanlı teknikler kullanılarak gerçekleştirilebilmektedir. Lokal metodların spektral özellikleri daha iyi koruduğu literatürde gösterilmiştir. Tezin bu bölümünde, blok ve kümeleme

tabanlı yaklaşımlar standart bileşen ekleme pankeskinleştirme yaklaşımlarından IHS [38], BT [39], GS [41] ve PCA [40] üzerine uygulanmıştır. Bunu gerçekleştirmek için çakışmayan ve çakışan blok yaklaşımlarıyla beraber k-ortalama kümeleme (k-means), İteratif Özyinelemeli Data Analiz Tekniği Algoritması (Iterative Self Organizing Data Analysis Techniques Algorithm - ISODATA) [92] ve Basit Lineer İteratif Kümeleme (Simple Linear Iterative Clustering - SLIC) [93] yaklaşımları kullanılmıştır. Bu yaklaşımların performans karşılaştırmasını yapabilmek için farklı karakteristikte iki veri seti kullanılmıştır. Blok ve kümeleme tabanlı yaklaşımların daha iyi performans sonucu verdiği görülmüştür. Bilgimize göre, süperpiksel kümeleme yaklaşımı literatürde ilk defa hiperspektral pankeskinleştirme yaklaşımından önce kullanılmıştır. Deneysel sonuçlar iki veri seti üzerinde uzamsal bilginin pankeskinleştirme yaklaşımıyla birleştirilmesinin önemini vurgulamaktadır. Çoğu CS pankeskinleştirme yaklaşımı piksel tabanlıdır ve pankeskinleştirme sürecinde görüntünün uzamsal konfigürasyonunu dikkate almamaktadır. Bu kısıtlamanın üstesinden gelmek için literatürde çeşitli çalışmalar gerçekleştirilmiştir. Bazı CS yaklaşımları üzerine blok ya da kümeleme tabanlı metodolojiler kullanılmıştır. Örneğin; HS pankeskinleştirme için, k-ortalama kümeleme ve İkili Parçalama Ağacı (Binary Partition Tree - BPT) [94] GS pankeskinleştirme yaklaşımı üzerinde global ve lokal kazanç tahminleme prosedürü kullanılarak hesaplanmıştır [95-96]. Benzer bir amaç için Neural Network ve Laplacian filtresi [97] de kullanılmıştır. Uzamsal bilginin içeriğe bağlı integrasyonu [98]'da uygulanmıştır. Bu yaklaşımların güçlü ve zayıf yönleri dikkate alındığında MRA'dan daha çok CS pankeskinleştirme yaklaşımlarına daha uygun olduğu sonucuna varılabilmektedir [60].

1.5.1.1. Çakışan ve çakışmayan bloklar için deneysel sonuçlar

Tezin bu bölümünde çeşitli pankeskinleştirme yaklaşımları görüntüyü bölütlere parçalayarak aynı bölgedeki piksellerin aynı detay katsayısına sahip olmasına dayalı pankeskinleştirme sonuçları analiz edilmiştir. Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) alıcısından elde edilen Indian Pines veri seti için global ve lokal kazanç faktörü tahminlemesine dayalı ayrıntılı bir performans karşılaştırması sunulmaktadır. Indian Pines'dan 120×120 piksel büyüklüğünde bir alt görüntü kullanılmıştır. Bu veri seti üzerinde yapılan aşağıdaki test sonuçlarına göre, bazı

durumlarda global yaklaşımların daha düşük bir performans ile sonuçlandığı gözlemlenmiştir. Ayrıca blok boyutunun ayarlanabilmesi spektral karakteristikleri korumakla beraber, uzamsal ve yapısal içeriği artırmaktadır. Eğer blok boyutu büyük olursa, uzamsal ve yapısal detaylar artırılırken, spectral özellikleri koruma azalmaktadır, eğer blok boyutu küçük olursa uzamsal ve yapısal detaylar azalırken, daha çok spektral özellikler korunmaktadır. Aşağıdaki tablolarda AVIRIS Indian Pines veri seti üzerinde çakışmayan ve farklı boyutlarda çakışan bloklarla yapılan deneylerin sonuçları sunulmaktadır. Bu deney gerçekleştirilirken oluşturulan sentetik pankromatik görüntü hiperspektral görüntü ile farklı sayıda çakışan bantların ortalaması şeklinde alınmıştır.

Tablo 1.13. AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS-PAN çakışan bantlar (2-35) SRF ile, senaryo 1.

		Orijinal	çakışmayan blok (15x15)	Blok Boyutu			
				Çakışan blok			
				5x5	9x9	15x15	25x25
IHS	RMSE	66,28	77,01	90,93	80,59	75,69	71,52
	PSNR	37,40	35,65	34,35	35,29	35,86	36,45
BT	RMSE	63,62	75,21	89,67	78,87	73,72	69,25
	PSNR	37,45	35,76	34,54	35,48	36,02	36,59
PCA	RMSE	46,73	62,59	81,08	67,00	60,08	54,50
	PSNR	39,76	37,30	35,26	36,76	37,62	38,40
GS1	RMSE	45,75	62,32	81,19	66,94	59,87	53,84
	PSNR	39,91	37,32	35,25	36,76	37,64	38,49
GS2	RMSE	114,74	129,77	129,73	124,39	121,16	118,34
	PSNR	32,58	31,64	31,62	31,95	32,16	32,34
GS-LS	RMSE	60,35	105,41	129,26	115,60	106,09	91,38
	PSNR	37,66	33,27	31,64	32,53	33,23	34,40
HPF	RMSE	122,09	126,26	125,98	126,25	125,86	125,26
	PSNR	32,18	31,83	31,87	31,87	31,90	31,95
UNB	RMSE	55,88	165,97	76,24	69,77	64,96	60,28
	PSNR	39,33	28,69	35,90	36,58	37,24	38,12
AWLP	RMSE	81,98	86,83	x	84,57	83,86	82,40
	PSNR	35,27	34,79	x	35,03	35,09	35,22
ATWT	RMSE	81,32	86,61	x	84,56	83,68	82,11
	PSNR	35,36	34,82	x	35,02	35,11	35,25

Tablo 1.13’da sentetik pankromatik görüntü sadece hiperspektral görüntü ile çıkarılan bantlarının (2-35) ortalaması şeklinde alınmıştır. Sayısal sonuçlara bakılacak olursa, orijinal görüntünün çıkarılan ya da çıkarılmayan blok sonuçlarına göre daha iyi pankeskinleştirme sonucu verdiği görülmüştür.

Tablo 1.14. AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS-PAN çıkarılan bantlar (1-224) SRF ile, senaryo 2.

		Original	çıkartılmayan blok (15x15)	Blok Boyutu			
				Çıkartılan blok			
				5x5	9x9	15x15	25x25
IHS	RMSE	91,538	77,35	82,40	81,88	82,65	84,27
	PSNR	23,38	25,32	26,31	25,90	25,47	24,92
BT	RMSE	101,98	83,18	82,70	83,72	86,08	89,66
	PSNR	26,76	28,27	27,89	27,93	27,82	27,62
PCA	RMSE	71,87	78,21	79,24	82,31	78,77	81,54
	PSNR	28,89	28,52	28,15	27,92	28,30	28,11
GS1	RMSE	88,05	71,71	72,01	69,17	70,52	74,65
	PSNR	27,09	28,80	28,85	29,17	29,01	28,53
GS2	RMSE	82,35	81,20	88,61	86,19	84,84	83,82
	PSNR	27,80	27,94	27,24	27,46	27,58	27,67
GS-LS	RMSE	67,50	80,59	87,49	87,46	85,70	82,65
	PSNR	29,39	27,99	27,38	27,37	27,51	27,76
HPF	RMSE	83,58	80,61	86,48	85,34	85,00	84,59
	PSNR	26,08	25,53	25,62	26,71	26,78	26,74
UNB	RMSE	97,30	898,65	86,70	90,20	93,07	94,74
	PSNR	29,14	10,78	28,25	28,34	28,48	28,71
AWLP	RMSE	106,26	103,20	x	99,35	102,18	104,37
	PSNR	27,97	28,04	x	28,25	28,15	28,08
ATWT	RMSE	71,14	71,89				71,20
	PSNR	29,27	29,22				29,34

Tablo 1.14’de sentetik pankromatik görüntü hiperspektral görüntünün bütün bantlarının ortalaması şeklinde alınmıştır. Genellikle CS yaklaşımlarından IHS, BT ve GS’nin blok tabanlı pankeskinleştirmede daha iyi performans verdiği

görülmektedir. Tablo 1.15’de sentetik pankromatik görüntü hiperspektral görüntünün bütün bantlarının ortalaması şeklinde alınmıştır. Ancak SRF değeri kullanılmamıştır.


SRF kullanılmadan CS yaklaşımlarından IHS, BT, PCA ve GS’nin daha iyi pankeskinleştirme sonucu verdiği SRF değerlerinin kullanılmasına göre daha belirgin bir performans artışı sağladığı görülmektedir.

Tablo 1.15. AVIRIS Indian Pines (1992) HS-PAN, piksel-piksel, HS-PAN çakışan bantlar (1-224) SRF olmadan, senaryo 3, PAN = mean(data(:, :, overlap)) çakışan_bantlar = 1:41.

		Original	Blok Boyutu				
			çakışmayan blok (15x15)	Çakışan blok			
				5x5	9x9	15x15	25x25
IHS	RMSE	82,08	75,45	73,23	73,12	73,96	75,51
	PSNR	24,21	25,68	27,01	26,59	26,19	25,68
BT	RMSE	91,24	79,87	73,34	74,82	77,10	80,44
	PSNR	27,66	28,53	28,88	28,88	28,76	28,55
PCA	RMSE	73,66	78,71	71,73	78,96	72,63	75,56
	PSNR	28,59	28,42	28,97	28,30	29,00	28,73
GS1	RMSE	79,91	68,53	62,08	61,14	63,31	67,55
	PSNR	27,84	29,18	30,03	30,15	29,85	29,30
GS2	RMSE	74,27	81,90	81,49	78,27	76,86	75,70
	PSNR	28,59	27,87	27,87	28,20	28,35	28,46
GS-LS	RMSE	61,03	80,59	79,37	79,20	77,49	73,61
	PSNR	30,17	27,99	28,14	28,15	28,29	28,65
HPF	RMSE	76,29	80,67	78,67	77,51	77,22	76,87
	PSNR	26,60	25,51	26,30	27,37	27,44	27,39
UNB	RMSE	81,57	891,38	74,50	76,62	78,43	79,67
	PSNR	30,19	10,81	29,23	29,36	29,55	29,80
AWLP	RMSE	105,84	101,92	x	98,02	101,10	103,30
	PSNR	27,98	28,09	x	28,30	28,19	28,11
ATWT	RMSE	70,17	70,85	x	69,35	69,84	70,08
	PSNR	29,29	29,26	x	29,48	29,42	29,38

1.5.1.2. k-ortalama, ISODATA ve SLIC kümeleme yaklaşımları için deneysel sonuçlar

Tezin bu bölümünde, pankeskinleştirme işlemi gerçekleştirilmeden önce kümeleme tabanlı yaklaşımlar kullanılmaktadır. Kümeleme işlemi sonucunda aynı grupta bulunan pikseller detayların benzer spektral karakteristiklerine sahiptirler. Dolayısıyla aynı grupta bulunan pikseller aynı detay katsayısına sahip olmaktadır. Bir çok bölütleme algoritması bu amaç için kullanılabilir. Kümeleme algoritmalarından k-ortalama kümeleme, ISODATA ve SLIC gibi yaklaşımlar kullanılabilir. Bu kümeleme yaklaşımları görüntüyü aynı homojen spektral özelliklere sahip küçük bölgelere ayırmaktadır. Tezin bu kısmında gerçekleştirilen deneyde iki tane veri seti kullanılmıştır. Bunlar AVIRIS alıcısının Moffett ve ROSIS alıcısının Pavia University veri setleridir. Her iki görüntü için de 180×180 piksel boyutunda alt görüntü alınmıştır. Bu veri setleri yüksek frekans detayları ve karışık türde materyaller içeren yer yüzü görüntüsü içermeleri nedeniyle tercih edilmiştir. Veri setlerinin RGB görüntüleri Şekil 1.24.'de gösterilmektedir. Her iki veri setinde de şehir yolları, binalar ve yeşil alanlar bulunmaktadır.



Şekil 1.25. Veri Setleri a) AVIRIS - Moffett, b) ROSIS - Pavia University.

Performans karşılaştırma metodolojisi sentetik veri setleri oluşturularak gerçekleştirilmiştir. Hiperspektral sentetik veri seti referans görüntüsünün iki kez alt-örneklem ve interp23tap süzgeci kullanılarak üst-örneklem yapılarak Gaussian alçak geçiren süzgecinden geçirilerek oluşturulmuştur [61]. Pankromatik sentetik görüntü ise, 400-700 nm. görsel aralıkta hiperspektral bantlarının ortalaması olarak alınmıştır. Bu sentetik görüntüler pankeskinleştirme yaklaşımları için girdi olarak kullanılmış ve

elde edilen çıktı görüntüsü orijinal referans görüntü ile karşılaştırılmıştır. Blok ve kümeleme tabanlı yaklaşımlar için kullanılan parametreler deneysel analizler sonucunda belirlenmiştir. Çakışmayan blok tabanlı yaklaşımda blok boyutu 10 olarak alınmıştır. Çakışan blok yaklaşımında ise blok (kayan pencere) boyutu 25 olarak seçilmiştir. k-ortalama kümeleme için küme sayısı 26 olarak seçilmiştir. SLIC yaklaşımı optimize edilecek herhangi bir parametreye sahip değildir. Pankeskinleştirme yaklaşımlarının performansı PSNR, SAM ve geçen süre (TIME) olmak üzere Tablo 1.16.-Tablo 1.21.'de sunulmaktadır. Görsel sonuçlar AVIRIS alıcısının Moffett veri seti için Şekil 1.25.'de sunulmaktadır.

Tablo 1.16. Pankeskinleştirme performansı AVIRIS Moffett veri seti, oran = 2.

Oran = 2		PSNR	SAM	TIME
Global	IHS	26,7	0,1	0,2
	BT	26,3	0,1	0,1
	GS	27,1	0,1	0,5
	PCA	26,5	0,1	1,8
Çakışmayan blok	IHS	31,9	0,1	0,6
	BT	31,9	0,1	0,5
	GS	31,7	0,1	8,3
	PCA	30,0	0,1	4,5
Çakışan blok	IHS	30,85	0,07	122,16
	BT	30,91	0,06	108,41
	GS	30,92	0,07	985,36
	PCA	29,79	0,08	943,18
k-ortalama	IHS	31,71	0,08	1034,5
	BT	31,60	0,07	1033,5
	GS	31,72	0,08	1034,2
	PCA	29,73	0,12	1035,8
ISODATA	IHS	30,95	0,06	401,02
	BT	31,16	0,06	401,17
	GS	31,16	0,06	402,00
	PCA	30,81	0,06	402,67
SLIC	IHS	32,78	0,06	4,03
	BT	32,71	0,06	3,93
	GS	32,71	0,07	16,32
	PCA	31,71	0,07	10,30

Tablo 1.16.’deki sonuçlara bakıldığında en iyi PSNR değerini SLIC süperpiksel kümeleme yaklaşımı kullanılan pankeskinleştirme yaklaşımının verdiğini görülmektedir. Bunu ISODATA ve kayan pencere şeklinde çakışan blok yaklaşımı takip etmektedir. SAM metriği dikkate alındığında, ISODATA yaklaşımı en iyi performansı vermektedir.

Tablo 1.17. Pankeskinleştirme performansı AVIRIS Moffett veri seti, oran = 4.

Oran = 4		PSNR	SAM	TIME
Global	IHS	26,25	0,13	0,05
	BT	25,85	0,10	0,04
	GS	26,63	0,13	0,38
	PCA	26,23	0,13	1,35
Çakışmayan blok	IHS	29,14	0,10	0,47
	BT	28,98	0,10	0,40
	GS	28,88	0,10	8,13
	PCA	28,24	0,11	4,40
Çakışan blok	IHS	29,22	0,10	121,57
	BT	29,16	0,10	107,96
	GS	29,18	0,10	1013,9
	PCA	28,48	0,11	960,94
k-ortalama	IHS	28,86	0,10	922,42
	BT	28,90	0,09	922,40
	GS	28,86	0,10	925,94
	PCA	28,34	0,11	925,11
ISODATA	IHS	29,89	0,10	357,08
	BT	29,88	0,10	356,93
	GS	29,92	0,09	359,42
	PCA	29,85	0,10	358,52
SLIC	IHS	29,12	0,10	3,27
	BT	28,96	0,09	3,18
	GS	29,03	0,10	15,43
	PCA	28,81	0,10	9,13

Tablo 1.17.’deki sonuçlarda kullanılan pankeskinleştirme girdileri olan, sentetik pankromatik ve sentetik hiperspektral görüntüleri 4 oranında alt-örneklem gerçekleştirilerek oluşturulmuştur. Bu oran kullanıldığında ISODATA kümeleme

yaklaşımı, Moffett verisi için PSNR’da en iyi performansı sağlamaktadır. Bunu SLIC yaklaşımı ve çakışan blok yaklaşımı takip etmektedir. SAM metriği dikkate alındığında SLIC süperpiksel kümeleme yaklaşımı en iyi sonucu vermektedir. Ancak ISODATA yaklaşımı kullanıldığında hesaplama karmaşıklığının SLIC yaklaşımına göre çok fazla olduğu dikkati çekmektedir.

Tablo 1.18. Pankeskinleştirme performansı ROSIS Pavia veri seti, oran = 2.

Oran = 2		PSNR	SAM	TIME
Global	IHS	29,37	0,10	0,04
	BT	29,44	0,09	0,03
	GS	29,41	0,10	0,24
	PCA	30,19	0,10	0,73
Çakışmayan blok	IHS	30,15	0,09	0,33
	BT	30,00	0,09	0,27
	GS	30,12	0,09	5,21
	PCA	28,55	0,11	3,53
Çakışan blok	IHS	30,12	0,09	74,72
	BT	30,07	0,09	62,52
	GS	30,20	0,09	582,35
	PCA	29,21	0,11	454,44
k-ortalama	IHS	31,28	0,08	767,14
	BT	30,95	0,09	767,57
	GS	30,87	0,09	769,05
	PCA	24,61	0,17	768,68
ISODATA	IHS	31,71	0,08	517,60
	BT	31,60	0,09	517,69
	GS	31,63	0,09	517,52
	PCA	31,54	0,09	517,30
SLIC	IHS	30,36	0,09	3,08
	BT	30,18	0,09	3,16
	GS	30,31	0,09	10,04
	PCA	29,48	0,10	5,41

Tablo 1.18.'de ROSIS – Pavia University veri seti kullanılarak elde edilen niceliksel sonuçlar görülmektedir. ROSIS alıcısı için ISODATA yaklaşımı diğer kullanılan yaklaşımları performans bakımından geçmektedir. Ancak hesaplama karmaşıklığı oldukça yüksektir.

Tablo 1.19. Pankeskinleştirme performansı ROSIS Pavia University veri seti, oran = 4.

Oran = 4		PSNR	SAM	TIME
Global	IHS	27,66	0,12	0,04
	BT	27,40	0,13	0,03
	GS	27,81	0,12	0,24
	PCA	28,29	0,12	0,71
Çakışmayan blok	IHS	27,10	0,12	0,35
	BT	26,90	0,13	0,36
	GS	27,14	0,12	4,84
	PCA	26,32	0,14	3,41
Çakışan blok	IHS	27,71	0,12	68,48
	BT	27,44	0,13	61,32
	GS	27,88	0,12	570,57
	PCA	27,02	0,14	443,75
k-ortalama	IHS	27,36	0,13	1029,9
	BT	27,43	0,13	1030,1
	GS	27,47	0,12	1032,0
	PCA	26,63	0,14	1031,7
ISODATA	IHS	28,13	0,12	510,44
	BT	27,89	0,13	510,47
	GS	27,93	0,12	511,42
	PCA	27,89	0,12	511,33
SLIC	IHS	26,74	0,12	2,58
	BT	26,61	0,13	2,55
	GS	26,72	0,12	9,74
	PCA	26,21	0,13	5,10

Tablo 1.19.'de sentetik veri setleri oluşturulurken 4 oranında alt-örneklem kullanılmaktadır. SAM metriği hemen hemen bütün yaklaşımlarda aynı performansı verirken, PSNR bakımından en iyi sonucu ISODATA vermektedir.

Tablo 1.20. Pankeskinleştirme Performansı ROSIS Pavia University veri seti, oran = 2.

Oran = 2		PSNR	SAM	TIME
Global	IHS	31,90	0,09	0,05
	BT	32,10	0,09	0,03
	GS	32,07	0,09	0,25
	PCA	31,70	0,09	0,93
Çakışmayan blok	IHS	31,22	0,09	0,35
	BT	31,36	0,09	0,40
	GS	31,21	0,09	5,12
	PCA	29,23	0,11	3,49
Çakışan blok	IHS	31,73	0,09	68,49
	BT	31,93	0,09	60,52
	GS	31,86	0,09	563,93
	PCA	29,84	0,11	448,86
k-ortalama	IHS	31,44	0,09	974,32
	BT	31,65	0,09	974,28
	GS	30,59	0,10	976,49
	PCA	26,25	0,15	975,97
ISODATA	IHS	31,96	0,09	468,42
	BT	32,15	0,09	468,49
	GS	32,21	0,09	469,34
	PCA	32,21	0,09	469,21
SLIC	IHS	30,93	0,09	3,14
	BT	31,05	0,09	3,22
	GS	31,06	0,09	10,05
	PCA	30,27	0,10	5,45

Tablo 1.21. Pankeskinleştirme Performansı ROSIS Pavia veri seti, oran = 4.

Oran = 4		PSNR	SAM	TIME
Global	IHS	28,42	0,13	0,04
	BT	28,65	0,13	0,03
	GS	28,56	0,13	0,31
	PCA	28,33	0,13	0,83
Çakışmayan blok	IHS	27,26	0,13	0,47
	BT	27,41	0,13	0,36
	GS	27,23	0,13	6,00
	PCA	26,52	0,14	4,01
Çakışan blok	IHS	28,03	0,13	67,98
	BT	28,26	0,13	60,89
	GS	28,12	0,13	557,27
	PCA	27,08	0,15	441,53
k-ortalama	IHS	27,75	0,13	1004,87
	BT	28,00	0,13	1004,7
	GS	27,21	0,14	1006,8
	PCA	25,87	0,16	1007,13
ISODATA	IHS	28,29	0,13	293,97
	BT	28,44	0,13	294,00
	GS	28,57	0,12	294,96
	PCA	28,52	0,12	294,77
SLIC	IHS	26,81	0,13	2,59
	BT	26,92	0,13	2,49
	GS	26,88	0,13	9,62
	PCA	26,46	0,13	5,00

IKONOS_SRF_PAN bantları kullanılarak oluşturulan sentetik pankromatik görüntü ile elde edilen sonuçlar aşağıdaki Tablo 1.20.'de verilmektedir. Sadece ROSIS Pavia University verisi için gerçekleştirilmiştir. Çünkü, AVIRIS Moffett verisi için hangi

bantların atıldığı bilinmediğinden dolayı AVIRIS Moffett verisi için bu deney gerçekleştirilememiştir.


Tablo 1.20'deki sonuçlar yakından incelendiğinde önceki deneylerle paralellik gösterecek şekilde ISODATA yaklaşımının en iyi sonucu verdiği ve diğer yaklaşımların ise performans bakımından birbirleriyle yarıştığı görülmektedir. SAM metriğine göre, k-ortalama kümeleme dışında hemen hemen bütün yaklaşımların aynı performansa sahip olduğu dikkati çekmektedir

Tablo 1.21'deki sonuçlara yakından bakıldığında, ISODATA ve global yaklaşımın en iyi pankeskinleştirme sonucunu verdikleri görülmektedir. SLIC yaklaşımının alt-örneklem oranı 2 olduğundaki ISODATA ile olan performans karşılaştırmasının, oran 4 olduğunda kötüleştiği görülmektedir.

Tablo 1.20. ve Tablo 1.21.'de sentetik pankromatik görüntü, IKONOS alıcısının SRF değerleri dikkate alınarak sadece hiperspektral görüntü ile kesişen bantların ortalaması alınarak oluşturulmuştur. IKONOS alıcısının SRF değerleri kullanılarak, alt-örneklem oranının 2 ve 4 olduğunda elde edilen sayısal sonuçlar bütün bantların ortalaması şeklinde alınan Tablo 1.16. - 1.19.'ya göre daha kötü pankeskinleştirme performansı sunmaktadır. Neredeyse tablolardaki bütün durumlarda kümeleme ve blok tabanlı yaklaşımlar global yaklaşımlarla karşılaştırıldığında, daha iyi pankeskinleştirme sonucu vermektedir. Bu durum, sahnenin lokal ya da uzamsal bilgisinin önemini vurgulamaktadır. Dikkatli bir parametre optimizasyonu yapıldığında sonuçlar daha da iyileştirilebilir.

Tezin bu bölümünde standart CS pankeskinleştirme yaklaşımları için, sahnenin uzamsal ve lokal bilgisi de dikkate alınarak pankeskinleştirme performansının artırıldığı deneysel sonuçlarla gösterilmiştir. Bu amaç için, blok tabanlı ve kümeleme tabanlı yaklaşımlar kullanılmıştır.

Lokal ve uzamsal bilginin kullanılması, iyileştirilmiş pankeskinleştirmeye sonuçlanmıştır. Gelecek çalışmalar içerisinde bu lokal bilginin pankeskinleştirme yaklaşımlarına nasıl eklenebileceği üzerinde çalışmalar gerçekleştirilebilir. Şekil 1.26. dikkatlice incelendiğinde Tablo sonuçları ile orantılı olduğu görülebilmektedir. BT yaklaşımı en kötü pankeskinleştirme görsel sonucunu vermektedir.



Şekil 1.26. AVIRIS Moffett veri seti için görsel sonuçlar a) IHS b) IHS_ çakışmayan c) IHS_ çakışan d) IHS_k-ortalama e) IHS_ISODATA f) IHS_SLIC g) BT h) BT_ çakışmayan i) BT_ çakışan j) BT_k- ortalama k) BT_ISODATA l) BT_SLIC m) GS n) GS_ çakışmayan o) GS_ çakışan p) GS_k- ortalama r) GS_ISODATA s) GS_SLIC t) PCA u) PCA_ çakışmayan v) PCA_ çakışan w) PCA_k- ortalama x) PCA_ISODATA y) PCA_SLIC.

1.5.2. Bayesian, Hysure temelli PAN-HS pankeskinleştirme yaklaşımlarının başarımları ve deneysel sonuçlar

Tezin bu bölümünde, AVIRIS alıcısının Indian Pines, Moffett ve Cuprite veri setleri için PAN-HS görüntüleri üzerine yapılan hiperspektral pankeskinleştirme deneyi ayrıntılı bir şekilde anlatılmıştır. Pankeskinleştirme yaklaşımları olarak CNMF, Bayesian Naive, Bayesian Sparse ve HySure teknikleri kullanılmıştır.

Tablo 1.22’de AVIRIS alıcısının Indian Pines, Moffett ve Cuprite veri setlerinden 120×120 piksel büyüklüğünde bir alt görüntü olarak alınan veriler üzerinde yapılan test sonuçları görülmektedir;

Tablo 1.22. AVIRIS Indian Pines HS-PAN veri kaynaştırma sonuçları.

Indian Pines (HS-PAN)	RMSE	CC	SAM	ERGAS
CNMF	137,59	0,74	3,66	4,47
Bayesian Naive	86,04	0,84	2,49	4,10
Bayesian Sparse	72,39	0,86	2,08	4,04
HySure	103,08	0,82	2,77	4,21

Tablo 1.23. AVIRIS Moffett HS-PAN veri kaynaştırma sonuçları.


Moffett Field (HS-PAN)	RMSE	CC	SAM	ERGAS
CNMF	314,54	0,95	9,43	5,43
Bayesian Naive	220,03	0,97	7,13	3,78
Bayesian Sparse	199,80	0,98	6,61	3,42
HySure	254,20	0,97	7,53	4,35

Tablo 1.24. AVIRIS Cuprite HS-PAN veri kaynaştırma sonuçları.

Cuprite (HS-PAN)	RMSE	CC	SAM	ERGAS
CNMF	129,14	0,92	1,25	5,96
Bayesian Naive	86,91	0,96	0,86	4,81
Bayesian Sparse	82,60	0,96	0,83	4,67
HySure	102,69	0,95	1,00	257,64

Tablo 1.22. ve Tablo 1.24. yakından incelendiğinde, Bayesian Sparse yaklaşımının RMSE, SAM ve ERGAS için en küçük sayısal değerleri verdiği için dolayı tablodaki diğer yaklaşımlara göre daha iyi performans sunmaktadır.

Şekil 1.27. incelendiğinde Tablo 1.22. ve Tablo 1.24.'de görülen sonuçlar ile uyumlu olduğu görülmektedir. Moffett Field verisi için Bayesian Sparse ve HySure yaklaşımlarının en iyi görsel sonucu verdiği görülmektedir. Benzer şekilde, Indian Pines ve Cuprite veri setleri için de aynı durum söz konusudur. Yine, Bayesian Naive, Bayesian Sparse ve HySure yaklaşımları en iyi görsel sonucu vermektedir.



Şekil 1.27. AVIRIS sensörü HS-PAN veri kaynaştırması görsel sonuçları.

1.6. Vargılar

Bu bölümde, pankeskinleştirme yaklaşımları anlatıldıktan sonra, pankeskinleştirme yaklaşımlarının PAN-MS ve PAN-HS verileri üzerindeki başarımların analizi, yapılan ayrıntılı deneysel sonuçlar ile gösterilmiştir. PAN-MS görüntüleri için RASAT ve GÖKTÜRK-2 görüntüleri kullanılırken, PAN-HS görüntüleri için ise, AVIRIS alıcısının Indian Pines, Moffett ve Cuprite veri setleri kullanılmıştır.

2. MULTİSPEKTRAL – HİPERSPEKTRAL (MS –HS) KAYNAŞTIRMA TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

Spektral karışım giderimi, hiperspetral veriyi kullanarak spektral imzalar ve onlara karşılık gelen bolluk değeri oranlarını en iyi şekilde tahminlemeye çalışan önemli bir tekniktir [1]. Hiperspektral görüntülerle birlikte multispektral görüntülerin uzamsal çözünürlüğü artırılmış hiperspektral görüntü elde etmek amacıyla kaynaştırılması son yıllarda önemli bir çalışma alanı olmuştur.

Tezin bu bölümünde hiperspektral ve multispektral görüntülerin veri kaynaştırması üzerinde çalışılmıştır. Bu bölümde, en son ve en yeni yaklaşımları içeren düzenleyici terimler CNMF [82] üzerine eklenerek MS-HS veri kaynaştırması gerçekleştirilmiştir.

HS-MS veri kaynaştırması aşağıdaki nedenlerden dolayı çok daha zordur:

1. Kötü konumlanmış problemdir ve tahminlenmesi gereken değişkenlerin sayısı çok fazladır.
2. Çok fazla boyutlarla çalışıldığı için hesaplama karmaşıklığı yüksektir.
3. Hiperspektral görüntünün spektral aralığı multispektral görüntüden büyüktür. Dolayısıyla, hiperspektral görüntünün birçok bandı multispektral görüntünün herhangi bir bandı tarafından içerilmez.

Negatif Olmayan Matris Faktörizasyonu (NMF) için Çarpımsal İteratif Güncelleme Algoritması 1.4.2. bölümünde ayrıntılı bir şekilde anlatılmıştır. Özetleyecek olursak, Euclidean distance yerine Frobenous norm kullanılarak NMF için maliyet fonksiyonu;

$$C(W,H)=\frac{1}{2} \|X-WH\|_F^2 \quad (2.1)$$

olmak üzere çarpımsal güncelleme kuralı aşağıdaki şekilde tanımlanmaktadır;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.2)$$

$$H \leftarrow H \cdot (W^T X) ./ (W^T W H) \quad (2.3)$$

NMF, veriyi iki tane sıfırdan farklı matrise parçaladığından dolayı, sıfırdan farklı olma kısıtını doğal olarak sağlamaktadır. Bu maliyet fonksiyonunun konveks olmaması nedeniyle, global optimal çözümü elde etmek zordur. Bununla birlikte maliyet fonksiyonunun konveks olmaması NMF'nin çözümünde yerel minimum değerlerine karışım giderimi süresince sık sık rastlanmasına neden olmaktadır. Yani, performansı artırmak için daha çok kısıtlama eklenmelidir. Farklı regülarizasyon kısıtlarının eklendiği çalışmalar tez süresince incelenmektedir.

Son zamanlarda geliştirilen, bir çok seyrek (sparse) NMF algoritmaları, hiperspektral karışım giderimi için çok iyi performans elde etmişlerdir. Çünkü, bu yaklaşımlar saf piksellerin olmamasından kaynaklanan zorluğu aşmışlardır. Ayrıca bu yaklaşımlar verinin seyrek karakteristik bilgisini de kullanmışlardır. Fakat, çoğu var olan seyrek NMF algoritmaları hiperspektral karışım giderimi için sadece Euclidean yapısını kullanmışlardır.

2.1. Çeşitli Kısıtlamaları İçeren NMF Yaklaşımları

Son yıllarda bir çok NMF algoritması tanımlanmıştır. Aşağıda son yıllardaki NMF algoritmalarına örnekler verilmektedir. Tezin bu bölümünde, aşağıdaki NMF yaklaşımlarının birkaçı, CNMF [82] veri kaynaştırması yaklaşımına eklenerek uzamsal çözünürlüğü artırılmış hiperspektral görüntü elde edilmiştir:

- Seyreklik Kısıtlı L_1 -NMF (L_1 -NMF)
- Seyreklik Kısıtlı $L_{1/2}$ -NMF
- Minimum Volume Constrained NMF (MVCNMF)
- Piecewise Smoothness NMF with Sparsity Constrained
- Structure Constrained Sparse NMF (CSNMF)
- Graph Regularized $L_{1/2}$ -NMF (GLNMF)
- Abundance Separation and Smoothness Constrained NMF (ASSNMF)
- Weighted NMF (WNMF)
- Dual Graph Regularized Sparse NMF (DGNMF)
- Hypergraph Regularized $L_{1/2}$ -NMF (HG $L_{1/2}$ -NMF)
- Data Guided Constrained NMF (DGCNMF)

- Multilayer NMF (MLNMF)
- Local Neighborhood Weights Regularized NMF (W-NMF)
- Structured Sparse NMF (SS-NMF)
- Endmember Dissimilarity Constrained NMF (EDC-NMF)
- Substance Dependence Constrained Sparse NMF (SDSMF)

Spektral özellikleri kullanan NMF iyi bir matris ayrıştırma algoritması olmasına rağmen, verinin karakteristik özelliklerini koruma ve artırma konusunda yetersiz kalmaktadır. Bu nedenle, NMF içerisine ek yapısal kısıtlamalar getirilmelidir.

Tezin bu kısmında, veri kaynaştırma işlemi için yukarıdaki NMF kısıtlamaları CNMF [82]'ye eklenerek, CNMF'nin veri kaynaştırma başarımının artırılması hedeflenmektedir. Buna göre, aşağıdaki bölümde önce ilgili NMF yaklaşımları anlatılmakta, daha sonra bu NMF kısıtı CNMF'ye eklenerek elde edilen deneysel sonuçlar tablo ya da görsel sonuçlar şeklinde sunulmaktadır.

2.1.1. Seyreklik kısıtlı L_1 -NMF (Sparsity constrained L_1 -NMF)

Çeşitli seyreklik çeren karışım giderimi yaklaşımları sunulmuştur [99]. Regülerizasyon terimli metodlar, genel olarak son elemanların bolluk oranları üzerine seyreklik kısıtını tanımlamak üzere kullanılmaktadır. L_0 düzenleyicisi bolluk oranlarını içeren matriste sıfır elemanlarının olmasını gerektirir. Polinomsal olmayan kötü konumlanmış (NP-hard) optimizasyon problemidir ve pratikte çözülemez. L_2 düzenleyicisi, düzgün fakat seyreklik belirtmeyen sonuçlar üretmektedir. L_1 düzenleyicisi ise, bolluk değeri matrisinin seyrekliğini belirleyen en çok popüler olarak kullanılan düzenleyicidir.

L_1 düzenleyicisi seyrek çözüm üretmektedir. L_q ($0 < q < 1$) düzenleyicisi, L_1 düzenleyicisine göre daha seyrek çözüm vermektedir. Ayrıca L_1 düzenleyicisi, toplam toplanabilirlik kısıtını (full additivity constraint) sağlayamamaktadır. Bu nedenle, toplanabilirlik kısıtı ile birlikte seyrek çözüm elde etmek için farklı düzenleyicilerin bulunması NMF'ye dayalı karışım giderimi yaklaşımlarının temel problemidir. L_1 -NMF için çarpımsal güncelleme kuralı Denklem (2.4)'teki gibi hesaplanmaktadır;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.4)$$

$$H \leftarrow H .* (W^T X) ./ (W^T W H + \lambda) \quad (2.5)$$

L_1 - düzenleyicisine dayalı MS-HS veri kaynaştırması AVIRIS Indian Pines veri seti üzerinde gerçekleştirilmiş ve elde edilen sayısal sonuçlar CNMF sonuçlarıyla beraber aşağıdaki Tablo 2.1.'de verilmiştir.

Tablo 2.1. L_1 -CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.

value		PSNR	
λ_{hyper}	λ_{multi}	CNMF	L_1 -CNMF
58,5807	4,1637	40,2868	30,1776

Tablo 2.1.'deki λ_{hyper} ve λ_{multi} parametre değerleri (2.12) formüü kullanılarak elde edilmiştir. Tablo 2.1. incelendiğinde L_1 -NMF kısıtının CNMF'ye eklenmesinin iyi bir performans ile sonuçlanmadığı görülmüştür.

2.1.2. Seyreklik kısıtlı $L_{1/2}$ -NMF (Sparsity constrained $L_{1/2}$ -NMF)

$L_{1/2}$ -NMF modeli, karışım giderimi yaklaşımına iyi bir performans sağlamaktadır. $L_{1/2}$ -düzenleyicisi, L_1 -düzenleyicisi ile karşılaştırıldığında daha iyi bir çözüm sunmaktadır. Fakat, diğer NMF yaklaşımlarıyla karşılaştırıldığında kararsızdır ve gürültüye maruz kalabilir [100].

$L_{1/2}$ -NMF seyreklik kısıtlı maliyet fonksiyonu şu şekilde tanımlanmaktadır;

$$C(W,H) = \frac{1}{2} \|X-WH\|_F^2 + \lambda f(S) \quad (2.6)$$

$L_{1/2}$ -düzenleyicisi, L_q ($0 < q < 1$) düzenleyicisine göre en iyi seyrek çözümü sunmaktadır. $L_{1/2}$ - düzenleyicisi sadece seyrek çözüm değil, aynı zamanda hesaplama karmaşıklığı daha az olan bir çözüm sunmaktadır. $L_{1/2}$ -NMF modeli karışım giderimi problemi için aşağıdaki şekilde tanımlanmaktadır;

$$C(W,H) = \frac{1}{2} \|X-WH\|_F^2 + \lambda \|S\|_{\frac{1}{2}} \quad (2.7)$$

buradaki S normu şu şekilde tanımlanmaktadır;

$$\|S\|_{\frac{1}{2}} = \sum_{k,n=1}^{K,N} s_n(k)^{\frac{1}{2}} \quad (2.8)$$

burada $s_n(k)$ değeri k.ıncı son eleman için bolluk miktarını belirtmektedir. $L_{1/2}$ -NMF için tekrar ölçeklenmiş Gradient Descent Algoritması ile çarpımsal güncelleme kuralı aşağıdaki gibi hesaplanmaktadır;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.9)$$

$$H \leftarrow H .* (W^T X) ./ \left(W^T W H + \frac{\lambda}{2} H^2 \right) \quad (2.10)$$

Güncelleme kuralının yakınsaklığını garantilemek için objektif fonksiyonun monoton azalan olduğu gösterilebilmektedir [100]. $L_{1/2}$ -NMF bir konveks optimizasyon problemi olmadığından dolayı çözüm olarak lokal minimum değerlerini elde etmektedir.

Son elemanların bolluk değerlerinin toplam toplanabilirlik kısıtı, optimizasyonun çözüm uzayını azaltmaktadır. Bu toplam toplanabilirlik kısıtı aşağıdaki şekilde gerçekleştirilmektedir;

$$X_f = \begin{bmatrix} X \\ \delta 1_N^T \end{bmatrix} \quad \text{ve} \quad W_f = \begin{bmatrix} W \\ \delta 1_K^T \end{bmatrix} \quad (2.11)$$

Burada karışım giderimi uygulanan MS/HS'ye karşılık gelen X görüntüsünün en alt satırına birlerden oluşan bir vektör eklenmektedir. Ayrıca bu X görüntüsüne karşılık gelen son eleman matrisi W'nun en alt satırına yine birlerden oluşan bir vektör eklenmektedir. Böylece, karışım giderimi uygulanan MS/HS görüntüsünün bolluk oranlarının toplamı bire eşitlenmektedir [101].

Son elemanların sayısının tahminlenmesi karışım giderimi süreci için büyük bir önem arz etmektedir. Bunun için bu tez kapsamında son eleman tahmini için En Küçük Hata ile Hiperspektral İşaret Altuzay Belirleme (Hyperspectral Signal Subspace Identification by Minimum Error - HySime) [102] algoritması

kullanılmıştır. $L_{1/2}$ -NMF algoritmasının sözde kodu aşağıdaki şekilde ifade edilebilmektedir;

Tablo 2.2. $L_{1/2}$ -NMF Algoritması'nın sözde kodu

Algoritma 2. HS verisi (X) karışım giderimi için $L_{1/2}$ -NMF
<p>Adım 1: HySime Algoritmasını kullanarak K son eleman sayısını belirle</p> <p>Adım 2: λ parametresini seyreklik kriterini kullanarak X için hesapla</p> <p>Adım 3: W ve H değerlerine rastgele [0,1] aralığından ilk değer ataması yap. H'nin bütün kolonlarını birim norma ölçekle</p> <p>Adım 4: Aşağıdaki adımları maksimum iterasyon sayısı ya da aşağıdaki şart sağlanana kadar yap $\ C_{new} - C_{old}\ < \varepsilon$</p> <p>X ve W'yu X_f ve W_f 'yı içerecek şekilde güncelle</p> <p>$C_{old} = C(W_f, H)$ hesapla</p> <p>W ve H'ı (7.20) ve (7.21)'ye göre güncelle</p> <p>$C_{new} = C(W_f, H)$ hesapla</p>

λ parametresinin değeri materyallerin bolluk değerlerinin seyrekliğine bağlıdır. Bu bolluk değerleri deney öncesinde elde edilemediğinden λ parametresi için 'Seyreklik Kriteri' adında bir tahminleyici kullanılmaktadır. Seyreklik kriteri aşağıdaki şekilde tanımlanmaktadır [103];

$$\lambda = \frac{1}{\sqrt{L}} \sum_1^{\sqrt{N}} \frac{\sqrt{N} - \|X_1\|_1 / \|X_1\|_2}{\sqrt{N} - 1} \quad (2.12)$$

burada $\|\cdot\|_1$ L_1 -normu ve $\|\cdot\|_2$ L_2 -normudur. Sunulan NMF algoritması $0 < q < 1$ için L_q -NMF'ye geliştirilebilmektedir. Özel olarak L_q -NMF modeli karışım giderimi için aşağıdaki şekilde tanımlanmaktadır;

$$C(W,H) = \frac{1}{2} \|X - WH\|_2^2 + \lambda \|S\|_q \quad (2.13)$$

Buradaki norm değeri aşağıdaki şekilde tanımlanmaktadır;

$$\|S\|_q = \sum_{k,n=1}^{K,N} s_n(k)^q \quad (2.14)$$


Buradaki $s_n(k)$, k.ıncı son eleman için bolluk değerlerini ifade etmektedir. Bu durumda çarpımsal güncelleme kuralı aşağıdaki gibi tanımlanmaktadır;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.15)$$

$$H \leftarrow H .* (W^T X) ./ \left(W^T W H + \frac{\lambda}{2} H^{q-1} \right) \quad (2.16)$$

$L_q (0 < q < 1)$ düzenleyicisi, L_1 'e göre daha seyrek çözüme karşılık gelmektedir. Buradaki q değerinin optimal değerini tanımlamak hala tartışılan bir problemdir. $q = \frac{1}{2}$ olarak almak iyi bir düzenleyici seçeneğidir.

Geometrik Yorumuna baktığımızda $L_{1/2}$ -düzenleyicisi geometrik olarak minimum hacim metoduyla yakından ilişkilidir.



Şekil 2.1. $L_{1/2}$ - düzenleyicisinin geometrik yorumu [100].

Kırmızı, yeşil ve mavi üçgenlerin hacim sıralaması aşağıdaki gibidir;

$$V_G > V_B > V_R \quad (2.17)$$

$l_{1/2}$ norm tanımı yerine yazılacak olursa,

$$\|S\|_{\frac{1}{2}} = \frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K s_n(k)^{\frac{1}{2}} \quad (2.18)$$

aşağıdaki eşitsizlik elde edilmektedir. Bu ise, minimum hacime karşılık gelmektedir;

$$\|S\|_{\frac{1}{2}}^{(V_R)} < \|S\|_{\frac{1}{2}}^{(V_B)} < \|S\|_{\frac{1}{2}}^{(V_G)} \quad (2.19)$$

$L_{1/2}$ -düzenleyicisi, CNMF yaklaşımı üzerine bir kısıtlama olarak getirilmiş, böylece MS-HS veri kaynaştırması AVIRIS Indian Pines veri seti üzerinde gerçekleştirilmiştir. Elde edilen sayısal sonuçlar CNMF sonuçlarıyla beraber aşağıdaki Tablo 2.3.'de sunulmaktadır.

Tablo 2.3. $L_{1/2}$ -CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri

value		PSNR	
λ_{hyper}	λ_{multi}	CNMF	$L_{1/2}$ -CNMF
58,5807	4,1637	40,2868	41,1776
7,1313	23,7692	40,309	41,0861
72,8722	5,1440	40,3269	41,1692

Tablo 2.3. sonuçları incelendiğinde $L_{1/2}$ -CNMF yaklaşımının, CNMF yaklaşımını PSNR değeri bakımından geçtiği görülmektedir.

2.1.3. Graf düzenleyicili NMF (Graph regularized NMF - GLNMF)

GLNMF yaklaşımında manifold düzenleyicisi, seyreklik kısıtı ile NMF'ye eklenmektedir. Hiperspektral karışım giderimi için, manifold öğrenmenin avantajlarından ve seyrek NMF kullanılarak 'graph regularized NMF (GLNMF)' adında yeni bir yaklaşım önerilmiştir. Bu yaklaşım hiperspektral verinin iç manifold yapısını kullanmaktadır. GLNMF, hiperspektral verinin geometrik yapısını elde etmek için seyreklik kısıtı ve seyreklik düzenleyicisini birleştirmektedir. Bu nedenle, GLNMF iki adımdan oluşan bir yaklaşımdır. Bunlar; seyreklik kısıtı ve graf düzenleyicisi adımlarıdır. $L_{1/2}$ -düzenleyicisi zaten yapısı itibariyle materyallerin oranlarının seyreklik kısıtını sağlamaktadır. İkinci adım olarak karışım giderimi için, lokal yapısal bilgiyi modellemek amacıyla en yakın komşuluk grafi oluşturulmaktadır. Sonuç olarak graf düzenleyicisi düzgünleştirme operatörü olarak da görev yapmaktadır. Eğer x_i ve x_j gibi iki pikselin spektral imzaları birbirine çok yakınsa, bunlara karşılık gelen bolluk oranları s_i ve s_j 'de birbirine çok yakındır. Bu kabul manifold varsayımı olarak bilinmektedir [104];

$$X_n \sim A s_n \quad (2.20)$$

Isı çekirdeği (heat kernel) W_{ij} aşağıdaki gibi tanımlanmaktadır;

$$W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma}} \quad (2.21)$$

GLNMF aşağıdaki maliyet fonksiyonunun minimizasyonu ile ilgilenmektedir;

$$\frac{1}{2} \sum_{i,j=1}^N \|h_i - h_j\|^2 \widetilde{W}_{ij} = \sum_{i=1}^N h_i^T h_i D_{ii} - \sum_{i,j=1}^N h_i^T h_j \widetilde{W}_{ij} \quad (2.22)$$

$$= \text{Tr}(HDH^T) - \text{Tr}(H\widetilde{W}H^T) \quad (2.23)$$

$$= \text{Tr}(H\widetilde{L}H^T) \quad (2.24)$$

Burada,

$$\widetilde{W}_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma}} \quad (2.25)$$

ısı çekirdeği, $\widetilde{L} = D - \widetilde{W}$ Laplacian operatörü ve D ise diagonal matristir. Burada $D_{ii} = \sum_j \widetilde{W}_{ij}$. Maliyet fonksiyonu ise,

$$C(W, H) = \frac{1}{2} \|X - WH\|_2^2 + \lambda \text{Tr}(H\widetilde{L}H^T) \quad (2.26)$$

şeklini almaktadır. λ parametresi genel olarak veri setinin seyrekliğine bağlı olarak en çok kullanılan seyreklik kriterine göre Denklem (2.12)'deki gibi belirlenmektedir. Çünkü, bolluk oranları karışım giderimi öncesinde belirli değildir.

Tezin bu bölümünde, MS-HS görüntüleri için veri kaynaştırması GLNMF'ye dayalı kısıtlı optimizasyon eklenmiş CNMF ile gerçekleştirilmiştir. Böylece, GLCNMF kodu elde edilmiştir. Diğer bir ifade ile, sunulan yaklaşım hiperspektral verisi için son eleman çıkartımı ile başlamaktadır. Bu son elemanlar mutlispektral uzayına dönüştürülmektedir. GLCNMF kullanılarak bolluk oranları hesaplanmakta, daha sonra bu değerler tekrar hiperspektral uzayına son elemanları çıkartmak için verilmektedir. Ve böylece yaklaşım hiperspektral ve multispektral görüntüleri için son elemanları ve bunlara karşılık gelen bolluk oranlarını iteratif bir şekilde

hesaplanmaktadır. GLCNMF için iteratif güncelleme kuralları aşağıdaki denklemlerle ifade edilmektedir [104];

$$W_h \leftarrow W_h \cdot * (XH_h^T) ./ (W_h H_h H_h^T) \quad (2.27)$$

$$H_h \leftarrow H_h \cdot * (W_h^T X + \mu H_h \widetilde{W}) ./ \left(W_h^T W_h H_h + \frac{\lambda}{2} H_h^2 + \mu H_h D \right) \quad (2.28)$$

$$W_m \leftarrow W_m \cdot * (YH_m^T) ./ (W_m H_m H_m^T) \quad (2.29)$$

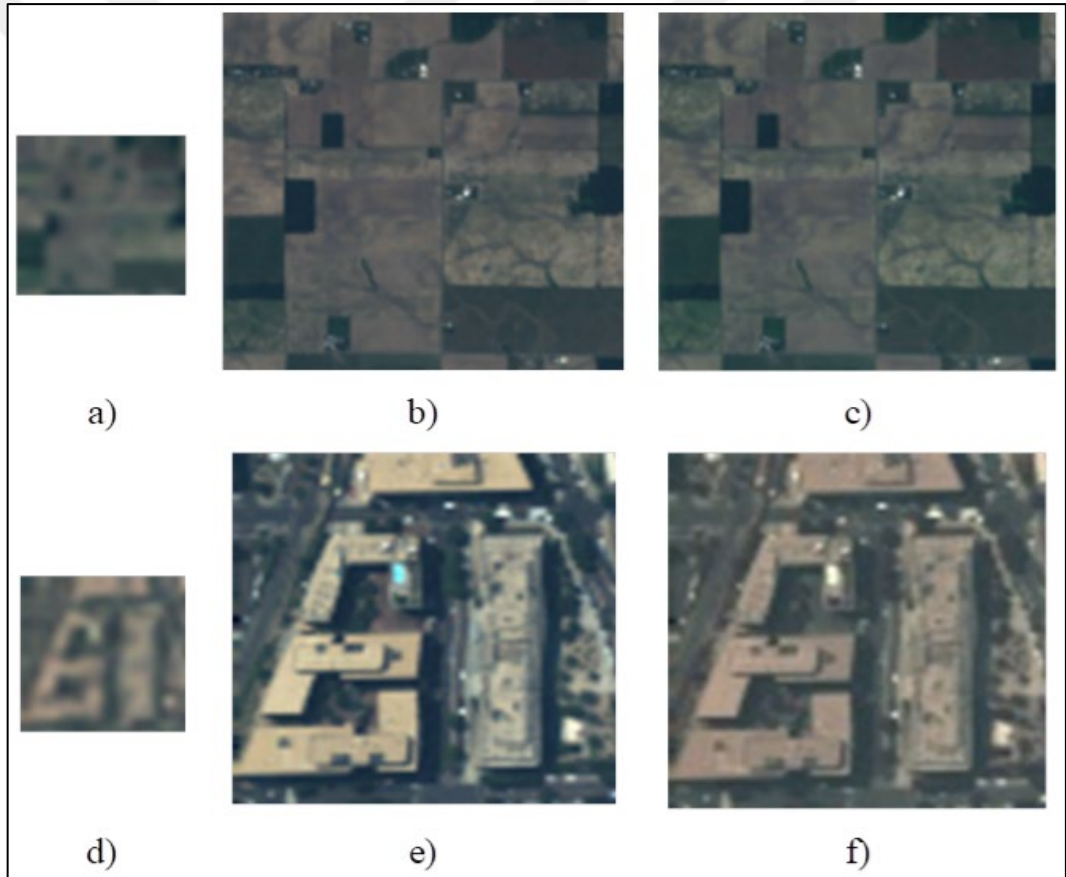
$$H_m \leftarrow H_m \cdot * (W_m^T Y + \mu H_m \widetilde{W}) ./ \left(W_m^T W_m H_m + \frac{\lambda}{2} H_m^2 + \mu H_m D \right) \quad (2.30)$$

Çarpımsal güncelleme kuralında (Multiplicative Update Rule - MUR) H^2 teriminde yakınsaklığı garantilemek için 10^{-4} 'den büyük olan değerlerde kısıtlama şartı $\frac{\lambda}{2} H^2$ alınmakta, diğer durumlarda ise, kısıtlama şartı alınmamaktadır.

Tezin bu kısmında, ayrıntılı deneysel bir çalışma iki farklı veri seti kullanılarak gerçekleştirilmiştir. İlk veri seti AVIRIS alıcısından elde edilen Indian Pines verisidir ve 120×120 piksel büyüklüğünde alt görüntü alınmıştır. İkinci veri seti ise, HYDICE alıcısından alınan Washington D.C. Mall veri setidir. 80×80 piksel büyüklüğünde olan alt görüntü kullanılmıştır. Hiperspektral ve multispektral görüntüleri [82]'de olduğu gibi Wald's protokolü ve algılayıcı karakteristikleri kullanılarak veri setlerinden elde edilmiştir. Indian Pines veri seti için, uzamsal çözünürlük oranı 6, DC Mall veri seti için ise, uzamsal çözünürlük oranı 4 olarak belirlenmiştir. Veri setlerinin RGB görüntüleri ile Wald's protokolü kullanılarak elde edilen hiperspektral ve multispektral görüntüleri Şekil 2.3.'de sunulmaktadır.

Hiperspektral ve multispektral görüntüleri GLCNMF veri kaynaştırma yaklaşımına girdi olarak verilmekte, elde edilen veri kaynaştırma görüntüsü performans değerlendirmesi için orijinal görüntü ile karşılaştırılmıştır. Bu çalışmada, sunulan yaklaşımın performansı CNMF veri kaynaştırma yaklaşımıyla karşılaştırılmıştır. Her iki yaklaşımın öncesinde, HySime yaklaşımı kullanılarak hiperspektral görüntünün veri boyutluluğuna karar verilmiştir. Her iki yaklaşımda, son eleman çıkarımı için VCA kullanılmıştır. VCA'nın her yeni çalıştırılmasında son elemanlar

değişmektedir. Bu nedenle, adil bir karşılaştırma yapmak adına VCA her bir senaryo için bir kez çalıştırılmış ve aynı VCA sonucu her iki CNMF ve GLCNMF'ye dayalı veri kaynaştırma yaklaşımları için girdi olarak kullanılmıştır. CNMF yaklaşımı bir parametreye sahip değildir. Fakat, λ ve μ parametreleri sunulan yaklaşım için büyük bir önem arz etmektedir. μ parametresi basitlik için 0.1 olarak alınmıştır. Fakat, deneysel analiz sonucunda λ parametresinin Denklem (2.12)'deki gibi alınması optimal bir performans sağlamamaktadır. Bundan dolayı, [105]'de yapıldığı gibi, $[\lambda_c/10, 10\lambda_c]$ aralığında lineer bir araştırma yapılarak λ parametresi belirlenmiştir. Bu λ parametresi seçimi Indian Pines veri seti için $\lambda_h = 135,7547$ ve $\lambda_m = 23,7692$ olarak belirlenmiştir. Aynı parametre DC Mall veri seti için de kullanılmıştır.




Şekil 2.2. Veri setlerinin RGB görüntüleri, a) AVIRIS Indian Pines-HS görüntüsü, b) AVIRIS Indian Pines-MS görüntüsü, c) AVIRIS Indian Pines-orijinal görüntü, d) HYDICE Washington, D.C-HS görüntüsü, e) HYDICE Washington, D.C-MS görüntüsü, f) HYDICE Washington, D.C-orijinal görüntü.

Her iki veri seti için PSNR değerleri Tablo 2.4.'de gösterilmektedir. Sunulan GLCNMF'ye dayalı yaklaşımın CNMF'ye göre daha iyi performans sağladığı görülmektedir.

Tablo 2.4. GLCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.

	PSNR	
	CNMF	Proposed
AVIRIS Indian Pines	40,2589	40,6024
HYDICE D.C. Mall	30,7707	31,7206




Şekil 2.3. Veri kaynaştırma sonucunun RGB görüntüsü, (a) Indian Pines - CNMF, (b) Indian Pines – sunulan yaklaşım, (c) DC Mall – CNMF, (d) DC Mall – sunulan yaklaşım.

Bu çalışmada, MS-HS görüntüleri için veri kaynaştırması CNMF çerçevesi altında, GLCNMF yaklaşımı olarak önerilmiştir. Önerilen yöntem, karışım giderimi için $L_{1/2}$ ve manifold düzenleyicilerini kullanmaktadır. Önerilen yöntem iki veri kümesi için değerlendirilmiş ve performans değerlendirmesi için CNMF yaklaşımı ile karşılaştırılmıştır. Önerilen yaklaşım, CNMF veri kaynaştırma yaklaşımını performans bakımından geçmektedir.

2.1.4. Çok katmanlı NMF (Multilayer NMF - MLNMF)

MLNMF, çözüm uzayını azaltmak için sunulmuştur. Hiperspektral görüntü, $X = AS$ şeklinde son eleman ve bolluk haritalarına ayrılmaktadır. Her yeni iterasyonda bolluk haritalarını tekrar parçalamakta, en sonki katmanda ise, her katman sonucunda elde ettiği son eleman değerlerini çarpmakta, sonucu son eleman değeri olarak almaktadır. Son katmandaki bolluk değeri ise, sonuç bolluk değeri olarak alınmaktadır. MLNMF yaklaşımının adımları aşağıdaki Şekil 2.4.'de sunulmaktadır [106]:



Şekil 2.4. Çok katmanlı NMF dekompozisyonu [106].

MLCNMF için maliyet fonksiyonu ve iteratif güncelleme fonksiyonu aşağıdaki şekilde tanımlanmaktadır;

$$C(A,S) = \frac{1}{2} \|X-AS\|_F^2 + \alpha_A \|A\|_{\frac{1}{2}} + \alpha_S \|S\|_{\frac{1}{2}} \quad (2.31)$$

$$A_l \leftarrow A_l .* (X_l S_l^T) ./ \left(A_l S_l S_l^T + \frac{1}{2} \alpha_A A_l^{-2} \right) \quad (2.32)$$

$$S_l \leftarrow S_l .* (A_l^T X_l) ./ \left(A_l A_l^T S_l + \frac{1}{2} \alpha_S S_l^{-2} \right) \quad (2.33)$$

Çok katmanlı NMF yaklaşımı, AVIRIS Indian Pines veri seti için MS-HS veri kaynaştırmasında uygulanmış ve elde edilen sonuçlar aşağıdaki Tablo 2.5.'de sunulmuştur. Tablo 2.5.'deki α_A ve α_S parametre değerleri Denklem (2.12) formülü kullanılarak elde edilmiştir. Tablo 2.5. incelendiğinde MLNMF kısıtının CNMF'ye eklenmesinin iyi bir performans ile sonuçlanmadığı görülmektedir.

Tablo 2.5. MLCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.

değer		PSNR	
α_A_hyper	α_S_multi	CNMF	MLCNMF
58,5807	4,1637	40,2868	33,1776

2.1.5. Veriye dayalı NMF (Data guided NMF, DGC - NMF)

DGC-NMF yaklaşımında, bir hiperspektral görüntünün farklı lokasyonlarda farklı seyreklik kısıtının olabileceği varsayımı kullanılmaktadır. $L_{1/2}$ ya da L_2 -düzenleyicisi NMF'ye seyreklik kısıtının eklenmesini sağlamaktadır. DGC-NMF yaklaşımı ise, bu kısıtlardan hangisinin ne zaman ekleneceğine karar vermektedir. DGC-NMF yaklaşımının maliyet fonksiyonu aşağıdaki gibi yazılabilmektedir [107];

$$C(W,H)=\frac{1}{2} \|X-WH\|_F^2 + \lambda \|C.*H\|_{\frac{1}{2}} + \mu \|D.*H\|_{\frac{1}{2}} \quad (2.34)$$

burada λ ve μ düzenleyici parametrelerdir. $C=1_p s^T$ ve $D=1_p(1_N-s)^T$ indiktör matrisleridir. Bu matrisler $L_{1/2}$ ya da L_2 -düzenleyicisinin eklenip eklenmeyeceğine karar vermektedirler. s vektörü ise, bütün piksellerin bolluk oranlarının seyreklik seviyeleriyle elde edilmektedir;

$$s(n)= \begin{cases} 1 & \text{seyreklik}(n) > \delta \\ 0 & \text{seyreklik}(n) \leq \delta \end{cases} \quad (2.35)$$

buradaki δ eşik değeridir ve Otsu metodu [108] kullanılarak bulunmaktadır. DGC-NMF yaklaşımının iteratif güncelleme kuralı aşağıdaki gibi yazılabilmektedir;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.36)$$

$$H \leftarrow H .* (W^T X) ./ \left(W^T W H + \frac{\lambda}{2} C .* H^{-1} + 2\mu D .* H \right) \quad (2.37)$$

DGC-NMF düzenleyicisini, CNMF [82] yaklaşımına eklediğimizde, DGC-CNMF kodu elde edilmektedir. DGC-CNMF yaklaşımı, AVIRIS Indian Pines veri seti üzerinde MS-HS veri kaynaştırması için uygulanmıştır ve elde edilen nümerik sonuçlar aşağıdaki gibi sunulmaktadır;

Tablo 2.6. DGC-CNMF ile kaynaştırılmış görüntülerin PSNR değerleri.

value		PSNR	
λ_{hyper}	μ_{multi}	CNMF	DGC-CNMF
58,5807	4,1637	40,2868	33,1346

Tablo 2.6.'daki λ_{hyper} ve μ_{multi} parametre değerleri en yüksek PSNR değerini veren rastgele denemeler sonucunda elde edilmiştir. Tablo.2.6. incelendiğinde DGC-CNMF kısıtının CNMF'ye eklenmesinin (DGC-CNMF) iyi bir performans ile sonuçlanmadığı görülmüştür.

2.1.6. Toplam değişinti kısıtlı graf düzenleyicili NMF (Total variation constrained graph regularized NMF, TV-GNMF)

TV-GNMF, seyrek matris faktörizasyonuna dayalı ve toplam değişinti kısıtı ile beraber Gradient bilgisini kullanmaktadır. Ayrıca TV-GNMF verinin karakteristik özelliklerini ve detaylarını koruyarak NMF başarımını artırmayı amaçlamaktadır. Toplam değişinti (Total Variation - TV), nesnenin sınırlarını, verinin detay ve karakteristik özelliklerini iyi bir şekilde korumaktadır. Manifold graf düzenleyicisi ise, verinin geometrik ve yapısal bilgisinden etkili bir şekilde yararlanmak için kullanılmaktadır. Bu nedenle, bu iki kısıtlama TV-GNMF'de daha iyi bir başarımla elde etmek için kullanılmaktadır [109].

(2.22-2.25) denklemlerindeki eşitlikler kullanılarak, maliyet fonksiyonu aşağıdaki gibi tanımlanmaktadır;

$$C(W,H)=\frac{1}{2} \|X-WH\|_2^2 + \lambda \text{Tr}(H\tilde{L}H^T) + \beta \|H\|_{\text{TV}} \quad (2.38)$$

kısıtı altında $W \geq 0$, $H \geq 0$

burada $\tilde{L}=D-\tilde{W}$ Laplacian operatörü, \tilde{W}_{ij} ısı çekirdeği ve D ise diagonal matristir ve $D_{ii}=\sum_j \tilde{W}_{ij}$ dir.

Toplam değişinti sürekli ve ayırık uzayda aşağıdaki gibi tanımlanmaktadır. Sürekli uzayda,

$$E(H)=\|H\|_{TV} = \int_{\Omega} |\nabla H| \, dx dy \quad (2.39)$$

ayrık uzayda ise,

$$\|H\|_{TV} = \sum_{i,j} |(\nabla H)(i,j)| = \sum_{i=1}^r \sum_{j=1}^n \sqrt{((\partial_x H)(i,j))^2 + ((\partial_y H)(i,j))^2} \quad (2.40)$$

şeklinde tanımlanmaktadır. Burada $\|\cdot\|_{TV}$ TV-normunu ifade etmektedir. φ_{ik} ve ϕ_{kj} ve Lagrangian çarpanları $\Psi = [\varphi_{ik}]$ ile $\Phi = [\phi_{kj}]$ olmak üzere, Lagrangian fonksiyonu aşağıdaki şekilde yazılabilmektedir;

$$\begin{aligned} L &= \frac{1}{2} \|X-WH\|_2^2 + \lambda \text{Tr}(H\tilde{L}H^T) + \beta \|H\|_{TV} + \text{Tr}(\Psi W^T) + \text{Tr}(\Phi H^T) \\ &= \text{Tr}(XX^T) - 2\text{Tr}(XH^T W^T) + \text{Tr}(WHH^T W^T) + \text{Tr}(H\tilde{L}H^T) + \beta \|H\|_{TV} \\ &\quad + \text{Tr}(\Psi W^T) + \text{Tr}(\Phi H^T) \end{aligned} \quad (2.41)$$

L fonksiyonunun W ve H'a göre türevleri alınıp sıfıra eşitlenecek olursa,

$$\frac{\partial L}{\partial W} = -2XH^T + 2WHH^T + \Psi \quad (2.42)$$

$$\frac{\partial L}{\partial H} = -2W^T X + 2W^T WH + 2\lambda HX - 2\beta \text{div} \left(\frac{\nabla H}{|\nabla H|} \right) + \Phi \quad (2.43)$$

elde edilmektedir. Karush-Kuhn-Tucker (KKT) şartı kullanılarak aşağıdaki TV-GNMF çarpımsal güncelleme kuralı elde edilmektedir;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.44)$$

$$H \leftarrow H .* \left(W^T X + \lambda HX + \beta \text{div} \left(\frac{\nabla H}{|\nabla H|} \right) \right) ./ (W^T WH + \lambda HD) \quad (2.45)$$

TV-GNMF yaklaşımı, CNMF [82]'ye uyarlanarak TV-GCNMF kodu elde edilmiştir. Bu kod, AVIRIS Indian Pines veri seti üzerinde MS-HS veri kaynaştırması için uygulanmıştır ve elde edilen nümerik sonuçlar Tablo 2.7.'deki gibi sunulmaktadır. Tablo 2.7.'deki λ_{hyper} ve μ_{multi} parametre değerleri en yüksek PSNR değerini

veren rastgele denemeler sonucunda elde edilmiştir. Tablo 2.7. incelendiğinde TV-GNMF kısıtının CNMF'ye eklenmesinin (TV-GCNMF) iyi bir performans ile sonuçlanmadığı görülmüştür.

Tablo 2.7. TV-GCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.

value		PSNR	
λ_hyper	μ_multi	CNMF	TV-GCNMF
28,5807	2,1637	40,2868	38,1346

2.1.7. Son eleman ve bolluk oranları kısıtlı NMF (NMF Method with endmemeber and abundance constraints, EAC-NMF)

EAC-NMF yaklaşımında, son eleman ve bolluk oranlarına eş zamanlı olarak kısıtlamalar getirilmektedir. Son elemanların geometrik özellikleri bolluk oranlarının ise seyreklik ve uzamsal düzgünlülük kısıtları eklenmektedir [110]. Son elemanlar üzerine kısıtlamalar;

$$ED(W) = \sum_{i=1}^K \|w_i - \tilde{w}\|_2^2, \quad \tilde{w} = \sum_{i=1}^K \frac{w_i}{K}, \quad ED(W) = \text{tr}(WPW^T) \text{ ve}$$

$$P = I - I_K I_K^T / K \quad (2.46)$$

Bolluk oranlar üzerine kısıtlamalar ise,

$$L_{1/2}\text{-düzenleyicisi: } AB_1(H) = \|H\|_{\frac{1}{2}} \quad (2.47)$$

$$\text{Düzgünlülük kısıtı: } AB_2(H) = \sum_{i=1}^N \sum_{j \in N(i)} \|h(i) - h(j)\|^2 u_{ij} \quad (2.48)$$

$$= \text{Tr}(HWH^T) - \text{Tr}(HUH^T)$$

şeklinde tanımlanmaktadır. $N(i)$, i .inci pikselinin sekiz tane komşusunu içeren bölgeyi temsil etmektedir. u_{ij} ise, piksel i ve piksel j arasındaki spektral benzerliği ifade etmekte ve Denklem (2.49)'daki şekilde tanımlanmaktadır;

$$u_{ij} = \begin{cases} e^{-\|x^{(i)} - x^{(j)}\|^2} & \text{eğer } j \in N(i) \\ 0 & \text{diğer durumda} \end{cases} \quad (2.49)$$

W diagonal matris olmak üzere,

$$W_{ii} = \sum_j u_{ij} \quad (2.50)$$

şeklinde tanımlanmaktadır. Maliyet fonksiyonu ise,

$$C(W, H) = f_0 + ED(W) + \beta AB_1(H) + \frac{\gamma}{2} AB_2(H) \quad (2.51)$$

$$\text{kısıtı altında } W \geq 0, H \geq 0, \quad 1_K^T H = 1_N^T$$

olarak tanımlanmaktadır. W ve H'a göre türevler alınıp sıfıra eşitlenecek olursa, çarpımsal güncelleme kuralı, aşağıdaki gibi ifade edilmektedir;

$$W \leftarrow W .* (XH^T) ./ (WHH^T + \alpha AP) \quad (2.52)$$

$$H \leftarrow H .* (W^T X + \gamma HU) ./ \left(W^T W H + \gamma H W + \frac{\beta}{2} H^{-1} \right) \quad (2.53)$$

EAC-NMF yaklaşımı, CNMF [82]'ye uyarlanarak EAC-CNMF kodu elde edilmiştir. Bu kod, AVIRIS Indian Pines veri seti üzerinde MS-HS veri kaynaştırması için uygulanmıştır ve elde edilen nümerik sonuçlar Tablo 2.8.'deki gibi sunulmaktadır.

Tablo 2.8. EAC-CNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.


value		PSNR	
λ_hyper	μ_multi	CNMF	EAC-CNMF
32,1843	1,1665	40,1971	38,2391

Tablo 2.8.'deki λ_hyper ve μ_multi parametre değerleri en yüksek PSNR değerini veren rastgele denemeler sonucunda elde edilmiştir. Tablo 2.8. incelendiğinde EAC-NMF kısıtının CNMF'ye eklenmesinin (EAC-CNMF) iyi bir performans ile sonuçlanmadığı görülmüştür.

2.1.8. Lokal komşuluk ağırlıklı NMF (Local neighborhood weights NMF - WNMF)

WNMF yaklaşımında, bir lokal komşulukta uzamsal komşuluk pikselleri arasında bolluk oranlarının benzerliğine dayalı ağırlık belirlenmektedir. Burada x_i ve x_j pikselleri spektral olarak birbirine çok yakınsa, x_j komşu pikselleri x_i pikseline daha çok katkı sağlamaktadır' varsayımı kullanılmaktadır.

WNMF yaklaşımı, ayrıca 'Saf pikseller büyük bir olasılıkla homojen bölgelerde daha çok bulunmaktadır. Fakat, karışım halinde bulunan pikseller ise, daha çok geçiş alanlarında (transition areas) bulunmaktadır' varsayımı üzerinde durularak geliştirilmiştir [111].



Şekil 2.5. S benzerlik matrisine göre homojen ve geçiş alanlarının bölütlenmesi a) simüle edilmiş spektral görüntü b) benzerlik matrisi c) bölütleme sonuçları [111].

Böylelikle, spektral karışım giderimi bu homojen ve geçiş bölgelerinin bölütlenmesinden fayda sağlayabilmektedir. Buna göre, x_j komşu pikselinin x_i pikseline sağladığı katkı aşağıdaki ağırlık ile tanımlanmaktadır;

$$w_{ij} = \frac{1}{\sqrt{\alpha + \beta}}, \quad j \in N(i) \quad (2.54)$$

Burada α ve β değerleri x_i ve x_j pikselleri arasındaki uzamsal ve spektral farkları karakterize etmektedir. (r,s) ve (k,l) i ve j piksellerinin uzamsal koordinatları olmak üzere, x_i ve x_j pikselleri eşit olarak $x(r,s)$ ve $x(k,l)$ şeklinde ifade edilebilmektedir. Buradaki uzamsal ve spektral farklar Denklem (2.55)'teki şekilde tanımlanmaktadır;

$$\alpha = \sqrt{(r-k)^2 + (s-l)^2} \quad (2.55)$$

$$\beta = \text{SAD}(x(r,s), x(k,l)) = \cos^{-1} \frac{x(r,s) \cdot x(k,l)}{\|x(r,s)\| \|x(k,l)\|} \quad (2.56)$$

α ve β değerlerinin küçük olması j.ninci pikselin i.ninci piksele olan katkısının fazla olduğu anlamına gelmektedir. Homojen ve geçiş alanlarının bölütlemesinde $p \times q$ boyutundaki bir görüntü üzerinde toplam $p * q$ tane piksel bulunmaktadır. i.ninci pikselin (r,s) uzamsal koordinatı ile p ve q arasında aşağıdaki ilişki bulunmaktadır;

$$i = (r-1) * q + s$$

$$i = (s-1) * p + r \quad (2.57)$$

(r,s) uzamsal koordinatına sahip x_i pikseli için onun lokal komşuluk piksellerinin etkisi $\lambda(r,s)$ ile ifade edilmektedir ve aşağıdaki şekilde tanımlanmaktadır;

$$\lambda(r,s) = \lambda_i = \sum_{j \in N(i)} w_{ij} \quad r=1, \dots, p; s=1, \dots, q, i=1, \dots, N. \quad (2.58)$$

λ_i ya da $\lambda(r,s)$ lokal komşuluk benzerlik ölçümü olarak görülebilmektedir. Bütün $p \times q$ boyutundaki görüntü için bütün benzerlik ölçüm matrisi aşağıdaki gibi tanımlanmaktadır;

$$S = \begin{bmatrix} \lambda(1,1) & \lambda(1,2) & \dots & \lambda(1,q) \\ \lambda(2,1) & \lambda(2,2) & \dots & \lambda(2,q) \\ \vdots & \vdots & \ddots & \vdots \\ \lambda(p,1) & \lambda(p,2) & \dots & \lambda(p,q) \end{bmatrix} \quad (2.59)$$

Bu benzerlik matrisinde, homojen pikseller birbirine yakın ve yüksek değerlere sahiptir. Fakat, geçiş alanlarındaki pikseller birbirinden farklı ve küçük değerlere sahiptirler. Buna göre, WNMF maliyet fonksiyonu aşağıdaki gibi tanımlanmaktadır;

$$C(W,H) = \min \|X - WH\|_F^2 + \sum_{i=1}^N \sum_{j \in N(i)} w_{ij} \|h_i - h_j\|_2^2 \quad (2.60)$$

kısıtı altında $W \geq 0, H \geq 0$

Maliyet fonksiyonunun W ve H 'ya göre türevi alınıp sıfırlanacak olursa, çarpımsal güncelleme kuralı aşağıdaki gibi elde edilmektedir;

$$W \leftarrow W .* (XH^T) ./ (WHH^T) \quad (2.61)$$

$$H \leftarrow H .* (W^T X + H_w) ./ (W^T W H + S .* W) \quad (2.62)$$

burada H_w değeri $\sum_{j \in N(i)} w_{ij} h_j$ toplamına eşittir.

WNMF yaklaşımı, CNMF [82]'ye uyarlanarak WCNMF kodu elde edilmiştir. WCNMF kodu, AVIRIS Indian Pines veri seti üzerinde MS-HS veri kaynaştırması için uygulanmıştır ve elde edilen nümerik sonuçlar aşağıdaki gibi sunulmaktadır:

Tablo 2.9. WCNMF ile Kaynaştırılmış görüntülerin PSNR değerleri.

value		PSNR	
λ_hyper	μ_multi	CNMF	WCNMF
29,9977	0,2426	40,2868	40,6491

Tablo 2.9.'deki λ_hyper ve μ_multi parametre değerleri [105]'de yapıldığı gibi, $[\lambda_e/10, 10\lambda_e]$ aralığında lineer bir araştırma yapılarak belirlenmiştir. Tablo 2.9. incelendiğinde WNMF kısıtının CNMF'ye eklenmesinin (WCNMF), biraz daha iyi bir performans sağladığı görülmektedir.

2.2. Vargılar

Tezin bu bölümünde MS-HS veri kaynaştırmasına dayalı hiperspektral uzamsal çözünürlük artırımı, CNMF [82] yaklaşımına bazı düzenleyici terimler ekleyerek gerçekleştirilmiştir. En iyi performans artışını sırası ile, $L_{1/2}$ -CNMF, GLCNMF ve WCNMF yaklaşımları en iyi karışım giderimi sonucunu vermektedir. CNMF [82]'ye başka düzenleyici terimler eklenerek, karışım giderimi başarımları artırılabilir.

3. LİDAR - HİPERSPEKTRAL KAYNAŞTIRMA TEMELLİ UZAMSAL ÇÖZÜNÜRLÜK ARTIRIMI

3.1. LiDAR Verisi Yardımıyla Hipergraf Kısıtlı Hiperspektral Karışım Giderimi

Son yıllarda gözlemlenen sahne hakkında daha çok faydalı bilgi sağlayan alıcı teknolojilerinde birçok ilerlemeler gerçekleştirilmiştir. En yeni uzaktan algılama teknolojilerinden ikisi; hiperspektral ve LiDAR alıcılarıdır. Küçük uzamsal komşuluktaki pikseller büyük olasılıkla benzer bolluk değerlerini içerdikleri için, hiper-graf düzenleyicili negatif olmayan matris faktörizasyonu (HG-NMF) uzamsal olarak komşu pikseller arasındaki benzerlik ilişkisini ele almak için uygulanabilmektedir. Bu çalışmada LiDAR verisi yardımıyla HG-NMF kısıtlı hiperspektral karışım giderimi gerçekleştirilmektedir. Bütün bu değerli bilgilerin birleşik kullanımı yüksek doğruluklu karışım giderimi sonuçlarına sebep olmaktadır. Elde edilen konveks optimizasyon problemi Spectral Unmixing by Split Augmented Lagrangian (SUnSAL-TV) Algoritması kullanılarak çözülmüştür. Deneyler sentetik data üzerinde gerçekleştirilmiştir. Ayrıca HG-NMF kısıtının avantajları belirtilmiştir.

Alıcı teknolojilerindeki gelişmeler gözlemlenen sahne için LiDAR ve hiperspektral verilerinin eş zamanlı olarak elde edilmesine olanak sağlamaktadır. Bu yolla, yer yüzü yüzeyi hakkında farklı bakış açılarında ölçümler kolaylıkla elde edilmektedir. Örneğin; hiperspektral görüntü detaylı spektral radyans bilgisini, LiDAR verisi ise, gözlemlenen sahnenin yükseklik bilgisini vermektedir [112]. Fakat, bu faydalı modüller büyük avantajlara sahip olmalarına rağmen, bazı kısıtlamalara da sahiptirler. Diğer bir deyişle, hiperspektral veri benzer materyallerden yapılan farklı nesnelere ayırt edememektedir. (örneğin; asfalt ile kaplı çatı ve yol) ve bulutun altındaki bölgelerde materyali ayırt etme konusunda sıkıntılara neden olmaktadır. Öte yandan, LiDAR verisi aynı yükseklikteki farklı nesnelere ayırt edememektedir. (örneğin; çimen ve yol). Bu nedenle, LiDAR verisi ile hiperspektral görüntünün spektral verisinin birbirini tamamlayan kullanımıyla, hiperspektral karışım

gideriminin performansı artırılabilir. LiDAR verisini kullanan çeşitli karışım giderimi çalışmaları vardır. [113]'de yarı öğreticili (semi-supervised) içeriğe bağlı hiperspektral karışım giderimi yaklaşımı sunulmuştur. LiDAR alıcısından kısmi denetim kullanmaktadır. [114]'de, parçalı konveks uzamsal-spektral karışım giderimini içeren yeni bir algoritma hiperspektral görüntünün karışım giderimi için sunulmuştur. Olasılıksal ve Fuzzy kümeleme alt piksel hedef takibi için sunulmuştur. [115]'de, dış LiDAR verisini standart uzamsal düzenleyicileri ayarlamak için kullanan bir karışım giderimi sistemi sunulmuştur. [116]'de, spektral ve ağaç özelliklerinin kullanılmasıyla hiperspektral ve LiDAR verilerinin birleşimini içeren bir metodoloji sunulmaktadır. Veri kaynaştırma Teknik Komitesi IEEE Yerbilim ve Uzaktan Algılama Topluluğu (The Data Fusion Technical Committee of the IEEE Geoscience and Remote Sensing Society - GRSS)'in 2013'de gerçekleştirmiş olduğu yarışmada bulut gölgesini içeren hiperspektral görüntüsü ile LiDAR verisinden elde edilen dijital yüzey modeli (digital surface model - DSM) sunulmaktadır [117]. Özel olarak, boyut azaltımı ve spektral bilginin özellik kaynaştırmasını gerçekleştirmek için grafa dayalı kaynaştırma yaklaşımı ve onun geliştirilmiş versiyonu sunulmuştur.

Tezin bu bölümünde, grafa dayalı manifold düzenleyicisinin bir geliştirmesi olarak, hiper-graf düzenleyicisi LiDAR verisi ile hiperspektral karışım giderimi başarımını artırmak için kullanılmıştır. Bu nedenle, multi-modal (HS ve LiDAR) veri kaynaştırması HG-NMF düzenleyicisi ile ilişkilendirilmiştir. Bu çalışma [115]'deki HS-LiDAR veri kaynaştırması çalışmasından ilham alınarak gerçekleştirilmiştir. Sunulan yaklaşımda temel yenilik HS-LiDAR karışım gideriminde hiper-grafın kullanılmasıdır. Kullanılan hiper-graf yüksek derecede ilişkiyi ifade edebilmektedir. Ve böylece sonuç Laplacian düzenleyicisi karışım giderimi sonuçları için ek ilişkisel bilgi sunmaktadır.

3.1.1. Toplam değişinti (Total variation - TV) düzenleyicili LiDAR yardımıyla karışım giderimi

Toplam değişinti yaklaşımı, lokal uzamsal benzerlik kısıtı olarak kenar yapısını korumaktadır. Bu yaklaşım bir pikselin sadece dört komşusu ile benzer olduğu varsayımını kabul etmektedir [118]. Hiperspektral görüntüleri gözlemlenen sahne ile

ilgili yeterli bilgi sağlamasına rağmen birbirlerine spektral olarak yakın fakat farklı olan objeleri doğru bir şekilde ayırt etme konusunda bazen yeterli olamamaktadır. Bu durumda, LiDAR verisinden çıkartılan dijital yüzey modeli (digital surface model - DSM) yükseklik bilgisini temin ettiği için daha çok faydalı olabilmektedir. Uzamsal düzenleyici ağırlıkları LiDAR görüntüsü kullanılarak tahminlenebilmektedir. Ayrıca, yükseklik farkları farklı materyalleri ayırt etmek için önemli bir rol oynamaktadır. Bu yolla, kenarlara yerleştirilen komşuluk pikselleri uzamsal düzenleyiciye farklı bir şekilde katkıda bulunabilmektedir. LiDAR data bilgisi ile ağırlıklandırılmış TV uzamsal düzenleyicisi aşağıdaki gibi sunulmaktadır [115];

$$\min_A \|Y-EA\|_F^2 + \lambda \sum_{i=1}^N \sum_{j \in N(i)} w_{ij} \|a_i - a_j\|_P^P \quad (3.1)$$

Burada λ parametresi veri eşleştirme terimi (data-fitting term) ve uzamsal düzenleyici arasındaki dengeyi kontrol eden düzenleyici parametreyi belirtmektedir. $p=1$ değeri anisotropic TV düzenleyicisidir. Birçok ağırlık fonksiyonları tanımlanabilmektedir [115]. Bu çalışmada, w-DSM ağırlıklandırma fonksiyonu aşağıdaki gibi kullanılmıştır;

$$w_{ij} = \frac{1}{Q_i} \left[\exp \left(-\frac{1}{\sigma_h^2} \frac{(h_i - h_j)^2}{(h_i + h_j)^2} \right) \right] \quad (3.2)$$

burada h_i LiDAR DSM bantlarını Q_i normalizasyon sabitini ve σ_h^2 ise ağırlık aralığını kontrol eden parametreyi belirtmektedir.

3.1.2. Hiper-graf

Yukarıda belirtildiği gibi TV düzenleyicisi sadece dört doğrultuda komşuluk pikselleri ile ilgilenmektedir. Fakat, graf Laplacian düzenleyicisi daha çok esneklik özelliğine sahiptir. Çünkü, bir pikseli benzer oldukları sürece diğer birçok pikselle ilişkilendirmeye izin vermektedir. Uzamsal ve spektral bilgi eş zamanlı olarak kullanıldığında dikkate değer bir oranda performansı artırılmış, karışım giderimi doğruluğu elde edilebilmektedir. Hiperspektral görüntünün uzamsal-spektral ilişki özelliğine göre benzer pikseller büyük olasılıkla benzer bolluk değerlerini küçük uzamsal komşulukta paylaşmaktadırlar. Böylelikle, uzamsal olarak komşu piksellerin

spektral benzerliği bolluk değerlerinin tahminlenmesine katkıda bulunabilmek için kullanılabilir. Gerçek dünyada, iki tane komşuluk pikselleri büyük olasılıkla aynı sınıfa aittirler.

Basit graf bazı karmaşık ilişkileri ifade edemediği için birçok uygulamada dikkate değer ölçüde bilgi kaybına neden olabilmektedir. Basit grafa benzemeden, hiper-graf birçok veri örnekleri arasında yüksek dereceden ilişkiyi yakalayabilmektedir. Bu durum, hiperspektral görüntünün spektral-uzamsal birleşik yapısının etkili bir şekilde modellenmesini sağlamaktadır [119]. Bu tezde, L_1 -NMF'li, hipergraf-düzenleyicisi (HGL₁-NMF), [115]'deki çalışmadan ilham alınarak yüksek başarımlı bolluk değeri tahminlemesi elde etmek için kullanılmıştır. Bir hiper-graf modelinde, her bir köşe hiperspektral görüntünün bir pikselini ifade etmektedir ve her bir hiper-köşe (hyperedge) piksel grupları arasındaki benzerlik ilişkisini belirtmektedir.

Tezin bu bölümünde, hiper-graf ile ilgili kavramlar tanımlanmaktadır. V köşelerin sonlu kümesini ve E ise, V 'nin alt kümelerinin ailesini belirtmektedir ve şu şekilde gösterilmektedir: $U_{e \in E} = V$. Böylelikle, kenar kümesi V ve hiperköşe kümesi E 'den oluşan $G=(V,E)$ ikilisi hiper-graf olarak tanımlanmaktadır. Bir hiperkenar sadece iki tane köşeden oluşursa, basit graf kenarı olarak isimlendirilmektedir. Ağırlıklandırılmış hiper-graf her bir hiperkenarla ilişkili olan pozitif değerli sabit $w(e)$ değerine sahiptir. Buradaki e değeri hiperkenarın ağırlığı olarak isimlendirilmektedir. Bu durumda hiper-graf $G=(V,E,W)$ ağırlıklandırılmış hipergraf olarak adlandırılmaktadır. $v \in V$ kenarının derecesi $d(v) = \sum_{\{e \in E | v \in e\}} w(e)$ olarak tanımlanmaktadır. Keyfi bir S kümesi verildiğinde $|S|$, S kümesinin kardinalitesini ifade etmektedir. $e \in E$ hiperkenarı için onun derecesi $\delta(e) = |e|$ olarak tanımlanmaktadır. Hiper-graf G $|V| \times |E|$ matrisi şeklinde ifade edilebilmektedir. İlişki matrisi (incidence matrix) H , $h(v,e)=1$ if $v \in e$ ve 0 değerlerini alabilmektedir. Dolayısıyla, $d(v) = \sum_{e \in E} w(e) h(v,e)$ ve $\delta(e) = \sum_{v \in V} h(v,e)$ ifadeleri elde edilebilmektedir. D_v ve D_e sırasıyla köşe ve hiperkenar derecelerini içeren diagonal matrisleri ifade etmektedir. W hiperkenarların ağırlıklarını içeren diagonal matrisi ifade etmektedir. eğer $i=j$ $(D_v)_{ij} = d_{v_i}$ ve diğer durumda $(D_v)_{ij} = 0$ şeklinde tanımlanmaktadır. Benzer şekilde, D_e ve W matrisleri diagonal girişlerinde $j=1,2,\dots,M$ için $\delta(e_j)$ ve $w(e_j)$ değerlerinden oluşmaktadır. G hiper-grafının A

komşuluk matrisi $A=HWH^T-D_v$ şeklinde tanımlanmaktadır. Burada H^T , H matrisinin transpozunu ifade etmektedir [120].

Hiperkenar, köşelerin grubu şeklinde tanımlandığı yukarıda belirtilmişti. Bu köşeler grubu bir merkezi köşeyi belirtmektedir. Ve bu merkez k-tane en yakın komşuya (k-nearest neighbors) sahiptir [120]. Doayısıyla, normalize olmamış hiper-graf Laplacian matrisi $L^{Hyper}=D_v-B$ şeklinde formalize edilebilmektedir. Burada, $B=HW(D_e)^{-1}H^T$ benzerlik matrisini

$|V| \times |V|$ belirtmektedir. Eğer (u, v) birbirleriyle bağlantılı ise, benzerlik matrisi (u,v)'nin ağırlığına eşittir, diğer durumda 0 değerine eşittir. Buna ek olarak, yukarıdaki ifadelere benzer şekilde köşe-kenar benzerlik ilişkisini dikkate alarak Laplacian matrisinin diğer eşiti $L=I-D_v^{-1/2}BD_v^{-1/2}$, lineer yansıtma matrisi kullanılarak $L=2D_v-HWH^T$ ve $L=I-\frac{1}{2}D_v^{-1/2}HWH^TD_v^{-1/2}$ şeklinde yazılabilmektedir [121]. Graf Laplacian matrisi aşağıdaki gibi yazılabilmektedir;

$$\sum_{e \in E} \sum_{u,v \in e} \frac{w(e)h(v,e)h(v,e)}{\delta(e)} \|a_i - a_j\|^2 = \text{Tr}(AL^{Hyper}A^T) \quad (3.3)$$

burada $L=D_v-HWD_e^{-1}H^T$.

Basit olması adına bu çalışmada, aynı sayıda köşeleri içeren düzgün hipergraf (uniform hypergraph) kullanılmıştır.

3.1.3. Hiper-grafı karışım giderimi ile birleştirme

Bir hipergraf oluşturmak için her bir piksel köşe olarak alınmakta ve bu her bir pikselin k-tane en yakın komşusu (K-nearest neighbors - KNNs) alınarak hiperkenar $e_j \in E$ oluşturulmuştur.

Bu komşular v_i ile aynı uzamsal komşulukta t tane alınarak seçilmektedir. Dolayısıyla, hipergraf G, farklı uzamsal bölgelerde oluşturulan N tane hiperkenar içermektedir. Bu hiperkenarlara dayanarak W ağırlık matrisi, ilişki matrisi H, köşe

D_v ve hiperkenar derece matrisi D_e tanımlanabilmektedir. Ağırlık matrisinin herbir elemanı aşağıdaki şekilde hesaplanabilmektedir [122];

$$w(e_i) = \sum_{y_j \in e_i} \exp\left(-\frac{\|y_i - y_j\|^2}{\delta^2}\right) \quad (3.4)$$

burada $\delta = \frac{1}{KN} \sum_{i=1}^N \sum_{\{y_j \in e_i\}} \|y_i - y_j\|^2$ uzamsal komşuluk pikselleri arasındaki ortalama mesafeyi ifade etmektedir.

3.1.4. Optimizasyon

Denklem (3.1) dikkate alındığında, L_1 -NMF'li hipergraf düzenleyici kısıtını maliyet fonksiyonuna eklediğimizde aşağıdaki eşitlik elde edilmektedir;

$$C(W,H) = \|Y - EA\|_F^2 + \lambda \sum_{i=1}^N \sum_{j \in N(i)} w_{ij} \|a_i - a_j\|_p^p + \alpha \|A\|_1 + \beta \text{Tr}(AL^{\text{Hyper}}A^T) \quad (3.5)$$

Bu kısıtlı optimizasyon problemini çözmek için, düzenleyici başına yeni değişkenler tanımlanmıştır ve daha sonra ADMM methodu kullanılmıştır [123]. Yeni değişkenleri seçerek, optimizasyon problemi daha basit alt problemler dizisine dönüştürülmüştür (SUnSAL-TV) [124]. Bu strateji kullanılarak problem daha etkin bir şekilde çözülmektedir;

$$\min_A \frac{1}{2} \|Y - EA\|_F^2 + \lambda \|AW\|_{1,1} + \iota_N(A) + \iota_S(A) + \beta \text{Tr}(AL^{\text{Hyper}}A^T) \quad (3.6)$$

burada $\iota_C(\cdot)$ indikatör fonksiyonudur. N ve S negatif olmama ve toplanabilirlik kısıtını ifade etmektedir;

$$\min_{U,V} \frac{1}{2} \|V_1 - Y\|_F^2 + \lambda \|V_3\|_{1,1} + \iota_N(V_4) + \iota_S(V_5) + \beta \text{Tr}(V_6 L^{\text{Hyper}} V_6^T) \\ \text{s.t.} + \begin{cases} V_1 = EU \\ V_2 = U \\ V_3 = V_2 W \end{cases} \quad \text{ve} \quad \begin{cases} V_4 = U \\ V_5 = U \\ V_6 = U \end{cases} \quad (3.7)$$

Problem şu şekilde tekrar yazılabilmektedir;

$$\min_{U,V} g(V) \text{ burada } GU+VB=0 \quad (3.8)$$

$$G = \begin{bmatrix} E \\ I \\ 0 \\ I \\ I \\ I \end{bmatrix}^T \text{ ve } B = \begin{bmatrix} -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & -1 & W & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 \end{bmatrix} \quad (3.9)$$

Augmented Lagrangian şu şekilde ifade edilebilmektedir;

$$L(U,V,D) = g(V) + \frac{\mu}{2} \|GU+VB-D\|_F^2 \quad (3.10)$$

3.1.5. Deneysel sonuçlar

Simulasyon verisi olan SIM görüntüsü USGS spektral kütphanesinden rastgele beş tane son eleman seçilerek oluşturulmuştur. 60×60 boyutunda [115]'den sentetik bir alt küme görüntüsü kullanılmıştır. Bu sentetik görüntüde her bir alan farklı bir yükseklik değerine atanmıştır. Daha sonra, bu veri beyaz Gaussian gürültüsü ile SNR = 30dB değerinde bozulmuştur.

Deneyle her bir piksel merkez köşe olarak alınıp 5×5 boyutunda kayan pencere içerisindeki 7 tane en-yakın komşuluğu alınarak gerçekleştirilmiştir. Beta ve mu değerleri 0,001 ve 0,1 olarak seçilmiştir. δ ve λ parametreleri deneysel olarak ayarlanmış ve en düşük RMSE değerini verdikleri için 0,2 ve 0,05 şeklinde sırasıyla alınmıştır. Bu parametre büyük bir oranda bolluk değeri tahminlemesini etkilemektedir.

Tablo 3.1. sonuçlarında da görüldüğü gibi HGL₁-NMF düzenleyicisini eklemek daha iyi karışım giderimi sonucuna sebep olmaktadır.

Tablo 3.1. TV düzenleyicili LiDAR w-DSM ve w-DSM-HG-NMF.

	TV regularized LiDAR	
	w-DSM	w-DSM-HGL ₁ -NMF
RMSE	0.0071	0.0061

Tezin bu bölümünde, hiper-graf düzenleyicisine dayalı hiperspektral karışım giderimi LiDAR verisi kullanılarak gerçekleştirilmiştir. Sunulan yapı, bütünleşik modalitelerin avantajlarını kullanmaya izin vermektedir. Dolayısıyla, uzamsal olarak komşu olan piksellerin spektral benzerliği bolluk değerlerinin tahminlenebilmesi için kullanılabilir. Yeni hiper-graf düzenleyicisini eklemek daha iyi bolluk değeri tahminlemesine sebep olmaktadır. Bu yolla, elde edilen sonuçlar daha ayrıntılı deneysel sonuçlar ve parametre optimizasyonu ile birlikte daha iyi bolluk değeri tahminlemesi yapılabileceğini göstermektedir.

3.2. LiDAR Yardımıyla Hiperspektral Görüntülerde Spektral Değişkenliğin Azaltılması

Hiperspektral karışım giderimi uzaktan algılama uygulamalarında son yıllarda büyük bir önem kazanmıştır. Işıklandırma şartları gibi bazı dış etkiler ya da klorofil konsantrasyonu gibi bazı iç etkiler nedeniyle hiperspektral görüntülerde spektral değişkenlik oluşmaktadır. Bu spektral değişkenlik ciddi bolluk değeri tahminlemesi hatasına sebep olmaktadır. Tezin bu bölümünde, yeni bir strateji sunularak LiDAR-DSM bölütleme bilgisini kullanarak hiperspektral görüntüden özellik çıkarımı gerçekleştirilerek hiperspektral karışım gideriminde spektral değişkenlik azaltılmaya çalışılmıştır. Böylece, anlamlı materyal bolluk değeri tahminlemesi elde edilmektedir. Deneysel sonuçlar simulasyon ve gerçek veri üzerinde gerçekleştirilmiştir. Sonuçlar spektral değişkenliğin hiperspektral karışım gideriminde LiDAR yardımıyla azaltılabileceğini göstermektedir. Son yıllarda, karışım halinde bulunan piksellerin üstesinden gelmek için spectral karışım analizi (spectral mixture analysis - SMA) hiperspektral verisi üzerinde çok fazla kullanılmıştır. Lineer karışım modeli spektral karışım giderimi için etkili bir şekilde kullanılmaktadır. Fakat, LKM'nin en önemli dezavantajı lineer olmama ve spektral değişkenliktir. Spektral değişkenlik, bir görüntü boyunca ya da farklı görüntülerdeki materyallerin spektral imzasındaki değişkenlik olarak tanımlanmaktadır. Bir materyal için spektral imzaların değişkenliği hiperspektral karışım giderimi ve sınıflandırmada performans azalmasına neden olmaktadır. Bu problemi vurgulamak için istatistiksel ve deterministik [125] olan çeşitli yaklaşımlar geliştirilmiştir. Spektral değişkenlik çeşitli nedenlerden dolayı meydana gelebilmektedir. Bunlar; ışıklandırma [126], çevresel, topografik ve yüzeyin pürüzlü olması [127], atmosferik

şartlar (su, oksijen, ozon, karbon monoksit ve karbon dioksit gibi) [128], geçici şartlar, materyalin iç değişkenliği, gizli parametrelerin varlığı (bitkilerdeki klorofil konsantrasyonu) [129]. İki tür spektral değişkenlik bulunmaktadır. Bunlar; iç-sınıf spektral değişkenliği ve sınıflar arası spektral değişkenliktir [130]. SMA spektral değişkenliği dikkate almamaktadır. Spektral değişkenlik bolluk değeri tahminlemesini ciddi bir şekilde engellemektedir.

Literatürde spektral değişkenlik ile ilgili bir kaç inceleme çalışması bulunmaktadır. L. Drumetz vd. [131] en yeni ve en güncel spektral değişkenlik yaklaşımlarının incelemesini gerçekleştirmiş ve bu çalışmaları üç başlık altında ayırmışlardır. Bunlar son eleman demetleri, hesaplama modelleri ve parametrik fiziksel modellerdir. Aynı zamanda bu modellerin avantaj ve dezavantajlarını tartışmışlardır. A Zare ve K.C. Ho [132] hiperspektral karışım giderimi ve son eleman tahminlemesi süresince, spektral değişkenlik modellerini incelemişlerdir. Aynı zamanda, spektral değişkenliğin geleceği üzerinde yorumlar yapmışlardır. Son eleman değişkenlik yaklaşımlarını iki kategoriye ayırmışlardır. Bunlar; son elemanların küme olarak ya da istatistiksel dağılım olarak incelenmesidir. B. Somers et vd. [133] SMA'da son eleman değişkenliği ile ilgili indirgeme yaklaşımlarını ve sonuçlarını incelemişlerdir. Aynı zamanda, son eleman değişkenliğini baskılayan ilişkili yaklaşımların önemini vurgulamışlardır. Spektral değişkenlik probleminin üstesinden gelmek için literatürde birkaç farklı teori sunulmuştur. P. Thouvenin vd. [134] son eleman değişkenliği için uzamsal olarak değişen perturbasyon matrisini dikkate alan perturbed lineer karışım modelini (PLMM) sunmuşlardır. M.A. Veganzones vd. [135] Extended lineer karışım modeli (ELMM) her bir piksel için son eleman ölçeklemesine dayanan spektral değişkenliği modellemektedir. D.Hong vd. [136] temel ölçekleme faktörü ve diğer spektral değişkenlikleri spektral değişkenlik sözlüğü ile birleştiren Augmented lineer karışım modelini (ALMM) sunmuşlardır. T. Uezato vd. [137] her bir sınıf için hiyerarşik yapıyı ilişkilendiren bir karışım modeli sunmuşlardır. T. Uezato vd. [138], çok-görevli Gaussian Proses yaklaşımını (multi-task Gaussian Process framework - SUGP) az sayıda son eleman spektra kullanım probleminin üstesinden gelmek için spektral karışım giderimi yaklaşımını için sunmuşlardır.

Veri indirgeme hiperspektral görüntü işleme ve analizinde çok fazla olan hesaplama karmaşıklığını indirmek için geniş olarak kullanılmıştır [139]. Asner ve Lobell

[140] SMA’da veri indirgemenin önemini vurgulamışlardır. Veri indirgeme spektral değişkenliğin etkisini azaltmaktadır. Spektral özellikler ve dalga boylarının alt kümesine odaklanılarak, spektral değişkenlik probleminin üstesinden gelinebilmektedir [126]. Tezin bu bölümünde, LiDAR-DSM bölütleme bilgisini bir özellik çıkarımı yaklaşımı olarak hiperspektral görüntülerin bant seçimi işlemi için kullanan bir strateji sunulmaktadır. Bu sunulan yaklaşımda veri indirgeme olarak da görülebilen bant seçimi hiperspektral görüntüden özellik çıkarımı için kullanılmıştır. Elde edilen spektral özellikler spektral değişkenliğe karşı gürbüz sonuçlar vermektedir. Bu durum SMA’da bolluk değeri tahminlemesini artırmaktadır. Böylelikle, son eleman çeşitliliği bir görüntüde her bir piksel için baskılanabilmektedir.

3.2.1. Metodoloji

Spektral değişkenlik problemi SMA’da bant seçim yaklaşımı kullanılarak indirgenebilmektedir [126]. Bant seçim yaklaşımları minimum spektral değişkenlikle optimal dalga boyu bantlarını bulmayı denemektedir. Çünkü, hiperspektral görüntüde çoğu sürekli dalga boyu bantları birbirleriyle yüksek dereceden ilişkilidir [141]. En çok ayırt edici bantları seçen çeşitli bant seçim yaklaşımları vardır. Bu çalışmada [126] ‘daki bant seçim yaklaşımı referans olarak alınmıştır.

3.2.1.1. Spektral bölge karışım giderimi (Spectral zone unmixing - SZU)

Somers vd. [126] spektral değişkenlik için alt-piksel bolluk değeri tahminleme doğruluğunu artıran otomatik dalga boyu bandı seçimi protokolü sunmuşlardır. SZU yaklaşımı hızlı ve hesaplama olarak etkin ve senaryodan bağımsızdır. SZU’da bolluk değeri tahminlemesini artıran spektral özellikler SMA’da kullanılmaktadır. ISI değeri son eleman sınıfı içindeki spektral değişkenlik ile son eleman sınıfları arasındaki spektral değişkenlik oranı olarak tanımlanmaktadır [126]. ISI hesaplamasının kullanıldığı yaklaşımlar spektral değişkenlik problemini azaltmaktadır.

3.2.1.2. Hiyerarşik bölütleme

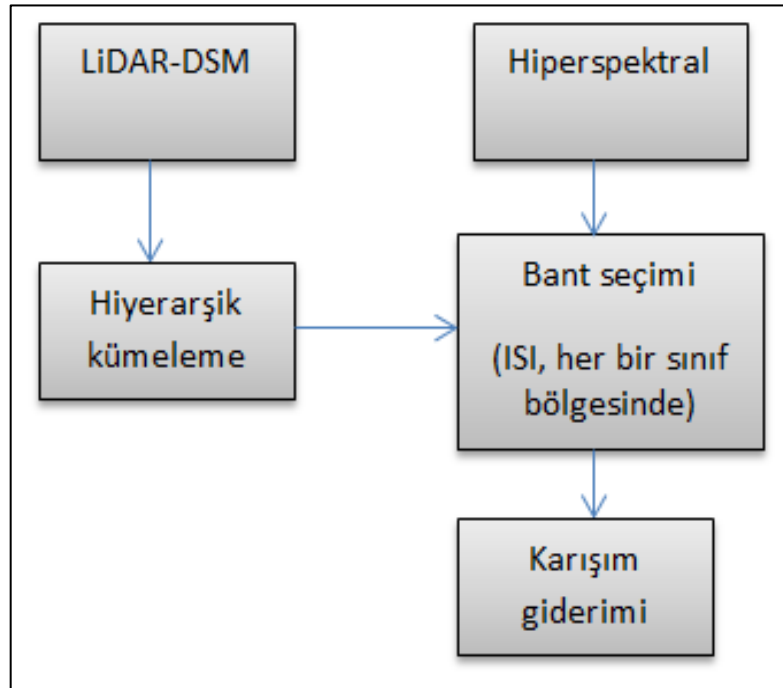
Tezin bu bölümünde, BPT [63] hiperspektral görüntünün hiyerarşik olarak bölütlenmesi amacıyla kullanılmıştır. BPT rekürsif bölge birleştirme yaklaşımıdır ve

hiyerarşik olarak yapılandırılmış bölgeler kümesini görüntünün anlamsal içeriğini ifade etmek için kullanmaktadır.

3.2.1.3. Sunulan yaklaşım

Tezin bu bölümünde, yeni bir yaklaşım önerilmiştir. DSM bilgisi spektral değişkenliğe karşı gürbüz olduğu için LiDAR-DSM bilgisi hiperspektral görüntüden özellik çıkarımı aşamasında DSM üzerinde bölütleme gerçekleştirilerek kullanılmıştır. Piksellerin bolluk değeri tahminlemesi bant seçimi prosedürü gerçekleştirilerek artırılabilir. Dolayısıyla bir alt uzaya yansıtma işlemi gerçekleştirilmeden, DSM yardımıyla hiperspektral görüntü üzerinde boyut indirgeme işlemi gerçekleştirilmiştir. Sunulan strateji hiperspektral görüntünün DSM yardımıyla bölgeye dayalı ifadesi olarak yorumlanabilmektedir.

Sunulan yaklaşımda bolluk değeri tahminlemesi için son eleman spektral bilgisi, fakat bölütleme için yükseklik bilgisi kullanılmıştır. Öncelikle DSM üzerinde bölütleme gerçekleştirilerek her bir bölütlenmiş bölge için bu bölgelere karşılık gelen piksel spektraller arasında ISI değeri hesaplanmıştır. Yapılan deneyler sonucunda elde edilen eşik değeri belirleme ile belli bir ISI değerine sahip olan bantlar SMA işlemi için seçilmiştir.



Şekil 3.1. Sunulan yaklaşımın akış diyagramı.

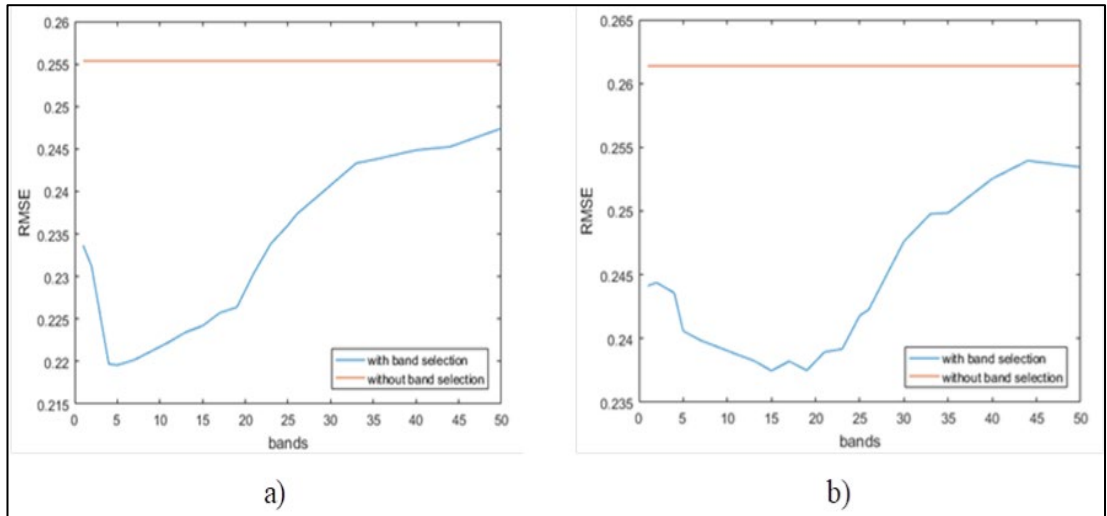
3.2.2. Deneysel sonuçlar

Deneysel sonuçlar sentetik veri seti üzerinde gerçekleştirilmiştir. Bu sentetik veri seti simule edilmiş hiperspektral görüntü ve simule edilmiş DSM ölçümlerinden oluşmaktadır. Bu deney için Birleşik Eyaletler Geolojik Araştırma Spektral Kütüphanesi'nden (United States Geological Survey spectral library) $M = 5$ tane son eleman seçilmiştir. Her bir son eleman spektrumu $L = 224$ spektral banttandır. Hiperspektral veri LKM'ye göre, 20 dB SNR beyaz Gaussian gürültüsü uygulanarak elde edilmiştir. Sentetik Veri Seti üzerinde yapılan deneysel çalışmaların sayısal sonuçları aşağıdaki Tablo 3.2.'de sunulmuştur.

Tablo 3.2. Önerilen yaklaşımın RMSE değeri.

Veri	RMSE	
	General	Proposed
Simulated	0,2581	0,2204

Tablo 3.2. incelendiğinde, LiDAR verisi yardımıyla spektral değişkenliğin azaltılabileceği sonucu elde edilmektedir. LiDAR verisi kullanılarak, daha iyi bolluk değeri tahminlemesi elde edildiği görülmektedir. Şekil 3.2.'de ise, gürültü eklenmemiş ve gürültü eklenmiş veri üzerinde spektral değişkenliğin hangi oranda azaltılabildiği karşılaştırmalı olarak görülebilmektedir.



Şekil 3.2. a)'da, yaklaşık olarak 5 tane bant seçimi spektral değişkenliği en iyi şekilde azaltırken, b)'de ise, 30B şeklinde gürültü eklenmiş veride yaklaşık olarak 5 tane bant seçiminin yeterli olmadığı daha iyi bolluk değeri tahminlemesi ve dolayısıyla, spektral değişkenliğin azaltılması için daha fazla bant sayısına ihtiyaç duyulduğu dikkati çekmektedir.

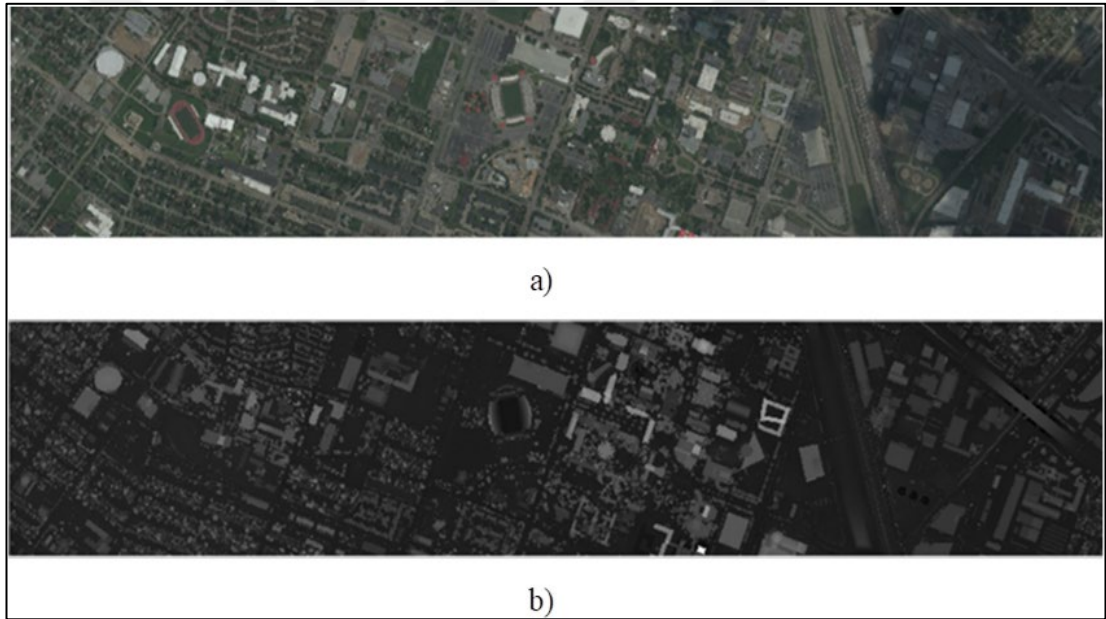
3.3. Vargılar

Tezin bu bölümünde, spektral değişkenliği azaltabilecek etkin bir yaklaşım sunulmuştur. Bunun için, etkili bir SMA için özellik seçim tekniği uygulanmıştır. Sınıf içi spektral değişkenliği azaltarak karışım giderimi ve sınıflandırma probleminin üstesinden gelen etkili bir yaklaşım sunulmuştur. Tablo 3.2. yakından incelendiğinde daha iyi RMSE sonuçları elde edilmektedir. Spektral değişkenliği azaltabilmek için, hiperspektral veri üzerinde farklı bant seçimi yaklaşımları LiDAR verisi kullanılarak gerçekleştirilebilir. Elde edilen sonuçlar daha sonra gerçekleştirilebilecek hedef takibi, sınıflandırma gibi araştırmalara öncülük edebilecek niteliktedir.

4. SONUÇLAR VE ÖNERİLER


4.1. PAN-HS ya da LiDAR-HS Verilerini Kullanarak Spektral Değişkenliğin Azaltılmasının Karşılaştırılması

Tezin bu bölümünde PAN-HS ya da LiDAR-HS verilerini kullanarak spektral değişkenliğin azaltılmasının karşılaştırılması gerçekleştirilmektedir. Deneyler süresince gerçek veri olan ‘2013 IEEE GRSS Data Fusion Contest’ veri setleri alınmıştır. Bu veri setinin hiperspektral ve LiDAR görüntüleri Şekil 4.1.’de görülmektedir.



Şekil 4.1. 2013 IEEE GRSS Veri Kaynaştırması Yarışması Houston University veri seti a) HS'nin RGB görüntüsü b) LiDAR-DSM görüntüsü.

Yukarıdaki Houston Üniversitesi veri setinin bir alt kümesi olan 231 x 251 boyutlarında stadyum, yollar, binalar ve yeşil alanları da içeren aşağıdaki alt görüntü seçilmiştir. Houston Üniversitesi veri setinin bir alt kümesi olan 231 x 251 boyutlarında bir alt görüntü seçilmiştir. Bu alt görüntüde stadyum, yollar, binalar ve yeşil alanlara bulunmaktadır. Bu bölge, yüksek frekans değerleri ve düzgün bölgeleri de içerdiği için tercih edilmiştir. Şekil 4.2.’de seçilen [59 40 23] bantlarını içeren RGB ve LiDAR görüntüsü gösterilmektedir.



Şekil 4.2. 2013 IEEE GRSS Veri Kaynaştırması Yarışması Houston Üniversitesi veri setinden seçilen alt görüntü a) HS'nin RGB görüntüsü b) DSM görüntüsü.

4.2. Deneysel Çalışmalar

Deneysel çalışmalar gerçekleştirilirken öncelikle, sentetik veri setleri oluşturulmuştur. Sentetik veri setleri performans karşılaştırması için oluşturulmuştur. Hiperspektral sentetik veri seti referans görüntüsünün iki kez alt-örneklem ve interp23tap süzgeci kullanılarak üst-örneklem yapılarak Gaussian alçak geçiren süzgeçinden geçirilerek oluşturulmuştur [60]. Pankromatik sentetik görüntü ise, 400-700 nm. görsel aralıkta hiperspektral bantlarının ortalaması olarak alınmıştır. Bu sentetik pankromatik görüntüsü ve DSM üzerinde BPT bölütleme yaklaşımı uygulanmıştır. Hem pankromatik hem de DSM bölütleme işlemi sonucunda elde edilen her bir bölüt için, bu bölüte karşılık gelen hiperspektral görüntüdeki piksel spektraller üzerinde SZU yaklaşımı uygulanmıştır. Bu sentetik görüntüler SZU yaklaşımı için girdi olarak kullanılmış ve elde edilen çıktı görüntüsü original referans görüntü ile karşılaştırılmıştır. Buna göre, elde edilen sayısal sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 4.1. PAN-HS ve LiDAR-HS karşılaştırması.

	RMSE
HS-PAN	1627,8
HS-LiDAR	1630,8

Tablo 4.1.'deki sonuçlar incelendiğinde hiperspektral görüntünün uzamsal çözünürlüğünün artırılması için pankromatik görüntü yerine LiDAR görüntüden yararlanmak daha doğru bir yaklaşım olacaktır. Çünkü, pankromatik görüntü LiDAR görüntüsü ile karşılaştırıldığında spektral değişkenlikten etkilenmektedir.

4.3. Vargılar

Çevrenin ve dünya yüzeyindeki kaynakların hiperspektral görüntüler ile algılanması ve yorumlanması değişim tespiti, sınıflandırma ve tespit için oldukça önemlidir. Bu tezin temel amacı hiperspektral görüntülerinin düşük uzamsal çözünürlük problemiyle ilgilenmek ve çeşitli yaklaşımlarla hiperspektral görüntülerinin uzamsal çözünürlüğünü artırmaktır. Bu durum ilk olarak pankeskinleştirme problemi olarak ele alınmış ve çeşitli pankeskinleştirme yaklaşımları RASAT, GÖKTÜRK-2 ve AVIRIS alıcılarının verilerine uygulanmıştır. İkinci olarak, AVIRIS alıcısından elde edilen Indian Pines, Moffett ve Cuprite ile HYDICE alıcısından elde edilen Washington, D.C görüntüleri üzerinde PAN - HS pankeskinleştirme ve MS - HS veri kaynaştırması, karışım giderimi temelli yaklaşımlardan birçoğu kullanılarak gerçekleştirilmiştir. Ayrıca HS-MS görüntüleri üzerinde Veri Kaynaştırma için Eşlemeli Negatif Olmayan Matris Faktörizasyonu (Coupled Non-Negative Matrix Factorization - CNMF) [82] Karışım Giderimi Yaklaşımının üzerine bazı kısıtlamalar eklenerek veri kaynaştırma başarımları artırılmıştır. Yapılan deneyler, görsel sonuçlar ve tablo şeklinde ilgili bölümün sonunda sunulmuştur.

Daha sonra, karışım giderimi problemi olarak CNMF [82] yaklaşımına düzenleyici terimler ekleyerek, MS-HS görüntü kaynaştırmasında hiperspektral görüntünün uzamsal çözünürlüğünün artırımı gerçekleştirimi yapılmıştır. Son olarak ise, HS-LiDAR verilerinin veri kaynaştırması incelenmiştir. Bu tez hiperspektral karışım giderimi için geleneksel en küçük kareler yaklaşımından farklı olan, teknikleri denemeyi ve böylece hiperspektral görüntülerde uzamsal çözünürlüğü artırmayı hedeflemiştir. Kaynaştırılmış görüntülerde konumsal detayın iyileştirilmesi ve spektral içeriğin korunması birlikte ele alındığında ise, daha iyi performans gösterdiği görülmektedir.

Bu amaçla, tez kapsamında ilk olarak pankeskinleştirme yaklaşımlarından olan bileşen ekleme, çok çözünürlüklü analiz, hybrid ve varyasyonel yaklaşımlarla

beraber hiperspektral pankeskinleştirmeye özgü olan Bayesian ve Matrix Factorization yaklaşımları incelenmiştir. Karışım giderimi bilgisi kullanılarak MS-HS görüntü kaynaştırma başarımlarının artırılması hedeflenmektedir. Bu nedenle, bu tez MS-HS görüntü kaynaştırmayı en iyi uzamsal çözünürlükle sağlayan gelişmeleri inceleme ve katkıda bulunmayı amaçlamıştır. Ayrıca, Bayesian, CNMF, HySure, FUSE, MAP/SMM, Akhtar ve Lanaras'ın yaklaşımları ayrıntılı bir şekilde teorik olarak incelenmiş, bunlardan sadece Bayesian, CNMF ve HySure yaklaşımları HS-PAN verileri üzerinde test edilmiştir.

İkinci adım olarak, karışım giderimi bilgisi kullanılarak MS-HS görüntü kaynaştırma başarımlarının artırılması hedeflenmiştir. Bu nedenle, L_1 -NMF, $L_{1/2}$ -NMF, GLNMF, MLNMF ve DGC-NMF TV-GNMF, EAC-NMF ve WNMF karışım giderimi yaklaşımları, iteratif olarak veri kaynaştırma problemini çözen [82]'deki çalışmaya eklenerek MS-HS veri kaynaştırma performansının artırılması hedeflenmektedir. Ancak, sadece $L_{1/2}$ -CNMF, GLCNMF ve WCNMF kısıtlamaları için elde edilen başarımlar sonuçları CNMF yaklaşımının performansını geçmektedir. Fakat, L_1 -NMF, MLNMF ve DGC-NMF yaklaşımları iyi bir başarımlar vermemektedir. Bu iyi başarımlar vermeyen yaklaşımlar üzerinde ayrıntılı bir lamdha optimizasyonu yapılması gerekebilmektedir.

Tezin üçüncü bölümünde, HS-LiDAR verilerinin veri kaynaştırması incelenmiştir. Bu tezde hiper-graf düzenleyicisine dayalı hiperspektral karışım giderimi LiDAR verisi kullanılarak gerçekleştirilmiştir. Yeni hiper-graf düzenleyicisini eklemek daha iyi bolluk değeri tahminlemesine sebep olmaktadır. Ayrıca LiDAR verisi yardımıyla hiperspektral görüntülerde spektral değişkenliğin azaltılması literatürde ilk defa uygulanmıştır.

Bu tezin diğer tezlerden farkı olarak, altı temel çalışma sayılabilmektedir: Bunlar;

- RASAT ve GÖKTÜRK-2 Uydu görüntüleri üzerinde en kapsamlı pankeskinleştirme yaklaşımlarının ayrıntılı analizi yapılmıştır.
- Literatürde ilk defa GÖKTÜRK-2 uydu görüntülerinin MTF ve SRF değerleri kullanılmıştır.
- Süperpiksel kümeleme yaklaşımı literatürde ilk defa hiperspektral pankeskinleştirme yaklaşımından önce kullanılmıştır.

- CNMF [82]'ye yeni kısıtlamalar eklenerek başarımları artırma çalışması gerçekleştirilmiştir.
- Hiper-graf düzenleyicisine dayalı hiperspektral karışım giderimi LiDAR verisi kullanılarak gerçekleştirilmiştir ve böylece daha iyi bolluk değeri tahminlemesi elde edilmiştir.
- Sınıf içi spektral değişkenliği azaltarak karışım giderimi ve sınıflandırma probleminin üstesinden gelen etkili bir yaklaşım sunulmuştur.

Kısaca, gerçekleştirilen tez çalışmasının literatüre katkısı şu şekilde özetlenebilmektedir:

- i) RASAT ve GÖKTÜRK-2 Uydu görüntüleri üzerinde en kapsamlı pankeskinleştirme yaklaşımlarının ayrıntılı analizi yapılmıştır.
- ii) Literatürde ilk defa GÖKTÜRK-2 uydu görüntülerinin MTF ve SRF değerleri kullanılmıştır.
- iii) Süperpiksel kümeleme yaklaşımı literatürde ilk defa hiperspektral pankeskinleştirme yaklaşımından önce kullanılmıştır.
- iv) CNMF [82]'ye yeni kısıtlamalar eklenerek karışım giderimi başarımları artırma çalışması gerçekleştirilmiştir.
- v) Hiper-graf düzenleyicisine dayalı hiperspektral karışım giderimi Light Detection And Ranging (LiDAR) verisi kullanılarak gerçekleştirilmiştir ve böylece daha iyi bolluk değeri tahminlemesi elde edilmiştir.
- vi) Sınıf içi spektral değişkenliği azaltarak karışım giderimi probleminin üstesinden gelen etkili bir yaklaşım sunulmuştur.

KAYNAKLAR

- [1] Bioucas-Dias J. M., Plaza A., Dobigeon N., Parente M., Du Q., Gader P., Chanussot J., Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5** (2), 354-379.
- [2] Gerçek D., Çeşmeci D., Güllü M.K., Ertürk A., Ertürk S., Hiperspektral Görüntüleme ve Görüntü İşlemenin Bugünü, Yakın Geleceği ve Mevcut Araştırma Eğilimleri, *XYZ Dergisi*, sayı 18, Mart 2013.
- [3] He L., Rao Y., Li J., Chanussot J., Plaza A., Zhu J., Li B., Pansharpening via Detail Injection Based Convolutional Neural Networks, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, **12**(4), 1-17.
- [4] GISAT, <http://www.gisat.cz/content/cz/sluzby/zpracovani-dat/pan-sharpening> (Ziyaret tarihi: 20 Ağustos 2019).
- [5] Garzelli A., Nencini F., Alparone L., Aiazzi B. and Baronti S., Pansharpening of multispectral images: a critical review and comparison, *IEEE International Geoscience and Remote Sensing Symposium IGARSS*, AK, USA, 20-24 Sept. 2004.
- [6] Claire T., Thierry R., Lucien W. and Jocelyn C., Synthesis of Multispectral Images to High Spatial Resolution: A Critical Review of Fusion Methods Based on Remote Sensing Physics, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(5), 1301-1312.
- [7] Jinghui Y., Jixian Z., Haitao L., Yushan S. and Pengxian P., Pixel level fusion methods for remote sensing Images: A current review. *ISPRS TC VII Symposium, IAPRS*, Vienna, Austria, 5-7 July 2010.
- [8] Amro I., Mateos J., Vega M., Molina R. and Katsaggelos A. K., A survey of classical methods and new trends in pansharpening of multispectral images, *Journal on Advances in Signal Processing EURASIP*, 2011, **79**, 1-22.
- [9] Aiazzi B., Alparone L., Baronti S., Garzelli A., and Selva M., *25 years of pansharpening: A critical review and new developments*, in *Signal Image Processing for Remote Sensing*, 2nd ed., C. H. Chen, Ed. Boca Raton, FL: CRC Press, 2011.
- [10] Yun Z. and Rakesh M. K., A review and comparison of commercially available pan-sharpening techniques for high resolution satellite image fusion, *IEEE International Geoscience and Remote Sensing Symposium*, Munich, Germany, 22-27 July 2012.

- [11] Javier M., Medina A. and Eugenio F., Evaluation of Spatial and Spectral Effectiveness of Pixel-Level Fusion Techniques, *IEEE Geoscience and Remote Sensing Letters*, 2013, **10**(3), 432 – 436.
- [12] Vivone G., Restaino R., Licciardi G., Mura M. D., Chanussot J., MultiResolution Analysis and Component Substitution techniques for hyperspectral Pansharpening, *IEEE Geoscience and Remote Sensing Symposium*, Quebec City, QC, Canada, 13-18 July 2014.
- [13] Gemine V., Luciano A., Jocelyn C., Mauro D. M., Andrea G., Giorgio L. A., Rocco R. and Lucien W., A Critical Comparison Among Pansharpening Algorithms, *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(5), 2565-2586.
- [14] Loncan L., Almeida L. B. de, Bioucas-Dias J. M., Briottet X., Chanussot J., Dobigeon N., Fabre S., Liao W., Licciardi G. A., Simoes M., Tournet J., Veganzones M. A., Vivone G., Wei Q. and Naoto Yokoya N., Hyperspectral Pansharpening: A Review. *IEEE Geoscience and Remote Sensing Magazine*. 2015, **3**(3), 27-46.
- [15] Vaiopoulos A. D. and Karantzalos K., Pansharpening on the narrow VNIR and SWIR spectral bands of Sentinel-2, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B7, XXIII ISPRS Congress*, 2016.
- [16] Berné O., Helens A., Pilleri P., Joblin C., Non-negative matrix factorization pansharpening of hyperspectral data: An application to mid-infrared astronomy, *2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, Reykjavik, Iceland, 14-16 June 2010.
- [17] Laetitia L., Luis B. de A., Jose M. B., Xavier B., Jocelyn C., Nicolas D., Sophie F., Wenzhi L., Giorgio A. L., Miguel S., Jean-Yves T., Miguel A. V., Gemine V., Qi W. and Naoto Y., Hyperspectral Pansharpening: A Review, *IEEE Geoscience and Remote Sensing Magazine*, 2015, **3**(3), 27-46.
- [18] Selva M., Aiazzi B., Butera F., Chiarantini L., Baronti S., Hyper-Sharpener: A First Approach on SIM-GA Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, **8**(6), 3008-3024.
- [19] Chiru G., Yunsong L., Lijiao J., Keyan W., Subspace selection for hyperspectral pansharpening using sparse unmixing, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, China, 10-15 July 2016.
- [20] Mura M. D., Vivone G., Restaino R., Adesso P., Chanussot J., Global and local Gram-Schmidt methods for hyperspectral pansharpening, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Milan, Italy, 26-31 July 2015.

- [21] Garzelli A., Capobianco L., Alparone L., Aiazzi B., Baronti S., Selva M., Hyperspectral pansharpening based on modulation of pixel spectra, *2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, Reykjavik, Iceland, 14-16 June 2010.
- [22] Khan M. M., Chanussot J., Alparone L., Hyperspectral pansharpening using QNR optimization constraint, *First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, Grenoble, France, 26-28 Aug. 2009.
- [23] Picone D., Restaino R., Vivone G., Addesso P., Chanussot J., Pansharpening of hyperspectral images: Exploiting data acquired by multiple platforms, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, China, 10-15 July 2016.
- [24] Xu Q., Zhang Y., Li B., Hyperspectral image pansharpening for photo analysis by ratio enhancement, *Third International Workshop on Earth Observation and Remote Sensing Applications (EORSA)*, Changsha, China, 11-14 June 2014.
- [25] Palubinskas G., Pan-Sharpener Approaches based on Unmixing of Multispectral Remote Sensing Imagery, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol.XLI-B7XXIII ISPRS Congress, Prague, Czech Republic, 2016.
- [26] Picone D., Restaino R., Vivone G., Paolo Addesso P., Mura M.D., and Chanussot J., Band Assignment Approaches for Hyperspectral Sharpening, *IEEE Geoscience and Remote Sensing Letters*, 2017, **14**(5), 739-743.
- [27] Teke M., Seyfioğlu M.S., Ağçal A. and Gürbüz S. Z., RASAT Uydu görüntülerinin optimal pankeskinleştirilmesi, *IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*, Trabzon, 23-25 Nisan 2014.
- [28] Teke M., Satellite Image processing Workflow for RASAT and Göktürk-2. *Journal of Aeronautics and Space Technologies*. 2016, **9**(1), 1-13.
- [29] Ozendi M., Topan H., Cam A. and Bayık Ç., RASAT ve Göktürk-2 Görüntülerinden pankeskinleştirilmiş görüntü üretimi ve kalite değerlendirmesi. 6. *Uzaktan Algılama CBS Sempozyumu (UZAL-CBS 2016)*, 2016.
- [30] Ozendi M., Topan H., Cam A. and Bayık Ç., Pan sharpening quality investigation of Turkish in operation remote sensing satellites: Applications with RASAT and Göktürk-2 Images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W1, 2016 3rd International GeoAdvances Workshop*, 16-17 Oct. 2016.

- [31] R. K p u, M. Teke, and A.  abuk, RASAT ve G kt rk-2 g r nt lerinin ortorektifikasyon bařarımına referans ve sayısal y kseklik modeli seiminin etkisi, 5. *Uzaktan Algılama CBS Sempozyumu (UZAL-CBS)*, İstanbul, 14-17 Ekim 2014.
- [32] M. Teke, C. Demirkesen, O. Halilođlu and E.  mre, G kt rk-2 Uydusunun Bađıl ve Mutlak  apraz Radyometrik Kalibrasyonu, *Harita Dergisi*, 2016,**155**, 32-52.
- [33] V. O. Atak, M. Erdođan and A. Yılmaz, G kt rk-2 Uydu G r nt  Testleri. (GOKTURK-2 Satellite Imagery Tests), *Harita Dergisi*, 2015, **153**,18-33.
- [34] M. Ozendi, H. Topan, A. Cam and  . Bayık, Pan sharpening quality investigation of Turkish in operation remote sensing satellites: Applications with RASAT and G kt rk-2 Images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII2/W1, 3rd International GeoAdvances Workshop*, 2016.
- [35] O. B. Bakiođlu, H. Topan, M.  zendi, and A. Cam, Pansharpening of RASAT and G KT RK-2 Images via High Pass Filter, *ISPRS – The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-4/W6*, 2017.
- [36] Kahraman S., and Ert rk A., A Comprehensive Review of Pansharpening Algorithms for G KT RK-2 Satellite Images, *Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-4/W4, 4th International GeoAdvances Workshop*, Safranbolu, 14–15 October 2017.
- [37] Dou W., Chen Y., Li X., and Sui D. Z., A general framework for component substitution image fusion: An implementation using the fast image fusion method, *Computational Geoscience*, 2007, **33**(2), 219–228.
- [38] Te-Ming T., Shun-Chi S., Hsuen-Chyun S. and Ping .S H., A new look at IHS-like image fusion methods, *Information Fusion*, 2001, **2**(3), 177-186,
- [39] Alan R. G., Anne B. K. and Richard E. W., Color enhancement of highly correlated images—II. Channel ratio and “chromaticity” transform techniques, *Remote Sensing Env.*, 1987, **22**(3), 343-365.
- [40] Pat S. C., Stuart C. and Jeffrey A., Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic, *Photogramm. Eng. Remote Sensing*, 1991, **57**(3), 295–303.
- [41] Laben C.A. and Brower B.V., Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening, *U.S. Patent 6 011 875*, 2000.
- [42] Chris P., Michael D., Fabio P. and Scott S., WorldView-2 pan sharpening, *ASPRS Annual Conference*, San Diego, California, 26-30 April 2010.

- [43] Tu T., Hsu C., Tu P., Lee C., An Adjustable Pan-Sharpening Approach for IKONOS/QuickBird/GeoEye-1/WorldView-2 Imagery, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5**(1), 125–134.
- [44] Ute. G., Pushkar P. S., and Derrold W. H., Optimizing the high-pass filter addition technique for image fusion, *Photogramm. Eng. Remote Sening.*, 2008, **74**(9), 1107-1118.
- [45] Zhang, Y., A new merging method and its spectral and spatial effects, *International Journal of Remote Sensing*, 1999, **20**(10), 2003–2014.
- [46] Choi J., Yu K., and Kim Y., A New Adaptive Component-Substitution-Based Satellite Image Fusion by Using Partial Replacement, *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(1), 295–309.
- [47] B. Aiazzi, L. Alparone, S. Baronti, A. Garzelli and M. Selva, MTF tailored multi scale fusion of high resolution MS and PAN imagery, *Photogrammetric Engineering & Remote Sensing*, 2006, **72**(5), 591-596.
- [48] A. Garzelli, F. Nencini, L. Capobianco, Optimal MMSE Pan Sharpening of Very High Resolution Multispectral Images, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(1), 228-236.
- [49] Vivone G., Alparone L., Chanussot J., Mura M. D., Garzelli A., Licciardi G. A., Restaino R., Wald L., A Critical Comparison Among Pansharpening Algorithms, *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(5), 2565-2586.
- [50] Thomas C., Ranchin T., Wald L. and Chanussot J., Synthesis of Multispectral Images to High Spatial Resolution: A Critical Review of Fusion Methods Based on Remote Sensing Physics. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(5), 1301-1312.
- [51] Baronti S., Aiazzi B., Selva M., Garzelli A., Alparone L., A theoretical analysis of the effects of aliasing and misregistration on pansharpened imagery, *IEEE Journal of Selected Topics in Signal Processing*, 2011, **5**(3), 446-453.
- [52] Liu J. G., Smoothing filter-based intensity modulation: A spectral preserve image fusion technique for improving spatial details, *International Journal of Remote Sensing*, 2000, **21**(18), 3461–3472.
- [53] Yokoya N., Mayumi N., and Iwasaki A., Cross-calibration for data fusion of EO-1 / Hyperion and Terra / ASTER, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, **6**(2), 419-426.
- [54] Fionn M., Jean-Lue S. and Albert B., Image restoration with noise suppression using a multiresolution support, *Astronomy and Astrophysics supplement series*, 1995, **112**, 179-189.

- [55] Nunez J., Otazu X., Octavi Fors Oc., Prades A., Pala V., and R Arbiol R., Multiresolution - Based Image Fusion with Additive Wavelet Decomposition, *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37**(3), 1204-1211.
- [56] Otazu X., Gonzalez-Audicana M., Fors O., Nunez J., Introduction of sensor spectral response into image fusion methods. Application to wavelet-based methods, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(10), 2376-2385.
- [57] Stefano B., Andrea C., Franco L. and Luciano A., Context-driven differential encoding of an enhanced image pyramid, *Signal Processing Image Communication*, 1994, **6**, 463-469.
- [58] Bruno A., Stefano B., Luciano A. and Massimo S., Advantages of Laplacian pyramids over "à trous" wavelet transforms for pansharpening of multispectral images, *Proceedings of SPIE-The International Society for Optical Engineering*, XVIII, 853704, 8 November 2012.
- [59] Aiazzi, B., Alparone, L., Baronti, S., Cappellini, V., Carl`a, R., and Mortelli, L., A Laplacian pyramid with rational scale factor for multisensor image data fusion, Proc. Int. Conf. on Sampling Theory and Applications Samp TA 97, 1997.
- [60] Aiazzi B., Alparone L., Baronti S., and Garzelli A., Context-driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis, *IEEE Transactions on Geoscience and Remote Sensing*, 2002. **40**(10), 2300-2312.
- [61] Aiazzi B., Alparone L., Baronti S., Garzelli A. and Selva M., MTF-tailored multiscale fusion of high resolution MS and Pan imagery, *Photogramm. Eng. Remote Sens.*, 2006. **72**(5), 591–596.
- [62] Lee J. and Lee C., Fast and efficient panchromatic sharpening, *IEEE Trans. Geosci. Remote Sens.*, 2010, **48**(1), 155–163.
- [63] Stefano B., Bruno A., Massimo S., Andrea G., Luciano A., A theoretical analysis of the effects of aliasing and misregistration on pansharpened imagery, *IEEE Journal of Selected Topics in Signal Processing*, 2011, **5**(3), 446-453.
- [64] Chibani Y. and Houacine A., The joint use of IHS transform and redundant wavelet decomposition for fusing multispectral and panchromatic images, *International Journal of Remote Sensing*, 2002, **23**(18), 3821–3833.
- [65] Klonus S. and Ehlers M., Image fusion using the Ehlers spectral characteristics preservation algorithm, *GIScience & Remote Sensing*, 2007, **44**(2), 93-116.

- [66] W. Liao, X. Huang, F. V. Coillie, S. Gautama, A. Pizurica, W. Philips, H. Liu, T. Zhu, M. Shimoni, G. Moser, and D. Tuia, Processing of multiresolution thermal hyperspectral and digital color data: Outcome of the 2014 IEEE GRSS data fusion contest, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, **8**(6), 2984–2996.
- [67] Baester C., Caselles V., IgualJoan L. and Rougé V., A variational model for P+XS image fusion, *International Journal of Computer Vision*, 2006, **69**(1), 43–58.
- [68] Alparone L., Aiazzi B., Baronti S., Garzelli A., Nencini F. and Selva M., Multispectral and panchromatic data fusion assessment without reference, *Photogrammetric Engineering & Remote Sensing*, Feb, 2008, **74**(2), 193-200.
- [69] <https://gezgin.gov.tr> (Ziyaret tarihi: 21.10.2018).
- [70] Açıkgöz S., Teke M., Kutbay K. U. and Hardalaç F., Performance evaluation of pansharpening methods on GPU for RASAT images, *7th International Conference on Recent Advances in Space Technologies (RAST)*, Istanbul, Turkey, 16-19 June 2015.
- [71] L. Alparone, A. Garzelli, and G. Vivone, Intersensor Statistical Matching for Pansharpening: Theoretical Issues and Practical Solutions, *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(8), 4682 – 4695.
- [72] Yokoya N., <http://naotoyokoya.com/Research.html> (Ziyaret tarihi: 21.20.2019).
- [73] Boardman J. W., Kruse F. A., Green R. O., Mapping target signatures via partial unmixing of AVIRIS data, *Summaries of the Sixth JPL Airborne Earth Science Workshop, Pasadena, California, U.S.A., 4-8 March 1996*.
- [74] Winter M. E., N-FINDR: an algorithm for fast autonomous spectral endmember determination in hyperspectral data, *Imaging Spectrometry V, Proceeding of SPIE, Denver, Colorado, U.S.A., 27 October, 1999*.
- [75] Nascimento J. M. P., Dias J. M. B., Vertex component analysis: a fast algorithm to unmix hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(4), 898-910.
- [76] Chang C. I., Wu C., Liu W., and Ouyang Y. C., A growing method for simplex-based endmember extraction algorithms, *IEEE Transactions on Geoscience and Remote Sensing*, 2006, **44**(10), 2804–2819.
- [77] Heinz D. C. and Chang C.-I., Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39**(3), 529–545.

- [78] Jutten, C. and Héroult, J., Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture. *Signal Processing*, 1991, **24**, 1–10.
- [79] Comon, P. Independent component analysis - a new concept? *Signal Processing*, 1994, **36**, 287–314.
- [80] Alter O, Brown PO, Botstein D. Singular value decomposition for genome-wide expression data processing and modeling. *Proc Natl Acad Sci U S A*, 2000, **97**, 1-6.
- [81] Lee D. D. and Seung H. S., Algorithms for non-negative matrix factorization, in *Advances in Neural Information Processing Systems*. Cambridge, MA: MIT Press, 2001, 556–562.
- [82] Yokoya N., Yairi T., and Iwasaki A., Coupled Nonnegative Matrix Factorization Unmixing for Hyperspectral and Multispectral Data Fusion, *IEEE Transactions on Geoscience and remote sensing*, 2012, **50**(2), 528-537.
- [83] Yokoya N., Yairi T., Iwasaki A., Coupled non-negative matrix factorization (CNMF) for hyperspectral and multispectral data fusion: Application to pasture classification, *IEEE International Geoscience and Remote Sensing Symposium*, Vancouver, BC, Canada, 24-29 July 2011.
- [84] Wei Q., Bioucas-Dias J., Dobigeon N., Tourneret J.Y., Chen M., Godsill S., ,Multiband Image Fusion Based on Spectral Unmixing, *IEEE Transactions on Geoscience and Remote Sensing*, 2016, **54**(12), 7236 - 7249.
- [85] Wei Q., Dobigeon N., Tourneret J. Y., Fast Fusion of Multi-Band Images Based on Solving a Sylvester Equation, *IEEE Transactions on Image Processing*, 2015, **24**(11), 4109 - 4121.
- [86] Simões M., Dias J. B., Almeida L. B., and Chanussot J., A Convex Formulation for Hyperspectral Image, Superresolution via Subspace-Based Regularization, *IEEE Transactions on Geoscience and remote sensing*, 2015, **53**(6).
- [87] D.P.Bertsekas, *Nonlinear Programming*, Belmont, MA, USA: Athena Scientific, 1999, 273.
- [88] Eismann M. T., Hardie R. C., 2004, Application of the stochastic mixing model to hyperspectral resolution enhancement, *IEEE Transactions on Geoscience and Remote Sensing*, **42**(9), 1924-1933.
- [89] Akhtar N., Shafait F. and Mian A., Sparse Spatio-spectral Representation for Hyperspectral Image Super-Resolution, *European Conference on Computer Vision, ECCV'14*, Springer, Cham, 2014.

- [90] Bioucas-Dias J. M., Variable splitting augmented Lagrangian approach to linear spectral unmixing, *IEEE First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS'2009)*, Grenoble, France, 26-28 Aug. 2009.
- [91] Lanaras C., Baltasavias E. and Schindler K., Hyperspectral Super-resolution by coupled spectral unmixing, *IEEE International Conference on Computer Vision*, Santiago, Chile, 7-13 Dec. 2015.
- [92] G. H. Ball, D. J. Hall, ISODATA, A novel method of data analysis and pattern classification, Stanford University, AD- 699616, 1965, 1-61.
- [93] L. Fang, S. Shutao, W. Duan, J. Ren, and J. A. Benediktson, Classification of Hyperspectral Images by Exploiting Spectral Spatial Information of Superpixel via Multiple Kernel, *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(12), 6663-6674.
- [94] P. Salembier and L. Garrido, Binary partition tree as an efficient representation for image processing, segmentation, and information retrieval, *IEEE Trans. Image Process.*, Apr. 2000, **9**(4), 561–576.
- [95] Mura M. D., Vivone G., Restaino R., Addesso P., Chanussot J., Global and local Gram-Schmidt methods for hyperspectral pansharpening, *IEEE International Geoscience and Remote Sensing Symposium*, Milan, Italy, 26-31 July 2015.
- [96] Restaino R., Dalla Mura M., Vivone G., Jocelyn Chanussot J., Context-Adaptive Pansharpening Based on Image Segmentation, *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(2), 753-766.
- [97] Rekha P., Yasha M., and Shirur J., Towards a better hybrid pansharpening algorithm for high resolution satellite imagery, *International Conference on Communications and Signal Processing (ICCSP)*, Melmaruvathur, India, 2-4 April 2015.
- [98] Aiazzi B., Baronti S., Lotti F., Selva M., A Comparison Between Global and Context-Adaptive Pansharpening of Multispectral Images, *IEEE Geoscience and Remote Sensing Letters*, 2009, **6**(2), 302-306.
- [99] Iordache M.-D., Bioucas-Dias J., and Plaza A., Sparse unmixing of hyperspectral data, *IEEE Trans. Geosci. Remote Sens.*, 2011, **49**(6), 2014-2039.
- [100] Qian Y., Jia S., Zhou J., and Robles-Kelly A., Hyperspectral Unmixing via $L_{1/2}$ Sparsity-Constrained Nonnegative Matrix Factorization, *Transactions on Geoscience and Remote Sensing*, 2011, **49**(11), 4282-4297.
- [101] Heinz D.C., I-Chang C., Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39** (3), 529-545.

- [102] Bioucas-Dias J. M., Nascimento J. M. P., Hyperspectral subspace identification, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(8), 2435-2445.
- [103] Hoyer P.O., Non-negative matrix factorization with sparseness constraints, *J. Mach. Learn. Res.*, 2004, **5**, 1457-1469.
- [104] Lu X., Wu H., Yuan Y., Yan P. and Li X., Manifold regularized sparse nmf for hyperspectral unmixing, *IEEE Transactions on Geoscience and Remote Sensing (TGRS)*, 2013, **51**(5), 2815–2826.
- [105] Zhu F., Wang Y., Xiang S., Fan B., and Pan C., Structured Sparse Method for Hyperspectral Unmixing, *ISPRS Journal of Photogrammetry and remote sensing*, 2014, **88**, 101-118.
- [106] Rajabi R., Ghassemian H., Spectral Unmixing of Hyperspectral Imagery Using Multilayer NMF, *IEEE Geoscience and Remote Sensing Letters*, 2015, **12**(1), 38 – 42.
- [107] Huang R., Li X., and Zhao L., Nonnegative matrix factorization with data-guided constraints, *Remote Sensing MDPI*, 2017, **9**(1074), 3- 22.
- [108] Otsu, N. A threshold selection method from gray-level higtograms. *IEEE Trans. Syst. Man Cybern.* 1979, **9**, 62-66.
- [109] Leng C., Chen Z., Cai G., Cheng I., Xiong Z., Tian J., Basu A., Total variation constrained graph regularized NMF for medical image registration, *IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP)*, Bordeaux, France, 11-12 July 2016.
- [110] Zhi T., Yang B., Chen Z., Wang B., Nonnegative matrix factorization with constraints on endmember and abundance for hyperspectral unmixing, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, USA, 23-28 July 2017.
- [111] Liu J., Zhang J., Gao Y., Zhang C., Li Z., Enhancing Spectral Unmixing by Local Neighborhood Weights, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5**(5), 1545 – 1552.
- [112] Bruce C., Lawrence C., Ross N., Elizabeth M., Douglas M., Joel M., Jeffrey M., Kenneth R., Vuong L., Paul M., NASA Goddard’s LiDAR, hyperspectral and thermal (G-LiHT) airborne imager, *Remote Sens.*, Aug. 2013, **5**(8), 4045–4066.
- [113] Jenzri H., Frigui H., Gader P., Graph constrained multi-model unmixing using LIDAR information, *2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Gainesville, FL, USA, 26-28 June 2013.

- [114] Glenn T., Dranishnikov D., Gader P., Zare A., Subpixel target detection in hyperspectral imagery using piece-wise convex spatial-spectral unmixing, possibilistic and fuzzy clustering, and co-registered LiDAR, *IEEE International Geoscience and Remote Sensing Symposium – IGARSS*, Melbourne, VIC, Australia, 21-26 July 2013.
- [115] Uezato T., Fauvel M., Dobigeon N., Hyperspectral Image Unmixing With LiDAR Data-Aided Spatial Regularization, *IEEE Transactions on Geoscience and Remote Sensing*, , 2018, **56**(7), 4098-4108.
- [116] Matsuki T., Yokoya N., Iwasaki A., Hyperspectral Tree Species Classification of Japanese Complex Mixed Forest With the Aid of Lidar Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, **8**(5), 2177-2187.
- [117] Debes Ch., Merentitis A., Heremans R., Hahn J., Frangiadakis N., Van Kasteren T., Liao W., Bellens R., Pižurica A., Gautama S., Philips W., Prasad S., Du Q., Pacifici F., Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(6), 2405 - 2418.
- [118] Iordache M.-D., Bioucas-Dias J., and Plaza A., Total variation spatial regularization for sparse hyperspectral unmixing, *IEEE Trans. Geosci. Remote Sens.*, Nov. 2012, **50**(11), 4484–4502.
- [119] Wang W., Qian Y., Yan Tang Y., Hypergraph-Regularized Sparse NMF for Hyperspectral Unmixing, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, **9**(2), 681 – 694.
- [120] Agarwal S., Branson K., and Belongie S., Higher order learning with graphs, in *Proc. 23th Int. Conf. Mach. Learn.*, Pittsburgh, Pennsylvania, USA — June 25 - 29, 2006.
- [121] H. Yuan, Y. Yan Tang, Learning With Hypergraph for Hyperspectral Image Feature Extraction”, *IEEE Geoscience and Remote Sensing Letters*, 2015, **12**(8), 1695 – 1699,
- [122] Gao Y., Ji R., Cui P., Dai Q., and Hua G., Hyperspectral image classification through bilayer graph-based learning, *IEEE Trans. Image Process.*, Jul. 2014, **23**(7), 2769-2778.
- [123] Eckstein J. and Bertsekas D., On the Douglas-Rachford splitting method and the proximal point algorithm for maximal monotone operators, *Math. Program. Ser. A/B*, Jun. 1992, **55**(3), 293–318.
- [124] Iordache M.D., Bioucas-Dias J. M., and Plaza A., Total Variation Spatial Regularization for Sparse Hyperspectral Unmixing, *IEEE Transactions on Geoscience and Remote Sensing*, 2012, **50**(11), 4484-4502.

- [125] Zare A. and Ho K. C., Endmember variability in hyperspectral imagery, *IEEE Signal Process. Mag.*, Jan. 2014, **31**(1), 95–104.
- [126] Somers B., Delalieux S., Verstraeten W. W., Van Aardt J. A. N., Albrigo G. L. and Coppin P., An automated waveband selection technique for optimized hyperspectral mixture analysis, *International Journal of Remote Sensing*, 2010, **31**(20), 5549-5568.
- [127] Adams J., D Sabol., Kapos V., Filho R., Roberts D., Smith M., and Gillespie A., Classification of multispectral images based on fractions of endmembers: Application to land-cover change in the Brazilian Amazon, *Remote Sensing Environ.*, May 1995, **52**(2), 137-154.
- [128] Healey G. and Slater D., Models and methods for automated material identification in hyperspectral imagery acquired under unknown illumination and atmospheric conditions, *IEEE Trans. Geosci. Remote Sensing*, Nov. 1999, **37**(6), 2706-2717.
- [129] Drumetz L., Veganzones M.A., Henrot S., Phlypo R., Chanussot J., and Jutten C., Blind hyperspectral unmixing using an extended linear mixing model to address spectral variability, *IEEE Trans. Image Process.*, Aug. 2016, **25**(8), 3890-3905.
- [130] Zhang, J., Rivard, B., Sanchez-Azofeifa, A., & Castro-Esau, K., Intra- and inter-class spectral variability of tropical tree species at La Selva, Costa Rica: Implications for species identification using HYDICE imagery, *Remote Sensing of Environment*, 2006, **105**, 129-141.
- [131] Drumetz L., Chanussot J., Jutten C., Variability of the endmembers in spectral unmixing: Recent advances, *8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Los Angeles, CA, USA, 21-24 Aug. 2016.
- [132] Zare A., Ho K.C., Endmember Variability in Hyperspectral Analysis: Addressing Spectral Variability During Spectral Unmixing, *IEEE Signal Processing Magazine*, 2014, **31**(1), 95 – 104.
- [133] Somers B., Asner G. P., Tits L., Coppin P., Endmember variability in Spectral Mixture Analysis: A review, *Remote Sensing of Environment, Remote Sensing of Environment*, 2011, **115**, 1603–1616.
- [134] Thouvenin P., Dobigeon N., Tourneret J., Hyperspectral Unmixing With Spectral Variability Using a Perturbed Linear Mixing Model, *IEEE Transactions on Signal Processing*, 2016, **64**(2), 525 – 538.
- [135] Veganzones M.A., Drumetz L., Tochon G., Dalla Mura M., Plaza A., Bioucas-Dias J., Chanussot J., A new extended linear mixing model to address spectral variability, *6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Lausanne, Switzerland, 24-27 June 2014.

- [136] Hong D., Yokoya N., Chanussot J., Xiang Zhu X., An Augmented Linear Mixing Model to Address Spectral Variability for Hyperspectral Unmixing, *IEEE Transactions on Image Processing*, 2019, **28**(4), 1923 - 1938.
- [137] Uezato T., Fauvel M., Dobigeon N., Hyperspectral Unmixing With Spectral Variability Using Adaptive Bundles and Double Sparsity, *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **57**(6), 1-13.
- [138] Uezato T., Murphy R. Melkumyan J., Chlingaryan A., A., A Novel Spectral Unmixing Method Incorporating Spectral Variability Within Endmember Classes, *IEEE Transactions on Geoscience and Remote Sensing*, 2016, **54**(5), 2812 – 2831.
- [139] TU, T.N., Chen, C.H., WU, J.L. and Chang, C.I., A fast two-stage classification method for high-dimensional remote sensing data, *IEEE Transactions on Geoscience and Remote Sensing*, 1998, **36**, 182–191.
- [140] Asner G.P., and Lobell D.B., A biogeophysical approach for automated SWIR unmixing of soils and vegetation, *Remote Sensing of Environment*, 2000, **74**, 99 –112.
- [141] Delalieux S., Van Aardt J. A. N., Keulemans W., Schrevens E., and Coppin P., Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: nonparametric statistical approaches and physiological implications, *European Journal of Agronomy*, 2007, **27**, 130–143.

KİŞİSEL YAYINLAR VE ESERLER

- [1] **Kahraman S.**, Bacher R., Uezato T., Chanussot J., Tangel A., LiDARguided reduction of spectral variability in hyperspectral imagery, 10th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Amsterdam, Holland, 24 – 26 Eylül 2019, yayınlanmak üzere kabul edilmiştir.
- [2] **Kahraman S.**, Xu Y., Chanussot J., Tangel A., LiDAR Data-aided hypergraph regularized multi-modal unmixing, IGARSS 2019, Pacifico Yokohama, Japan, 28 Temmuz - 2 Ağustos 2019, yayınlanmak üzere Kabul edilmiştir.
- [3] **Kahraman S.**, Ertürk A., Ertürk S., Graph Regularized L1/2 Sparsity Constrained Non-negative Matrix Factorization for Hyperspectral and Multispectral Image Fusion, 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS2018), Amsterdam, 23-26 September 2018.
- [4] **Kahraman S.**, Yeşilyurt G., Ertürk A., and Ertürk S., Block-based and Segmentation-based Approaches for component substitution based hyperspectral pansharpening, *International Geoscience and Remote Sensing Symposium-IGARSS 2018*, Valencia, Spain, 22-27 July.
- [5] **Kahraman S.**, Ertürk A., Review and Performance Comparison of Pansharpening Algorithms for RASAT Images, *IU_JEEE, Electronica* 2018; **18**(1), 109-120.
- [6] **Kahraman S.**, Ertürk A., Performance Analysis of Pansharpening Algorithms for RASAT Images, *25.th IEEE Signal Processing and Communications Applications Conference (SİU)*, Antalya, Turkey, 15-18 Mayıs 2017.
- [7] **Kahraman S.**, Ertürk A., A Comprehensive Review of Pansharpening Algorithms for GÖKTÜRK-2 Satellite Images, *4th International Workshop on Geoinformation Science: GeoAdvances 2017*, Safranbolu, 14-15 Ekim 2017.
- [8] **Kahraman S.**, Ertürk A., 'GÖKTÜRK-2 Alıcısı Üzerine Pansharpening Yaklaşımlarının Başarım Analizi', *25.th IEEE Signal Processing and Communications Applications Conference, (SİU 2018)*, İzmir, 1-4 Mayıs 2018.

ÖZGEÇMİŞ

Sevcan Kahraman lisans derecesini Dokuz Eylül Üniversitesi Matematik Bölümü'nde 2005 yılında, yüksek lisans derecesini İzmir Yüksek Teknoloji Enstitüsü Matematik Bölümü'nde 2008 yılında tamamlamıştır. 2015-2019 yılları arasında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği'de doktorasını yapmıştır. Doktora öğrenimi sırasında çeşitli TÜBİTAK projelerinde görevler almıştır. 2018-2019 eğitim yılında altı aylığına University of Grenoble Alpes and Grenoble Institute of Technology, Laboratoire Grenoblois de l'Image, de la Parole, du Signal et de l'Automatique (Gipsa-Lab), Department of Images and Signal, Grenoble, Fransa'da ziyaretçi araştırmacı olarak çalışmalar yapmıştır. İlgi alanları arasında görüntü işleme, uzaktan algılama veri kaynaştırma ve spektral değişkenlik sayılabilir.