T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİPERSPEKTRAL GÖRÜNTÜLERİN AYRIŞTIRMA TEMELLİ ANALİZİ

BİLAL KOCAKUŞAKLAR

YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRONİK PROGRAMI

DANIŞMAN
YRD. DOÇ. DR. NİHAN KAHRAMAN

İSTANBUL, 2017

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

HİPERSPEKTRAL GÖRÜNTÜLERİN AYRIŞTIRMA TEMELLİ ANALİZİ

Bilal KOCAKUŞAKLAR tarafından hazırlanan tez çalışması 28.03.2017 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Yrd. Doç. Dr. Nihan KAHRAMAN

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Yrd. Doç. Dr. Nihan KAHRAMAN

Yıldız Teknik Üniversitesi _____

Yrd. Doç. Dr. Bülent BOLAT

Yıldız Teknik Üniversitesi _____

Yrd. Doç. Dr. Tuğrul ARTUĞ

İstanbul Arel Üniversitesi _____

ÖNSÖZ

Öncelikle tez danışmanım olan, çalışmalarıma katkı sağlayan Yrd. Doç. Dr. Nihan KAHRAMAN'a derin şükranlarımı sunarım.

Yüksek lisans boyunca bana destek olan, okulla ve derslerle alakalı yardımlarını esirgemeyen meslektaşım, devre arkadaşım Burak ALPTEKİN'e teşekkür ederim.

Son olarak, üzerimdeki emeklerini ve desteklerini hayatımın her döneminde hissettiğim değerli aileme teşekkür ederim.

Şubat, 2017

Bilal KOCAKUŞAKLAR

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ vi

KISALTMA LİSTESİ vii

ŞEKİL LİSTESİ viii

ÇİZELGE LİSTESİ x

ÖZET xi

ABSTRACT xiii

BÖLÜM 1

GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Tezin Amacı 3
1.3 Hipotez 3

BÖLÜM 2

HİPERSPEKTRAL AYRIŞTIRMA 4

2.1 Hiperspektral Ayrıştırma Zinciri 11
2.2 Doğrusal Karışım Modeli 12

BÖLÜM 3

SON ÜYE ÇIKARIM YÖNTEMLERİ 14

3.1 Zirve Bileşen Analizi 14
3.2 Dikey Alt-uzay Projeksiyonu 15
3.3 N-FINDER 16
3.4 Değişen Hacim Maksimizasyonu ve Ardışık Hacim Maksimizasyonu 17
3.5 En Küçük Hacimli Simpleks Analizi ve Değişken Bölme Arttırılmış Lagrange Yaklaşımı ile Simpleks Tanımlanması 18

BÖLÜM 4

UZAMSAL ÖNİŞLEME YÖNTEMLERİ 19

4.1 Uzamsal Ön-işleme 20
4.2 Bölgesel Tabanlı Uzamsal Ön-işleme 22

BÖLÜM 5

HİPERSPEKTRAL GÖRÜNTÜLERDE GÜRÜLTÜ GİDERİMİ YÖNTEMLERİ 25

5.1 Genel Analiz Öncelikli Algoritması 25
5.2 Uzamsal-Spektral Total Varyasyon 27

BÖLÜM 6

DENEYSEL SONUÇLAR 31

6.1 Kullanılan Hiperspektral Veri 31
6.2 Performans Kriterleri 33
6.2.1 Spektral Açı Haritalama (Spectral Angle Mapper-SAM) 33
6.2.2 Ortalama Karesel Hata (Root Mean Square Error-RMSE) 34
6.3 Deneme Sonuçları (Çalışma 1) 35
6.4 Deneme Sonuçları (Çalışma 2) 41
6.5 Deneme Sonuçları (Çalışma 3) 49

BÖLÜM 7

SONUÇ VE ÖNERİLER 57

KAYNAKLAR 59

ÖZGEÇMİŞ 63

SİMGE LİSTESİ

$a(i, j)$	Sayısal faktör
β	Ağırlık faktörü
B_i^k	Bregman değişkenleri
C	Simpleks yapı
D_v	Dikey fark operatörü
D_h	Yatay fark operatörü
M	Karışım matrisi
$\hat{S}$	Tahmini bolluk oranı
γ	Spektral açı
λ	Ayrık gürültü için gürültü giderim gücü parametresi
μ	Total varyasyon düzenleme parametresi

KISALTMA LİSTESİ

AVMAX	Alternating Volume Maximization
FCLS	Fully Constrained Least Squares
GAP	General Analysis Prior Algorithm
HFC	Harsanyi, Farrand, Chang
HYDICE	Hyperspectral Digital Imagery Collection Experiment
IEA	Iterative Error Analysis
LMM	Linear Mixing Model
LSMA	Linear Spectral Mixture Analysis
LSQR	Least Squares
MNF	Maximum Noise Fraction
MVSA	Minimum Volume Simplex Analysis
NAPC	Noise Adjusted Principle Components
OSP	Orthogonal Subspace Projection
PCA	Principal Component Analysis
PPI	Pixel Purity Index
PSNR	Peak Signal to Noise Ratio
RBSPP	Region Based Spatial Pre-processing
RMSE	Root Mean Square Error
SAM	Spectral Angle Mapper
SGA	Simplex Growing Algorithm
SISAL	Simplex Identification via Split Augmented Lagrangian
SNR	Signal to Noise Ratio
SPP	Spatial Pre-processing
SSTV	Spectral-spatial Total Variation
SVMAX	Successive Volume Maximization
TV	Total variation
VCA	Vertex Component Analysis
VD	Virtual Dimension

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 Multispektral ve hiperspektral görüntü farkı 5
Şekil 2.2 Elektromanyetik spektrum 5
Şekil 2.3 Hiperspektral görüntülemede saf piksel ve karışım pikseli 8
Şekil 2.4 Makroskobik ve mikroskobik karışım 9
Şekil 2.5 Doğrusal karışım modeli 9
Şekil 2.6 Doğrusal olmayan karışım modeli 10
Şekil 2.7 Ayrıştırma problemleri için oluşabilecek parazitler 10
Şekil 2.8 Hiperspektral ayrıştırma zinciri 11
Şekil 2.9 Simpleks yapı gösterimi 13
Şekil 3.1 VCA 15
Şekil 3.2 OSP'de dikey projeksiyon konseptinin kullanılarak son-üyelerin bulunması 16
Şekil 3.3 N-FINDER algoritmasında hacim maksimizasyonu yapılarak son-üyelerin bulunması 17
Şekil 3.4 Saf piksel içermeyen bir görüntüde VCA ve MVSA sonuçları 18
Şekil 4.1 Son-üye çıkarımı safhasında sadece spektral bilginin kullanılması 19
Şekil 4.2 Sayısal faktöre göre piksellerin yerdeğişimi 21
Şekil 4.3 Sentetik veri 24
Şekil 4.4 Son-üye çıkarımı safhasında kullanılacak pikseller 24
Şekil 5.1 GAP uygulama 27
Şekil 5.2 SSTV uygulama 30
Şekil 6.1 Kentsel HYDICE veri setinin sahte renkli görüntüsü 31
Şekil 6.2 Dört son üye için referans spektralar 32
Şekil 6.3 Beş son üye için referans spektralar 32
Şekil 6.4 Altı son üye için referans spektralar 33
Şekil 6.5 Spektral açı gösterimi 34
Şekil 6.6 GAP yöntemi 35
Şekil 6.7 Bolluk haritası tahmini (Referans spektra kullanılmıştır.) 40
Şekil 6.8 Bolluk haritası tahmini (Son üyeler algoritmalar vasıtasıyla orijinal veriden çıkarılmıştır.) 41
Şekil 6.9 Bolluk haritası tahmini (Son üyeler algoritmalar vasıtasıyla GAP uygulanmış veri üzerinden çıkarılmıştır.) 41
Şekil 6.10 Orijinal veriye SPP ile farklı pencereler uygulanarak elde edilmiş görüntüler (Bant 80-Bant 110) 42
Şekil 6.11 SPP-VCA yöntemi ile 7x7'lik pencerede çıkarılan son üyeler 44

Şekil 6.12 Bolluk haritası tahmini (Son üyeler SPP-VCA (7x7 pencere) uygulamasıyla çıkarılmıştır.)..... 45
Şekil 6.13 Gürültü içeren bantlar..... 46
Şekil 6.14 SSTV-SPP-VCA yöntemi ile 5x5'lik pencerede çıkarılan son üyeler..... 48
Şekil 6.15 Bolluk haritası tahmini (Son üyeler SSTV-SPP-VCA (5x5 pencere) uygulamasıyla çıkarılmıştır.)..... 49
Şekil 6.16 ISODATA algoritması uygulanması ile oluşan 7 küme..... 50
Şekil 6.17 RBSPP yöntemiyle seçilen kümelerdeki piksel vektörlerinin mevkileri..... 50
Şekil 6.18 RBSPP-OSP yöntemi ile çıkarılan son üyeler..... 52
Şekil 6.19 Bolluk haritası tahmini (Son üyeler RBSPP-OSP uygulamasıyla çıkarılmıştır.)..... 53
Şekil 6.20 Gürültü giderimi sonrası ISODATA algoritması uygulanması ile oluşan 7 küme..... 53
Şekil 6.21 Gürültü giderimi sonrası RBSPP yöntemiyle seçilen kümelerdeki piksel vektörlerinin mevkileri..... 54
Şekil 6.22 SSTV-RBSPP-OSP yöntemi ile çıkarılan son üyeler..... 55
Şekil 6.23 Bolluk haritası tahmini (Son üyeler SSTV-RBSPP-OSP uygulamasıyla çıkarılmıştır.)..... 56

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 Hiperspektral algılayıcılar.....6
Çizelge 6.1 Dört son üye varsayımına göre SAM sonuçları..... 36
Çizelge 6.2 Beş son üye varsayımına göre SAM sonuçları.....37
Çizelge 6.3 Altı son üye varsayımına göre SAM sonuçları..... 38
Çizelge 6.4 Kentsel veriden yöntemler ile elde edilen bolluk oranlarının rmse açısından benzerlik sonuçları..... 39
Çizelge 6.5 SPP uygulandıktan sonra SAM skorları..... 43
Çizelge 6.6 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (1)..45
Çizelge 6.7 SAM skorları (1)..... 47
Çizelge 6.8 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (2)..49
Çizelge 6.9 SAM skorları (2)..... 51
Çizelge 6.10 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (3)..53
Çizelge 6.11 SAM skorları (3)..... 54
Çizelge 6.12 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (4)..56

ÖZET

HİPERSPEKTRAL GÖRÜNTÜLERİN AYRIŞTIRMA TEMELLİ ANALİZİ

Bilal KOCAKUŞAKLAR

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. Nihan KAHRAMAN

Hiperspektral görüntü işleme günümüzde oldukça popüler bir konudur. Uzaktan algılama teknolojileri içeresinde yer alan hiperspektral görüntüleme, yüksek spektral bilgi içerdiğinden geniş bir faaliyet alanına sahiptir: askeri, tarımsal, jeoloji, tıbbi uygulamalar vb. Elektromanyetik spektrumda kısa aralıklarla ve fazla sayıda bantta bilgi alınması sayesinde elde edilen görüntünün spektral çözünürlüğü artmaktadır. Bu yüksek spektral çözünürlükten yararlanılarak yüzey materyalleri hakkında ayrım yapılabilmektedir.

Hiperspektral görüntülerin yüksek spektral içeriklerine rağmen uzamsal çözünürlükleri düşüktür. Bu da bir pikselin içerisine birden fazla yüzey materyalinin gelmesine ve karışım pikselleri oluşumuna neden olmaktadır. Düşük uzamsal çözünürlük hiperspektral görüntülemenin en büyük dezavantajıdır.

Hiperspektral ayrıştırma; yüzey materyallerinin sayılarının bulunması, bu materyallerin imzalarının tahmin edilmesi ve görüntü üzerindeki her pikselde her bir materyalin hangi oranda bulunduğunun tespit edilmesi işlemlerini ihtiva eder. Ayrıştırma işlemi görüntü içerisindeki gürültüler, iklimsel durumlar, veri boyutlarının yüksek olmaları nedeniyle çözümü zor bir problemdir.

Bu tezde, hiperspektral görüntülerin ayrıştırma problemlerinin çözümü için geometrik tabanlı algoritmlar kullanılmıştır. Aynı zamanda Genel Analiz Öncelikli Algoritması (GAP) ile dürtü gürültüsünün giderimi işleminin ayrıştırma probleminin çözümüne etkileri incelenmiştir.

Geometrik tabanlı algoritmaların yalnızca spektral içerik bilgisinden yola çıkarak işlem yapmaları sebebiyle, uzamsal bilginin de ön işleme adımları vasıtasıyla uzamsal ön işleme (SPP), bölgesel tabanlı uzamsal ön işleme (RBSPP) gibi yöntemlerle kullanılarak, ayrıştırma probleminin çözümü için spektral ve uzamsal bilginin birlikte kullanımı sağlanmıştır. Bu işlemler öncesinde de Gauss ve ayrık gürültünün giderilmesini hedefleyen Uzamsal-Spektral total varyasyon (SSTV) kullanıldığında ayrıştırma probleminin çözümünde daha başarılı sonuçlar elde edilmiştir.

Tez kapsamında, ayıştırma problemlerinin çözümünde, gürültü giderim işleminin ve uzamsal bilginin yalnızca spektral bilgiyi kullanan geometrik tabanlı algoritmalar ile birlikte kullanılarak daha iyi neticeler elde etmek amaçlanmıştır. Önerilen yöntemin bu hedefe uygun olduğu sonucuna varılmıştır.

Anahtar Kelimeler: Hiperspektral ayrıştırma, uzamsal ön işleme, genel analiz öncelikli algoritması, uzamsal-spektral total varyasyon.

ABSTRACT

UNMIXING BASED ANALYSIS OF HYPERSPECTRAL IMAGES

Bilal KOCAKUŞAKLAR

Department of Electronics and Communications Engineering

MSc. Thesis

Adviser: Assist. Prof. Dr. Nihan KAHRAMAN

Hyperspectral image processing is a popular topic today. Hyperspectral imaging within remote sensing technologies has a wide field of activity because it includes high spectral resolution: military, agricultural, geological, medical applications, etc. The spectral resolution of the resulting image is increased by acquiring information in short intervals and in a large number of bands in the electromagnetic spectrum. By using this high spectral resolution, surface materials can be distinguished.

Hyperspectral images have low spatial resolution despite high spectral content. This causes more than one surface material to come into a pixel and cause to form mixed pixels. Low spatial resolution is the biggest disadvantage of hyperspectral imaging.

Hyperspectral unmixing aims at finding the numbers of surface materials, predicting the signatures of these materials and determining the proportion of each material in each pixel on the image. Hyperspectral unmixing is a difficult problem because of the noisy, climatic conditions in the image and high data sizes.

In this thesis, geometric based algorithms are used to solve the problem of unmixing of hyperspectral images. At the same time, the effects of impulse noise reduction process with the General Analysis Prior Algorithm (GAP) on solving the problem of unmixing were examined.

Spatial and spectral information is solely used for solving the problem of unmixing by using spatial preprocessing (SPP) and regional based spatial preprocessing (RBSPP) by

means of preprocessing steps, since geometric based algorithms operate only from the spectral content information. In the case of using Spatial-Spectral Total Variation (SSTV) which aims to remove Gaussian and discrete noise before these processes, more successful results have been obtained in solving the unmixing problem.

Within the scope of the thesis, it is aimed to obtain better results by solving the problem of unmixing by using the noise removal process and spatial information with geometric based algorithms which only use spectral information. It is concluded that the proposed method suits this goal.

Keywords: Hyperspectral unmixing, spatial preprocessing, general analysis prior algorithm, spatial-spectral total variation.

BÖLÜM 1

GİRİŞ

1.1 Literatür Özeti

Dünyada bulunan bütün materyaller, üzerlerine gelen güneş ışığını yansıtma esnasında farklı karakteristik özellikler gösterirler. Bu özelliklerden faydalanılması maksadıyla algılayıcılar tarafından elde edilecek yüksek spektral içerikli bilgiye gereksinim duyulmaktadır. Elektromanyetik spektrumda daha az aralıkla ve daha fazla sayıda bantta bilgi alınması suretiyle bu materyaller hakkında daha fazla bilgi edinilmesi mümkündür [1]. Bu da hiperspektral algılayıcılar ile sağlanabilmektedir. Günümüzde akademik çalışmalarda hiperspektral görüntüler; hedef/anamoli tespiti, kamuflaj tespiti, mayın tespiti, keşif/gözetleme, patlayıcı tespiti gibi askeri uygulamalar, çevrenin görüntülenmesi, mineral aranması, ekin alanlarının incelenmesi, yerbilimleri, arkeoloji, doküman analizi ve adli belgelerin incelenmesi, kusurlu/zararlı gıda ürünlerinin tespiti, tıbbi uygulamalar gibi çok geniş bir alana tekabül eden bir sahada çeşitlilik göstermektedir. Bu alanlarda çözüm için kümeleme, sınıflandırma, hedef/anamoli tespiti, karışım tespiti gibi yaklaşımlar kullanılmaktadır.

Hiperspektral ayrıştırma işlemi; hiperspektral görüntü içerisindeki yüzey materyallerinin sayısının ve spektral imzalarının bulunması, piksellerde bu materyallerin hangi oranda bulunduklarının tespiti problemlerini içerir [2]. Görüntü içerisindeki materyaller son üye olarak adlandırılır. Bu problem için boyut indirgeme, son üyelerin tanımlanması ve bolluk oran tahmini olarak birbirlerini izleyen üç parçalı çözüm önerisi geliştirilmiştir [3]. Boyut indirgeme safhası için maksimum gürültü bölünmesi (maximum noise fraction-MNF) [4] ve gürültü ayarlanmış ana bileşenler

(noise adjusted principle components-NAPC) [5] gürültünün istatistiksel olarak modellenmesi için kullanılmaktadır.

Doğrusal karışım modeli içerisinde son üye tanımlanması safhasında kullanılmak üzere geometrik tabanlı algoritmalar geliştirilmiştir. Bu algoritmaların hepsinin mantığı aynı olmasına rağmen çözüme yaklaşımlarındaki farklılıklarından dolayı değişik sonuçlar ortaya koyarlar. Saf piksel ve minimum hacim olarak iki gruba ayrılırlar. İlk gruptaki yöntemlerden piksel saflık indeksi (Pixel purity index-PPI) [6], sinyal gürültü oranı (SNR)'ı arttırmak için ilk önce veriye MNF uygular. Sonrasında bütün spektral vektörlerin projeksiyonunu alarak, büyük bir rastgele vektör seti olarak tanımlanan şiş üzerine yerleştirir. Oluşan her şişte en uç noktalara denk gelen pikseller son üye olarak tanımlanır.

N-FINDER [7] yöntemi ise veriyi maksimum hacim üzerine yinelemeli olarak yerleştirerek oluşan köşeleri son üye olarak tanımlar.

Yinelemeli hata analizi (The iterative error analysis-IEA) [8] ise, bir dizi doğrusal kısıtlamalı ayrıştırma uygularken, her seferinde ayrıştırılmış görüntüde hatayı en aza indirecek pikselleri seçerek yüzey materyallerini belirler.

Zirve bileşen analizi (Vertex component analysis-VCA) [9], spektral vektörlerin yinelemeli olarak daha önceden belirlenmiş son-üye sayısına göre alt uzaya dik yönde projeksiyonlarını alarak son üyeleri belirlemektedir.

Simpleks geliştirici algoritma (Simpleks growing algorithm-SGA) [10], simpleks yapıyı hacimi maksimize edecek şekilde geliştirerek son üyeleri tespit etmeyi hedeflemektedir.

N-FINDER algoritmasından esinlenilerek oluşturulan AVMAX algoritması [11], son üyeler tarafından oluşturulan simpleks yapının hacminin art arda döngüsel olarak en üst düzeye çıkarılmasını sağlayarak çözüme gider.

SVMAX algoritması [11] da, VCA yönteminden türetilmiş bir algoritmadır. Aralarındaki temel fark ise alt uzayın tanımlanması aşamasındadır.

Minimum hacim algoritmaları ise görüntü içerisinde her bir son üye için saf piksel bulunmaması durumu için geliştirilmiş algoritmalardır. Burada hedef ise veriyi

sığdıracak şekilde minimum hacimli bir simpleks yapının oluşturulmasıdır. En Küçük Hacimli Simpleks Analizi [12] ve Değişken bölme arttırılmış lagrange yaklaşımı ile simpleks tanımlanması [13] (Minimum Volume Simplex Analysis-MVSA, Simplex Identification via Split Augmented Lagrangian-SISAL) bu yöntem için örnek algoritmalardandır. Bu yöntemlerde doğrusal karışım modelinde bolluk oranlarının negatif olamama kısıtı gevşetilerek gürbüz bir yapı elde edilir. Ancak gürültünün fazla olduğu verilerde gerçek veri simpleksinin çok dışına çıkarak orjinal son üyelere uzak tahminler sergileyebilirler.

1.2 Tezin Amacı

Bu tez kapsamında, hiperspektral bir görüntü içerisindeki son üyelerin imzalarının bir kütüphane kullanmadan eğiticisiz olarak doğruya en yakın şekilde bulunması hedeflenmektedir. Bu sebeple son üye tahmininin daha iyi olması için geometrik tabanlı algoritmaların kullandığı spektral bilgi haricinde uzamsal bilgiyi de kullanan uzamsal ön işleme ve bölgesel tabanlı uzamsal ön işleme yöntemleri de kullanılacaktır. İlave olarak gürültü giderim işlemleri de ön işleme adımı olarak uygulanarak bunların hiperspektral ayrıştırmaya etkisi incelenecektir.

1.3 Hipotez

Hiperspektral ayrıştırma problemleri için bu tezde, geometrik tabanlı algoritmaların sonuçlarının iyileşmesi için genel analiz öncelikli algoritması ve spektral-uzamsal total varyason yöntemleri ile gürültü giderim işlemleri yapılmış, sonrasında ise verideki uzamsal bilginin de kullanılması için uzamsal ön işleme ve bölgesel tabanlı uzamsal ön işleme yöntemleri uygulanmış, son olarak geometrik tabanlı algoritmaların son üye çıkarımı safhasında uygulanması hipotez olarak önerilmiştir.

BÖLÜM 2

HİPERSPEKTRAL AYRIŞTIRMA

Askeri ve sivil birçok uygulama için uzaktan bilgi alabilme büyük önem arz etmektedir. Uzaktan algılama genel olarak, incelenecek nesneye direkt bir müdahale olmaksızın uzak bir mesafeden algılayıcılar ile elde edilen bilgilerin değerlendirilmesini ifade eder. Bunlara örnek olarak takip edilen bir hedefin iz değişiminin izlenmesi veya arama ve kurtarma faaliyetleri için hedef aranması verilebilir. Bu amaçlarla tasarlanan multispektral ve hiperspektral algılayıcılar herhangi bir gönderme yapmaksızın, güneş ışığından faydalanarak yansıyan ışınların değerlendirilmesi ile pasif olarak çalışmış olurlar. Multispektral algılayıcılar birkaç ayrı bantta (genellikle 5-7 bantta) dönen ışınları ölçer. Hiperspektral görüntüleme cihazları, görüntü alınan alanda anlık olarak saçılan elektromanyetik enerjiyi, multispektral kameralara göre daha yüksek spektral çözünürlüğe sahip yüzlerce dar ve bitişik spektral kanalda ölçer [14]. Dolayısıyla hiperspektral kelimesi bant sayısının fazla olmasını ifade eder. Hiperspektral görüntülerin en temel avantajı işte bu zengin spektral içeriktir. Multispektral ve hiperspektral algılayıcı arasındaki bir pikselin yansıma değerlerinin farklılığı Şekil 2.1'de gösterilmiştir.

Hiperspektral görüntülerin veri boyutları yüksektir. Aynı zamanda algılayıcı tarafından alınan görüntü atmosferik etkiler, algılayıcı özellikleri gibi nedenlerden dolayı gürültü ihtiva ederler. Bu açıdan bakıldıklarında yorumlanmaları ve analiz edilmeleri bazı zorluklar içerir. Bu zorlukların giderilmesi için uygulamalardan önce ön-işleme yöntemleri sıklıkla kullanılır.

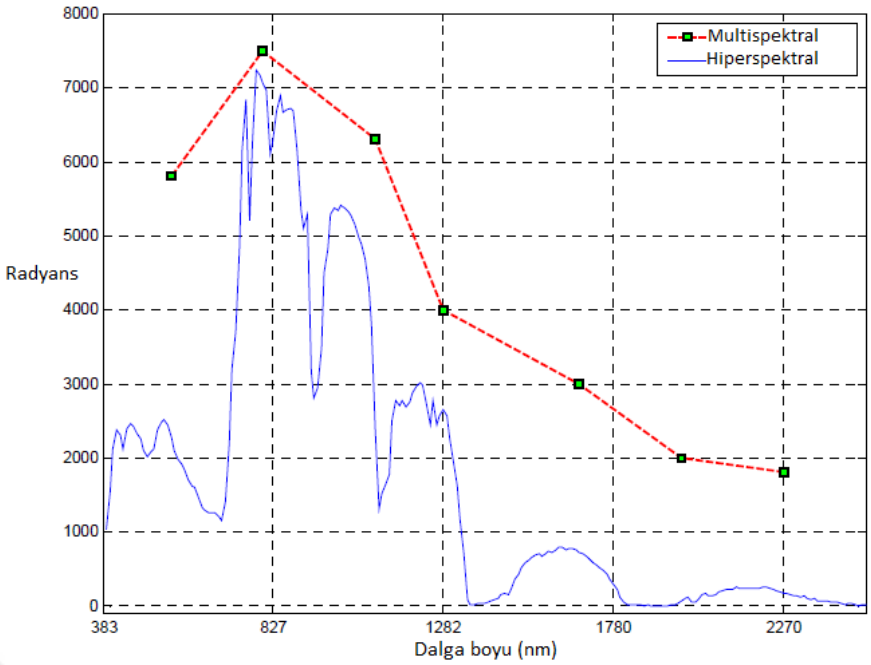

Şekil 2.1 Multispektral ve hiperspektral görüntü farkı

Hiperspektral görüntüleme elektromanyetik spektrumun bir kısmının algılanması olarak da düşünülebilir. Elektromanyetik spektrum; ultraviyole, görünür, kızıl ötesi, mikrodalga gibi bantlara ayrılır. Şekil 2.2 elektromanyetik spektrumun dalga boyu bölgelerini göstermektedir. Hiperspektral görüntülerin menzili görünür banttan yakın kızılötesi banta kadar olan bölümü kapsamaktadır (350-2500 nm.).

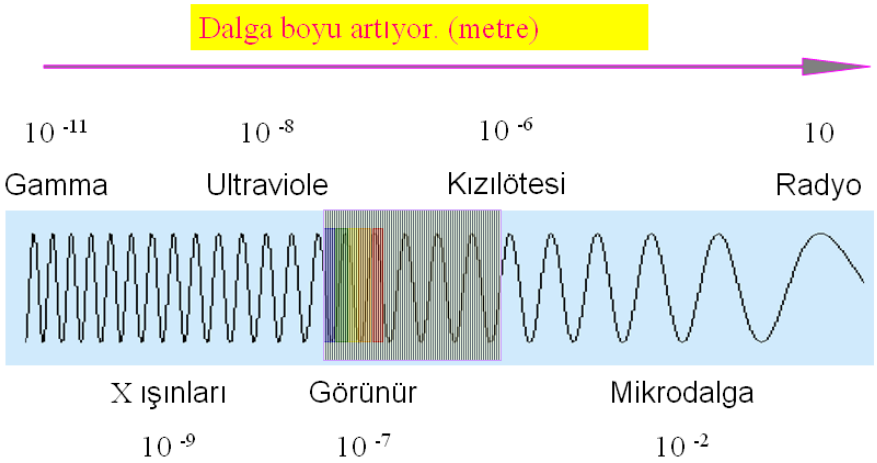

Şekil 2.2 Elektromanyetik spektrum [15]

Hiperspektral görüntüler nesneleri bulma, materyalleri tanımlama veya tespit işlemlerini sağlamadaki avantajları nedeniyle yaygın olarak kullanılmaktadır.

Hiperspektral görüntü analizi ise askeri gözetleme, mineral arama, çevre görüntüleme ve ekin alanlarının incelenmesi gibi alanlarda oldukça popüler bir konudur.

Yeryüzünde bulunan materyaller belirli dalga boylarında farklı saçılım özellikleri göstermektedirler. Hiperspektral algılayıcılar yüksek spektral içeriğe sahip olmaları nedeniyle, yüzeydeki materyaller hakkında çıkarım yapılabilmesine imkan vermektedir. Hiperspektral görüntüler uydulardan ya da hava araçlarından alınmaktadır. Genellikle bir hava aracının üzerine monte edilen bir algılayıcı ile istenen bölge taranarak görüntü elde edilir. Akademik çalışmalarda geliştirilen algoritmaların test edilmesi ve karşılaştırılması için hava araçları ile elde edilen veri setleri mevcuttur. Uydulara monte edilen algılayıcılar ise askeri maksatlarla kullanılmaktadır. Çizelge 2.1'de bazı hiperspektral algılayıcılar ve bunların özellikleri belirtilmiştir.

Çizelge 2.1 Hiperspektral algılayıcılar

Tip	Algılayıcı	Üretici	Bant sayısı	Dalga boyu aralığı (nm.)	Uzaya gönderilme tarihi
Uydu	Hyperion on EO-1	NASA Goddard Uzay Uçuş Merkezi	220	400 – 2500	2000
Uydu	CHRIS	ESA İngiltere	18/37/6	400 – 1050	2001
Uydu	HJ-1A	CAST Çin	110	450 – 950	2008
Uydu	HySI	ISRO Hindistan	64	400 – 950	2008
Uydu	HICO	NASA ABD	128	353 – 1081	2009
Uydu	PRISMA	ASI İTALYA	237	400 – 2500	2014
Uydu	EnMAP	GFZ/DLR-Almanya	218	420 – 2450	2015

Çizelge 2.1 Hiperspektral algılayıcılar (devamı)

Uçak	AVIRIS	NASA Jet Propulsion Lab.	224	400 – 2500	-
Uçak	HYDICE	ABD Donanma Araştırma Lab.	210	400 – 2500	-
Uçak	PROBE-1	Earth Search Sciences Şirketi	128	400 – 2500	-
Uçak	CASI	ITRES araştırma şirketi	228	400 – 1000	-

Algılayıcı ile yüzey arası mesafenin fazla olması nedeniyle bu görüntülerin uzamsal çözünürlükleri düşüktür. Bu nedenle bir piksel yüzeyde geniş alanlara tekabül eder. Düşük uzamsal çözünürlük nedeniyle ölçülen spektrumlar, yüzeyde bulunan materyallerin belirli oranlarda karışımlarından oluşmaktadırlar ki bu yüzey materyallerine son üye denmektedir. Hiperspektral ayrıştırma son üyelerin sayılarının bulunması, son üye imzalarının tahmin edilmesi ve görüntü üzerindeki her pikselde her bir son üyenin hangi oranda bulunduğunun tespiti işlemlerini ihtiva eder. Ayrıştırma işlemi görüntü içerisindeki gürültüler, iklimsel durumlar, veri boyutlarının yüksek olmaları nedeniyle çözümü zor bir problemdir.

Hiperspektral ayrıştırma problem odaklı bir konudur. Hangi son üye/üyelerin incelenmesi gerektiği önceden bilinmeli ve ona göre algılayıcı seçimi yapılmalı ve ölçüm alanına mesafe seçilmelidir. Örnek verilecek olursa, bir asfalt yol düşünüldüğünde bu yolun bazı kısımları beton ile doldurulmuş, bazı kısımlarında da çimenler yeşermiş olabilir. Bu yoldan bir görüntü alındığında 3 son üye olduğu düşünülebilir. Ancak beton ve çimenli kısım çok küçük bir alanı kapsadığından bunlar son üye olarak tanımlanmayabilir. Ancak problemimizin çeşitine göre bunlar önemli son üyeler de olabilir. Yani son üye tanımlamaları problemimize uygun olacak şekilde yapılmalıdır.

Hiperspektral görüntüler iki uzamsal boyutu ve bir spektral boyutu ile veri küpü olarak da adlandırılabilirler. Aynı şekilde görüntü içerisindeki her bir piksel spektrası da,

yüksek boyutlu vektör olarak düşünülebilir. Algılayıcı tarafından bir piksele dair ölçülen reflektans değeri piksel içerisindeki materyallere bağlı olarak farklılık göstermektedir. Birden çok materyalin bir piksel içinde bulunması durumunda bu piksellere karışım pikseli adı verilir. Örneğin Şekil 2.3'de 1 numaralı pikselin çeşitli dalga boylarına karşılık gelen reflektans değerleri (imzası), piksel içerisinde bulunan toprak ve mineral son üyelerinin karışımı olarak elde edilmektedir. Aynı şekilde 3 numaralı piksel de ağaç ve toprak son üyelerinden oluşan karışım pikselidir. 2 numaralı pikselin olduğu bölgede ise yalnızca su son üyesi bulunduğundan bu tarz pikseller saf piksel olarak adlandırılır.

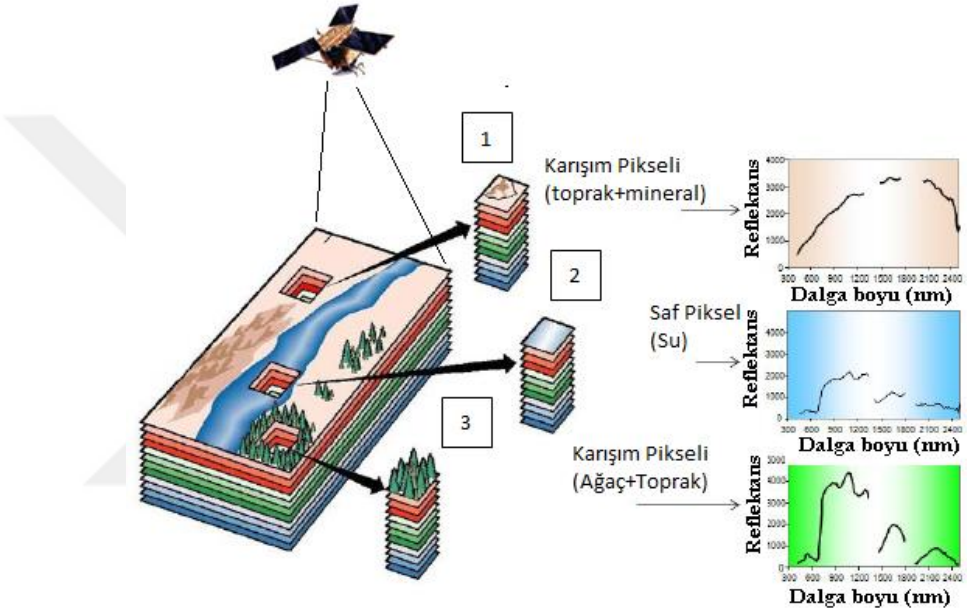

Şekil 2.3 Hiperspektral görüntülemede saf piksel ve karışım pikseli [16]

Karışım piksellerinin giderilmesi için uzamsal çözünürlüğün arttırılması çözüm değildir. Bu durumda da minerallerin birbirlerine yakın karışımları nedeniyle yine karışım pikselleri oluşmaktadır. Şekil 2.4'deki ilk görüntü 12x12 metrelik alana denk gelen bir görüntüdür. Burada işaret edilmiş piksel toprak, ağaç ve çimen son üyelerinden oluşan 3x3 metrelik alana denk gelen bölgede karışım oluştururlar. Diğer görüntüde ise uzamsal çözünürlük arttırılarak yeni bir görüntü elde edilmiştir. Burada da mikroskobik seviyede minerallerin yakın karışımlarından dolayı yine karışım pikseli oluşmuştur.

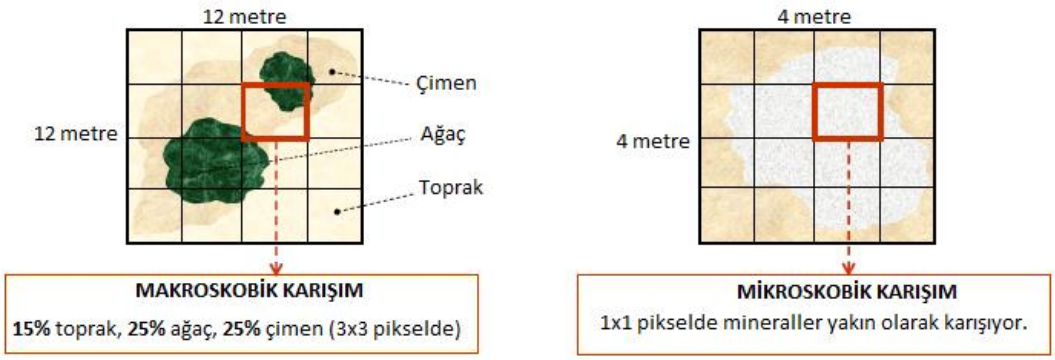

Şekil 2.4 Makroskobik ve mikroskobik karışım [16]

Burada her iki görüntüye ayrıştırma uygulanırken farklı yaklaşımlar mevcuttur. İlk görüntüdeki hedef son üyeleri bulmak ve piksellerde hangi oranlarda bulunduklarını belirlemek iken, ikinci görüntüde ise küçük skalalardaki karışımlardan dolayı, doğrusal olmayan karışım etkileri ile problem daha zor bir hal almaktadır. Ayrıştırma algoritmaları da bu karışımların hangi tip olduklarına bağlıdırlar. Burada iki model ortaya çıkmaktadır. Birincisi makroskobik seviyede karışımların olduğu durumdaki doğrusal karışım modelidir (Linear Mixing Model-LMM) [2]. Bu durumda gelen ışın dama tahtasındaki parçalara benzer şekilde sadece bir materyal ile etkileşir [17],[18]. Şekil 2.5 doğrusal karışımı modelini göstermektedir.

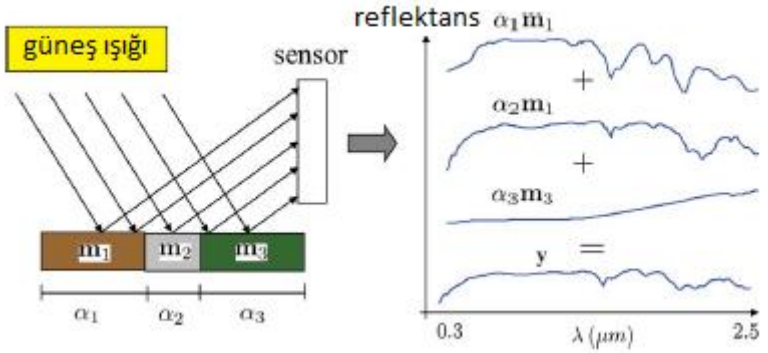

Şekil 2.5 Doğrusal karışım modeli [1]

Güneş ışığı yüzeydeki üç farklı materyalden yansıyarak algılayıcı tarafından farklı dalga boylarındaki reflektans değerleri olarak algılanır. Burada ölçülen y spektrumu son üyelerin spektrumlarının belli oranları alınıp toplanması ile elde edilir. Kısaca

özetlenecek olursa doğrusal karışım modelinde, spektral bileşenlerin piksellere homojen olarak yayıldıkları kabul edilir.

Şekil 2.6'da ise doğrusal olmayan karışım modeli gösterilmiş olup, yüzey üzerindeki materyallerin birbirleri ile etkileşimleri sonucu gelen ışık çoklu olarak saçılmaktadır.

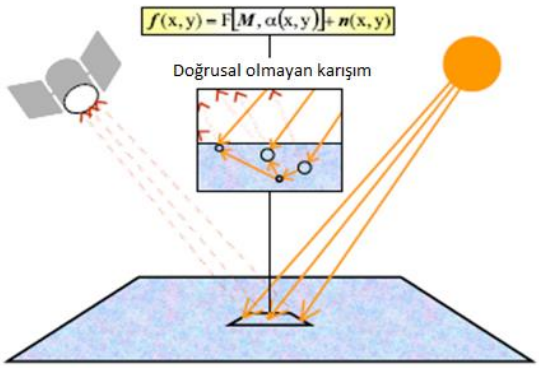

Şekil 2.6 Doğrusal olmayan karışım modeli [16]

Spektral karışımlarda ilave olarak, uzaktan algılanan hiperspektral verinin analiz işlemlerini önemli derecede etkileyen parazitler bulunmaktadır. Örneğin Şekil 2.7'de görüldüğü gibi atmosferik müdahaleler ayrıştırma problemlerinin hatalı sonuçlar vermesinin potansiyel bir sebebidir. Aynı şekilde çoklu saçılımlar da modellerin hatalı sonuçlar bulmasına neden olabilirler. Yine yüzeydeki materyallerin gölgesi, algılayıcının bulunduğu hava aracının yüzeye düşen gölgesi, bölgedeki aydınlık koşulları da uygulamalar yapılırken hesaba katılmalıdır.

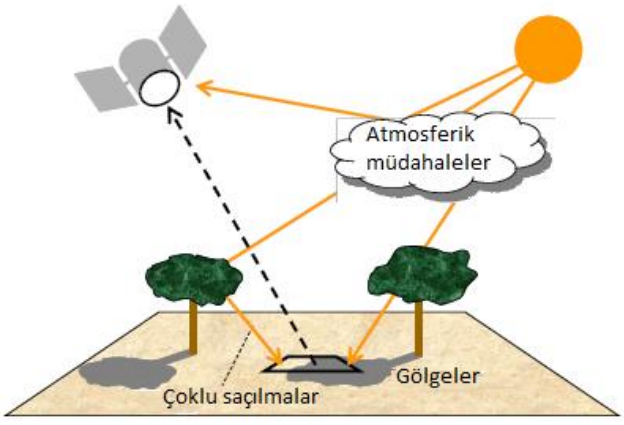

Şekil 2.7 Ayrıştırma problemleri için oluşabilecek parazitler [16]

Bundan sonraki kısımlarda doğrusal spektral ayrıştırma üzerinde durulacaktır. Bunun sebebi, bu yöntem temelinde spektral ayrıştırma konusunda, büyük araştırma

faaliyetlerinin son yıllarda geliştirilmiş olmasıdır. Bu çalışmalara dair bazı örnekler [1],[2],[3],[19],[20],[21] çalışmalarında bulunabilir.

2.1 Hiperspektral Ayrıştırma Zinciri

Şekil 2.8'de hiperspektral ayrıştırma zincirinin safhaları sergilenmiştir. Bu safhalar; atmosferik düzenleme, boyut indirgeme, son üye çıkarımı ve bolluk oranlarının tahmini adımlarından oluşmaktadır.

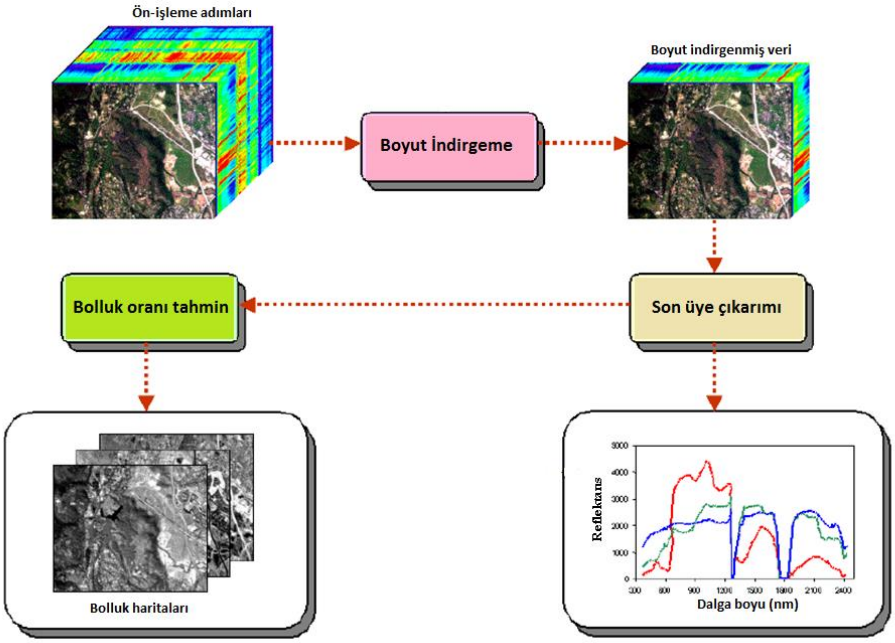

Şekil 2.8 Hiperspektral ayrıştırma zinciri [16]

Atmosferik Düzenleme: Atmosferik şartlar, ışık gücünün azalmasına ve saçılmasına neden olduklarından algılayıcı ile elde edilen parlaklık değerini etkiler. Atmosferik düzenleme, bu parlaklık değerinin reflektans değerine dönüştürülmesi ile oluşan bu durumu telafi eder.

Boyut İndirgeme: Hiperspektral veriler yüzlerce dalga boyundaki reflektans değerlerini içerdiklerinden veri hacimleri büyüktür. Bunun için uygulamalar yapılmadan önce hesaplama yükünü hafifletmek ve zamandan kazanç sağlamak için spektral içeriği de büyük oranda kaybetmeyecek şekilde boyut indirgeme işlemine tabi tutulurlar.

Hiperspektral Ayrıştırma: Bu safha ise son üye çıkarımı ve bolluk oranlarının tahmini işlemlerini içerir. Bu aşama için üç tip çözüm yöntemi bulunmuştur. Bunlar; geometrik

tabanlı yaklaşımlar, istatistiksel tabanlı yaklaşımlar ve seyrek regresyon yöntemleridir. İlk iki yöntem ayrıştırma problemine herhangi bir bilgi olmadan çözüm bulmaya çalışan yöntemler iken seyrek regresyonun bunlardan farkı, elimizde tüm son üye imzalarının içinde bulunduğu spektral kütüphanenin varlığını gerektirmesidir.

2.2 Doğrusal Karışım Modeli

Doğrusal karışım modelini matematiksel olarak ifade etmek gerekirse, $Y \in \Re^{l \times n}$ bir hiperspektral görüntüyü, l bant sayısını, n ise piksel sayısını ifade ettiği kabul edilsin. Burada $[y_1,.....,y_n]$ veri içerisindeki herhangi bir bantın görüntüsünün matrissel olarak gösterilmesidir. Doğrusal karışım modeline bağlı olarak bu hiperspektral veri aşağıdaki şekilde modellenebilir:

$$x_l = \sum_{i=1}^{l} a_i \times x_{wi} + \eta \tag{2.1}$$

Bu formülde son üyelerin spektrumu x_{wi} olarak tanımlanır. Görüntü içerisindeki pikseller $\{w_1, w_2, w_{3,}...., w_m\}$ ve η gürültü olarak ifade edilmiştir. $a_1, a_2, a_3,....., a_l$ katsayıları ise incelenen her pikseldeki son üyelere ait olan bolluk oranlarını ifade eder. x_l ise dalga boyunun bir fonksiyonu olarak yansıyan enerjinin her bir pikseldeki spektral parlaklık veya yansıma değerine eşittir. Bolluk oranlarını ifade eden katsayıların iki adet kısıtlaması mevcuttur. Bunlar; toplamlarının bire eşit olma kısıtlaması ve negatif olamama kısıtlamasıdır.

$$\sum_{i=1}^{l} a_i = 1 \tag{2.2}$$

$$a_1, a_2, a_3,....., a_l \geq 0 \tag{2.3}$$

Bu modelin çözümü için bir önceki kısımda geometrik tabanlı ve istatistiksel tabanlı yaklaşımlar geliştirildiği belirtilmişti. Kullanım alanlarının belirlenmesi için Şekil 2.9'da üç veri seti gösterilmiştir. Bu veriler doğrusal karışım modeli içerisinde (2.1) denklemine uygun olacak şekilde türetilmiştir. Bu formüle göre üretilen son üyelerin spektral vektörleri oluşan simpleks yapının köşelerine denk gelir. Örneklerde 3 son üye

bulunmaktadır. Sol taraftaki veride her bir son üye için en az bir saf piksel bulunmaktadır. Ortadaki veride ise son üyeler için saf piksel içermemesine rağmen son üyelerden birbirlerine doğru bir çizgi çizdiğimizde son üye sayısından bir eksik olacak şekilde veriler içermektedir. Dolayısıyla bu iki veride son üyeler simpleks yapıya minimum hacim giydirmesi yapılarak bulunabilir [1] ve bu yöntem geometrik tabanlı ayrıştırma algoritmalarının temelini oluşturur. En sağdaki örnekte ise minimum hacim giydirilmesi son üyelerin tanımlanmasını sağlayamaz. Çünkü veri yüksek oranda son üyelerin karışımı ile oluşmuştur. İşte bu durumlarda da istatistiksel tabanlı yaklaşımlar kullanılmaktadır.

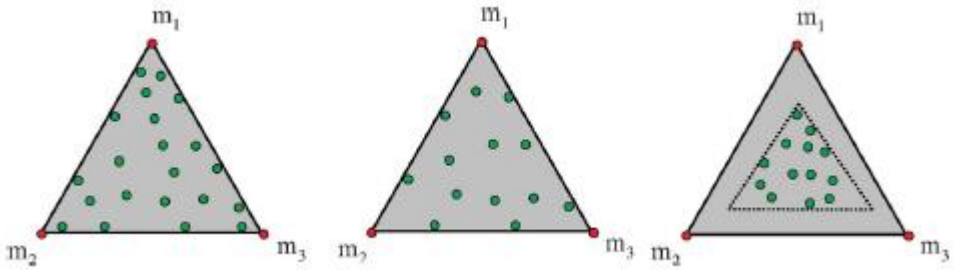

Şekil 2.9 Simpleks yapı gösterimi [1]

BÖLÜM 3

SON ÜYE ÇIKARIM YÖNTEMLERİ

Hiperspektral görüntüleri oluşturan vektörler, görüntü içerisinde bulunan son-üyelerin belirli oranlarda karışımları ile oluşur. Doğrusal spektral karışım analizi (Linear spectral mixture analysis-LSMA) veya lineer ayrıştırma öncelikle görüntüde bulunan son-üye sayısının tespit edilmesini, sonrasında bu son-üyelere ait spektral imzaların bulunmasını ve son olarak her bir piksel içerisinde mevcut olan son-üyelerin bu pikseller içerisinde hangi oranlarda bulunduklarını bulmayı hedefler. Bu maksatla son-üye imzalarının çıkarılması aşamasında geometrik tabanlı algoritmalar geliştirilmiştir.

3.1 Zirve Bileşen Analizi (Vertex Component Analysis-VCA)

VCA, hiperspektral görüntülerde son-üye çıkarımı safhasında kullanılan, eğiticisiz ve tam otomatik bir yöntemdir [9]. Algoritma iki olgudan yararlanır:

- Simpleks bir yapının köşeleri görüntüdeki son-üyeleri ifade eder.
- Simpleks bir yapının afin dönüşümü yine bir simpleks yapıdır.

Kısaca ifade etmek gerekirse VCA, spektral vektörlerin yinelemeli olarak daha önceden belirlenmiş son-üye sayısına göre alt uzaya dik yönde projeksiyonlarını almaktadır. Bu projeksiyonların en uç noktaları ise yeni son-üye imzalarına denk gelmektedir. Bütün son-üyeler bulunduktan sonra algoritma tamamlanır. Bu algoritma görüntü içerisinde bulunan her bir son-üye için bir saf piksel bulunduğu varsayımına dayanır. Bu durum bazı son-üyeler için sağlansa da, gerçek verilerde genellikle tüm son-üyeler için sağlanamaz. Bu algoritmanın en önemli dezavantajıdır. Avantajları ise sadece son-üye

sayısı bilgisine ihtiyaç duyması ve daha önceden herhangi bir yüzey materyalinin spektral imzasına ihtiyaç duymamasıdır. VCA'da ayrıca gürültüye karşı duyarlılığı azaltmak için gürültü tanımlaması işlemi uygulanır. Veriyi daha iyi temsil eden bu işlem tekil değer ayrıştırması (Singular Value Decomposition-SVD) kullanılarak yapılır ve yeni bir projeksiyon elde edilir. Şekil 3.1'de örnek olarak üç son-üyeye sahip varsayımsal bir karışım matrisi M ile oluşan simpleks yapı C gösterilmiştir. Burada yeşil noktalar spektral vektörleri göstermekte, kırmızı noktalar ise simpleks yapının köşelerini yani son-üyeleri göstermektedir. Yine Şekil 3.1'de orjinal ve projeksiyonu alınmış verinin iki boyuta indirgenmiş dağılımı verilmiştir. Bu görüntülerde tam üçgenler doğru son-üyeleri gösterirken kesikli üçgenler ise VCA ile tahmin edilen son-üyeleri ifade etmektedir. Buradan da anlaşılacağı üzere projeksiyonu alınmış veri ile son-üye imzaları orijinal veriye göre daha iyi tahmin edilmektedir.

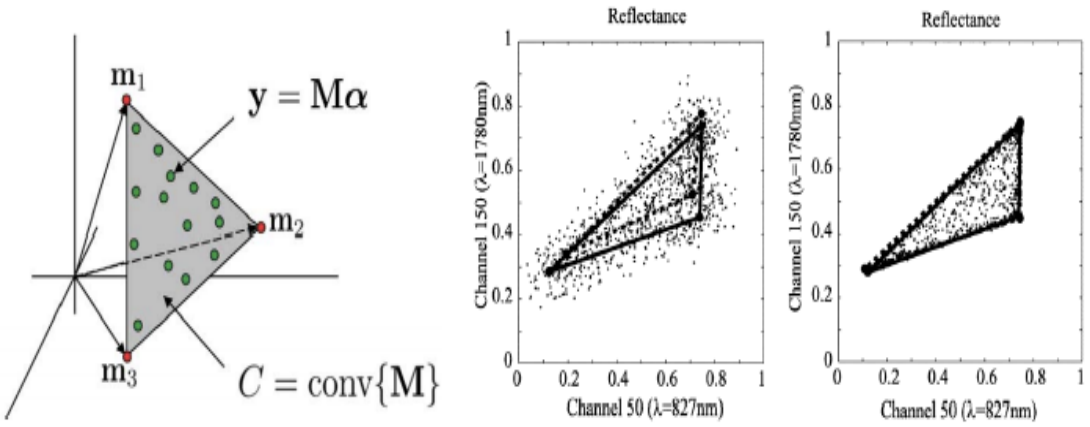

(a) (b) (c)

Şekil 3.1 VCA (a) Simpleks yapının gösterimi (b) Projeksiyonu alınmamış veri (c) SVD ile projeksiyonu alınmış veri [9]

3.2 Dikey Alt-uzay Projeksiyonu (Orthogonal Subspace Projection-OSP)

OSP algoritması hem veri boyutunun indirilmesi hem de istenmeyen veya parazit yapan spektral imzaları eleyerek, hedefteki materyallere ait spektral imzaları tespit eder [22]. Algoritmanın temel konsepti piksel vektörlerini istenmeyen imzalara dikey olan alt-uzaya yansıtmasıdır. Bu teknik en küçük kareler teorisinin bir sonucu olan dikey alt-uzay projeksiyonu kavramına dayanmaktadır. Öncelikle istenmeyen veya parazit olarak değerlendirilen spektral imzaları kaldıran, en küçük kareler anlamında optimal girişim

reddi operatörü oluşturulur sonrasında ise istenen imza sinyal-gürültü oranını (Signal to Noise Ratio-SNR) arttıran bir vektör operatörü oluşturulur. Şekil 3.2'de dikey projeksiyon yöntemi kullanılarak son-üyelerin tespit edilmesindeki safhalar gösterilmiştir.

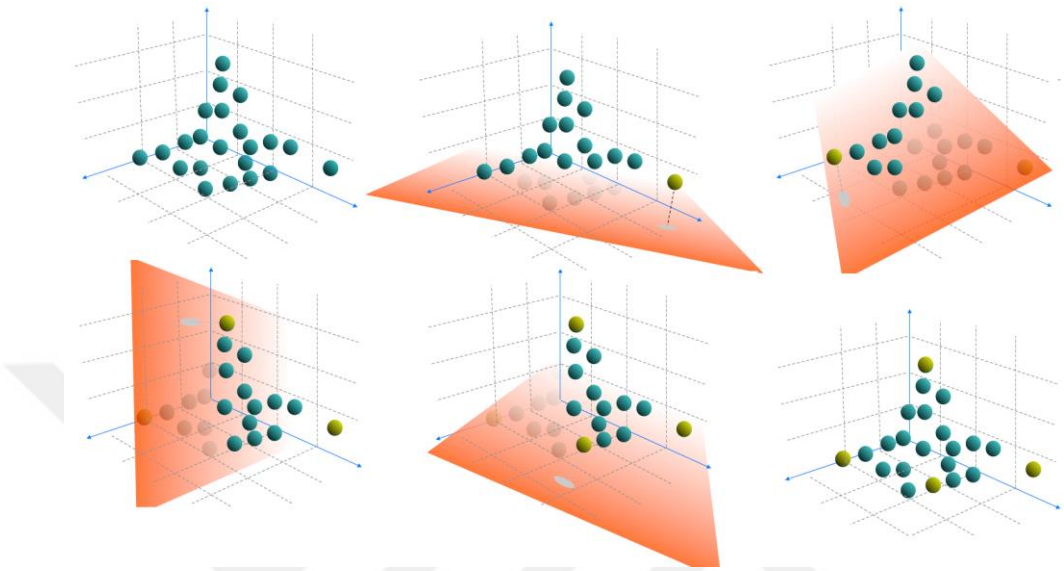

Şekil 3.2 OSP'de dikey projeksiyon konseptinin kullanılarak son-üyelerin bulunması [16]

3.3 N-FINDER

N-FINDER algoritması son-üye imzalarının çıkarılmasında kullanılan popüler bir yaklaşımdır. Görüntü içerisinde son-üyeler için saf piksel bulunduğu varsayımına dayanmaktadır. Veri küpündeki piksel vektörleri ile oluşturulabilen hacmi maksimize ederek son-üyeleri tespit eder [7]. N-FINDER başlangıç piksellerini rastgele seçerek algoritmayı başlatır. Ancak daha sonra başlangıç piksellerini seçmek için tekrarlamalı hata analizi [8] (IEA) algoritmasının kullanılarak hem daha kısa sürede son-üyelere ulaşılmasını, hem de algoritma her çalıştığında farklı sonuç alınması durumu engellenmiştir [23]. Aynı zamanda bu yöntem dışarıdan son-üye sayısının girilmemesi durumunda sanal boyut [24] (Virtual Dimension, VD) konseptini kullanarak son-üye sayısını kendisi bulabilir. Bu aşamada temel bileşenler analizi (Principal Component Analysis-PCA) ve Harsanyi, Farrand, Chang (HFC) [25] kullanılarak son-üye sayısı tespit edilir. Ancak son-üye sayılarını bulma yöntemlerinin görüntüde bulunan son-üyelerden daha fazla sayıda son-üye bulmalarına meyilli oldukları da hesaba katılmalıdır. Algoritma öncelikle başlangıç pikselleri olarak seçtiği piksellerden oluşan hacimi

hesaplar. Sonra yinelemeli olarak bulduğu diğer piksellerde de hacim hesabı yaparak bir önceki hacimden fazla olması durumunda pikselleri günceller. Bu şekilde maksimum hacimi üreten pikselleri bulduğunda köşelerdeki pikselleri son-üye olarak kabul eder. Bu durum görsel olarak Şekil 3.3'de sergilenmiştir.

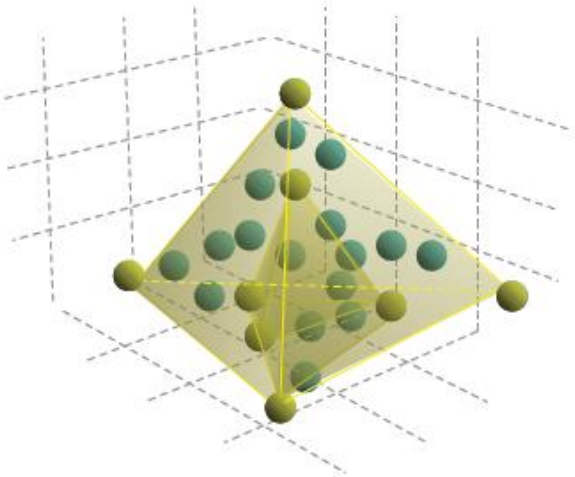

Şekil 3.3 N-FINDER algoritmasında hacim maksimizasyonu yapılarak son-üyelerin bulunması [18]

3.4 Değişen Hacim Maksimizasyonu ve Ardışık Hacim Maksimizasyonu (Alternating Volume Maximization-AVMAX, Successive Volume Maximization-SVMAX)

1990'ların sonunda Winter hiperspektral uzaktan algılama alanında son-üye imzalarının çıkarılması için geniş yankı uyandıran bir fikir ortaya koydu. Fikir özetle köşeleri piksel vektörleri olan maksimum hacimdeki simpleks yapının bulunmasıydı. Bu fikir piksel arama algoritmalarının birçok farklı varyasyonunun doğmasına neden oldu ki, N-FINDER da bu algoritmalardan birisiydi. Yine Winter'ın düşüncesinin çatısı altında iki farklı optimizasyon stratejisi kullanan iki yöntem türetilmiştir. N-FINDER algoritmasından esinlenilerek oluşturulan AVMAX algoritması [11], son üyeler tarafından oluşturulan simpleks yapının hacminin art arda döngüsel olarak en üst düzeye çıkarılmasını sağlar. Ancak ondan farklı olarak bazı yakınsama özellikleri kullanılmıştır. SVMAX'ın [11] ise VCA yöntemiyle benzerlikler gösterdiği görülmüştür. Dolayısıyla bu iki algoritma mevcut algoritmalara bağlı olarak alternatif yorumlar sunmaktadır. Aynı zamanda bu iki yöntem de saf piksel varsayımına dayanmaktadır.

3.5 En Küçük Hacimli Simpleks Analizi ve Değişken bölme arttırılmış lagrange yaklaşımı ile simpleks tanımlanması (Minimum Volume Simplex Analysis-MVSA, Simplex Identification via Split Augmented Lagrangian-SISAL)

MVSA hiperspektral ayrıştırma problemine, bolluk oranlarını olasılık simpleksine sığdıracak şekilde verilerin minimum hacim simpleksinde bulundurulması şeklinde yaklaşmaktadır [12]. Bu algoritmanın diğerlerinden en önemli farkı saf piksel varsayımına dayanmamasıdır. Yerel minimum noktalarından kaçınmak için iyi bir başlangıç çok önemlidir. Bu nedenle başlangıç degerleri VCA algoritması çalıştırılarak alınmaktadır. VCA, veri kümesinde bulunan spektral vektörler tarafından tanımlanan bir simpleks yapı üretmesi nedeniyle bu simpleks içindeki tüm spektral vektörler atılabilir ki bu da algoritmanın çalışmasını hızlandırır. Şekil 3.4'te ise sentetik bir görüntüde saf piksel bulunmaması durumu gösterilmiştir. Bu görüntü 3 adet son-üyenin belirli oranlarda karışımları ile elde edilmiştir. Böyle bir durumda MVSA, VCA'ya göre daha iyi sonuçlar elde etmektedir.

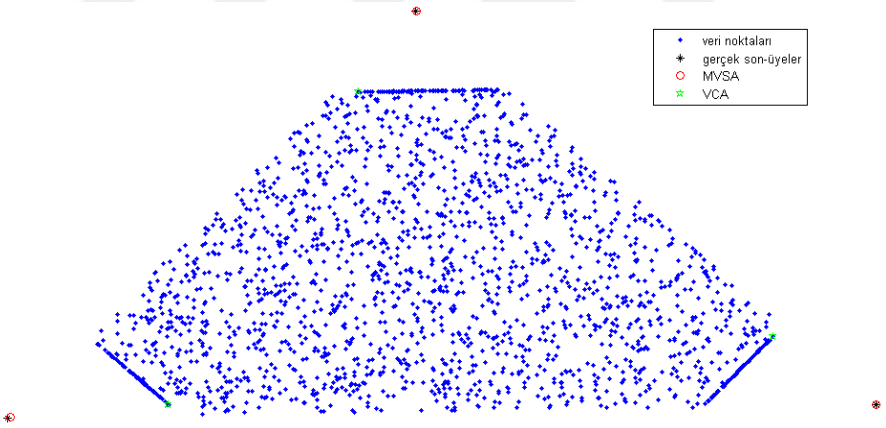

Şekil 3.4 Saf piksel içermeyen bir görüntüde VCA ve MVSA sonuçları

SISAL [13] algoritması ise minimum hacim sınıfına dahil olup, MSVA'ya benzer şekilde saf piksel varsayımına gerek duymamaktadır. MVSA'dan farklı olarak SISAL gürültülere karşı daha dayanıklı, zayıf başlangıç değerlerine karşı kuvvetli bir algoritmadır. Ayrıca MVSA algoritması ile çalışırken son-üye sayısının 10'un üzerine çıkması durumunda MATLAB'de hafıza hatası vermektedir. Bu nedenle SISAL daha büyük problemlerle baş etmenin de kapısını açmaktadır.

BÖLÜM 4

UZAMSAL ÖNİŞLEME YÖNTEMLERİ

Hiperspektral görüntülerde son-üye imzalarının bulunması aşamasında kullanılan VCA, N-FINDER, OSP, AVMAX, SVMAX, MVSA, SISAL gibi algoritmalar görüntülerdeki sadece spektral bilgiyi kullanırlar. Oysaki bu görüntülerde uzamsal bilgi de çok önemlidir. Şekil 4.1'de bu durumdan bahsedilmiştir. Burada görüldüğü gibi bir hiperspektral veri küpünde piksel mevkilerinin yerleri uzamsal olarak değiştirildiğinde, her iki görüntüye de spektral tabanlı son-üye çıkarım algoritmaları uygulandığında elde edilen sonuçlar değişmeyecektir. Dolayısıyla uzamsal bilginin son-üye çıkarım algoritmalarına bir şekilde dahil edilmesi elde edilen sonuçların doğruluğunu arttıracaktır.

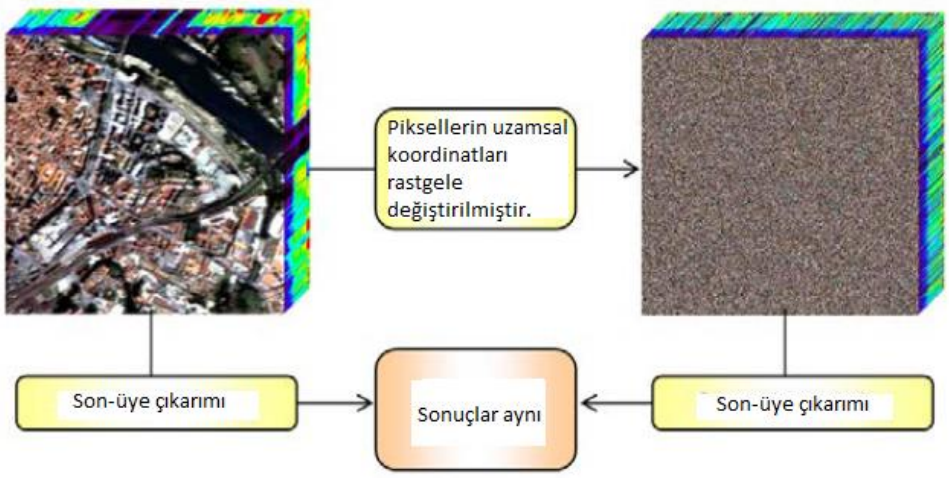

Şekil 4.1 Son-üye çıkarımı safhasında sadece spektral bilginin kullanılması [26]

Son-üye çıkarımı algoritmaları temelde veri setindeki uç noktaları bulmaya çalışırlar. Ancak bazen bu uç noktalar görüntü içerisindeki gürültülü kısımlara da denk gelebilir. Bu kısımların son-üye pikselleri olamayacağı açıktır. Etrafındaki piksel imzalarının

merkezdeki piksel imzalarına yakın olan bölgelerde ise bir homojenlik söz konusu olması nedeniyle bu bölgede gürültü olma ihtimali çok düşüktür, dolayısıyla son-üye çıkarımının bu bölgelerden yapılması daha mantıklı olacaktır. Ancak uzamsal bilgiyi spektral bilgiye dahil ederken bazı durumlara dikkat edilmelidir. Bunlar; uzamsal bilgi kullanılırken spektral bilginin kalitesi düşmemelidir ve bir kılavuz olarak kullanılmalıdır. Düzlemsel bilginin kullanılması için seçilen değişik pencere boyutları sonuçları fazla etkilememesi gerekir ve ek olarak literatürde mevcut olan son-üye çıkarım algoritmalarında yenileme yapmaya ihtiyaç duyulmaması gerekir. Bu durumlar dikkate alındığında bir ön-işleme modülünün mevcut son-üye çıkarım algoritmaları öncesinde kullanılması en uygun yol olarak ortaya çıkmaktadır.

4.1 Uzamsal Ön-işleme (Spatial pre-processing-SPP)

SPP geleneksel spektral tabanlı son üye çıkarım sürecine uzamsal bilginin de dahil edilmesi yöntemidir [27]. Bu sayede son-üyeler piksellerin uzamsal ve spektral özelliklerine göre seçilirler. SPP yönteminin ana fikri, görüntü içerisinde bulunan her bir piksel vektörü için, komşu piksel vektörleri ile arasındaki spektral benzerlik açısından yakından ilişkili sayısal bir değer (faktör) belirlenmesidir. Bu değer ile spektral bilgi ağırlıklandırılır. Matematiksel olarak ifade etmek gerekirse, (4.1)'de $y_{i,j}$, uzamsal koordinatları i, j olan pikseli temsil etmektedir. Bu formül ile bu koordinatlardaki pikselin sayısal faktörünün belirlenmesi hedeflenmektedir. $y_{r.s}$ ise uzamsal komşuluk piksellerini ifade eder.

$$\alpha(i,j) = \sum_{r=i-d}^{i+d} \sum_{s=j-d}^{j+d} \beta[r-i, s-j] \cdot \gamma\left[y_{i,j}, y_{r,s}\right] \tag{4.1}$$

γ fonksiyonu ise piksel ve komşuları arasındaki spektral benzerliği bir başka deyişle spektral açıyı (spektral angle-SA) hesaplar. Bir pencere seçimi yapıldıktan sonra spektral benzerlikler için daha yakın olan komşu pikseller uzakta olanlara göre daha önemlidir. Bu uzaklığa bağlı ağırlık faktörü ise β fonksiyonu ile hesaplanır. Sayısal faktör hesabı yapıldıktan sonra tüm piksellerin spektral içerik mevkisi bu değere göre simpleks yapının merkezine doğru kaydırılır. Bu kaydırma işlemlerinin sayısal faktöre bağlı olarak nasıl gerçekleştirildiği (4.2) ve (4.3)'de ifade edilmiştir.

$$\rho(i,j) = \left(1 + \sqrt{\alpha(i,j)}\right)^2 \tag{4.2}$$

$$\overline{y_{i,j}} = \frac{1}{\rho(i,j)}\left(y_{i,j} - c\right) + c \tag{4.3}$$

Burada c simpleks yapının merkezini gösterir ki bu görüntü içindeki tüm piksellerin spektral içeriklerinin ortalaması alınarak bulunur. $\overline{y_{i,j}}$ ise sayısal faktöre bağlı olarak değişen pikselin spektral içeriğinin yeni mevkisidir. $y_{i,j}$ ise pikselin spektral içeriğinin gerçek mevkisini gösterir. Bu formüllerden de anlaşılacağı üzere yüksek sayısal faktöre sahip piksellerin spektral içerikleri simpleks yapının merkezine doğru daha fazla ilerlerken, düşük sayısal faktöre sahip piksellerin spektral içerikleri merkeze doğru daha az ilerler. Sonuç olarak görüntülerin homojen bölgelerinde yer alan pikseller düşük sayısal faktöre sahiptirler ve bu nedenle simpleks yapının merkezine doğru az mesafe kateder. Fakat geçiş bölgelerinde yer alan piksellerin spektral içeriklerinin simpleks yapının merkezine doğru daha fazla ilerlemeleri nedeniyle yeni oluşan görüntüde, son-üye olarak seçilmeleri olası olmaktan çıkmaktadır.

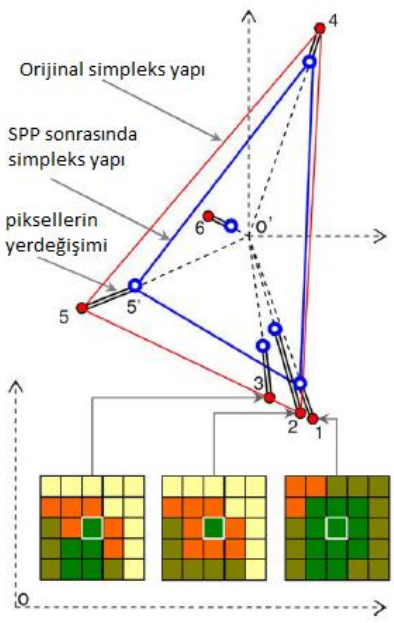

Şekil 4.2 Sayısal faktöre göre piksellerin yerdeğişimi [27]

(4.2)'de ifade edilen sayısal faktörün geometrik olarak basitçe gösterimi Şekil 4.2'de sergilenmiştir. Bu gösterim iki banta indirgenmiş bir hiperspektral veri küpü olarak düşünülebilir. Veri bulutundaki spektral özelliklerin yer değiştirmesi, uzamsal komşuluklarındaki spektral içerik benzerliği ile orantılıdır. Buradaki işlem sonucunda yeni bir simpleks yapı oluşur. Örneğin Şekil 4.2'deki 1 numaralı verinin 3x3 pencere komşuluğunda benzer içeriklere sahip olduğu görülmektedir. Bu nedenle simpleks merkezine doğru en az hareket bu veride oluşmuştur. 2 numaralı verinin komşuluğundaki verilere göre farklı özellikler göstermesi nedeniyle simpleks yapının merkezine doğru en fazla hareket bu veride oluşmuştur. Simpleks yapının köşelerinin muhtemel son-üyeler olduğu da gözönünde bulundurulduğunda, artık bunların homojen bölgelerden seçilme ihtimalleri bu işlem ile arttırılmıştır. Dolayısıyla son-üye çıkarımı öncesinde gürültüye karşı daha etkili olan ön-işleme adımı uygulanabilmektedir. Bu ön-işleme aşamasından sonra uygulanan son-üye çıkarımı adımından sonra yalnızca son-üyelerin mevkileri bulunur. Spektral imzaların seçiminde ise modifiye edilmiş simpleks yerine orjinal simpleks kullanılır. Bunun nedeni diğer safhalarda oluşabilecek hataları engellemek içindir.

SPP uygulaması hiperspektral ayrıştırma problemlerinin çözümü için ortaya konmuş bir çözümdür. Fakat hedef tespiti veya anamoli tespiti gibi problemlerde daha etkisiz olduğu akılda tutulmalıdır. Çünkü bu tarz hedefler uzamsal olarak homojenliğin aranması esnasında zayıflatılmış olabilir.

4.2 Bölgesel Tabanlı Uzamsal Ön-işleme (Region based spatial pre-processing-RBSPP)

Bir önceki kısımda anlatılan SPP yöntemi, belirlenen bir pencerenin görüntü üzerinde dolaştırılması ile uzamsal bilginin kullanılması ile alakalıdır. Bu yöntem spektral içeriğin görüntü üzerinde düzgün olarak yayılması durumunda uygun olmasına rağmen, süreksiz ve parçalı son-üyelerin tespit edilmesi için uygun değildir. Bu tür problemler için farklı bir modele ihtiyaç duyulmaktadır. RBSPP yöntemi [28],[29] bu tarz problemlere de çözüm bulabilmek için geliştirilmiştir. Bu yöntem öncelikle, spektral içerik olarak en saf bölgelerin aranması yani spektral içerik olarak birbirlerine yakın piksellerin gruplandırılmasını hedefler. Bunu, eğiticisiz kümeleme ve dikey alt-uzay

projeksiyonu yöntemlerini birleştirerek yapar. Bu işlemden sonra son-üye çıkarımı algoritması yalnızca bu piksellerin kullanılması ile sonuç verir. Dolayısıyla RBSPP yöntemi son-üyelerin geçiş alanlarından ziyade uzamsal olarak homojen bölgelerde olacağı temeli üzerine kurulmuştur. Homojen alanların son-üye çıkarma algoritmaları için iyi bir aday piksel vektörü olduğunu varsaydığımızda, spektral tabanlı bu algoritmaları uzamsal bilgiyi kullanarak bu alanlara yönlendirebiliriz. Ancak bu işlemler yapılırken seçilen bölgeler aynı zamanda spektral içerik olarak da saf olmalıdırlar. Çünkü uzamsal olarak homojen olan bir bölge aynı zamanda spektral içerik açısından birkaç son-üyenin birleşiminden oluşmuş alanlar olabilir. Bu konu RBSPP'nin SPP'den en büyük farkını gösterir. Çünkü SPP'de yalnızca uzamsal homojenlik hesaba katılırken, RBSPP'de uzamsal homojenlik ve spektral saflığın ikisi birden incelenir.

Kümeleme işlemi temel olarak spektral olarak benzer içeriklere sahip piksellerin aynı gruba dahil olmalarını hedefler. RBSPP uygulamasının kümeleme aşamasında ISODATA [30] algoritması kullanılmıştır. Algoritma görüntü içerisindeki piksel vektör verilerinin daha önceden belirlenen g tane aday kümeye rastgele olarak dağıtılması ile başlar. Daha sonra yinelemeli olarak bu bölümler en küçük kareler yöntemi [31] kullanılarak optimize edilir. Burada en önemli nokta son-üye sayısı yani küme sayısının seçimidir. Özellikle bu algoritmanın küme sayısını yani g'yi otomatik olarak belirlemesi için, mevcut dataya göre minimum küme sayısı ve maksimum küme sayısı belirlenebilir. Spektral kümeleme sonrasında uzamsal olarak birleştirilmiş bölgelere ayrılır. Bulunan her bölge için temsilci bir imza (ortalama spektrum) seçilir. Sonra OSP uygulanarak uzamsal olarak temsilci bölgeler seçilir. Bu sayede hem spektral bilgi hem de uzamsal bilgi kullanılmış olur. Sonrasında ise spektral tabanlı son-üye çıkarım algoritmaları uygulanır. Burada önemli olan konu bu algoritmaların yalnızca temsilci bölgelerde seçilen spektral içeriklere uygulanmasıdır. Bu algoritmaların ortalama spektraya uygulanmamasının sebebi ise son-üye imza saflığını azaltmaları nedeniyledir.

RBSPP uygulaması SPP uygulaması gibi problem odaklı oluşturulmuş yöntemlerdir. RBSPP yöntemi de anamoli tespiti veya hedef tespiti yapmak için uygun değildir. Bu yöntemlerin odağı hiperspektral ayrıştırma problemleridir.

Şekil 4.3'de RBSPP uygulaması sentetik bir veri üzerinde görselleştirilmiştir. 9 tane son-üyeye sahip bir görüntü üzerine gürültü eklenmiş ve bu son-üyeler piksellere belirli oranlarda dağıtılmıştır. Veri küpü 100x100 piksel ve 221 banttan oluşmaktadır. ISODATA algoritması sınıflandırma haritasını çıkarmak maksadıyla kullanılmıştır.

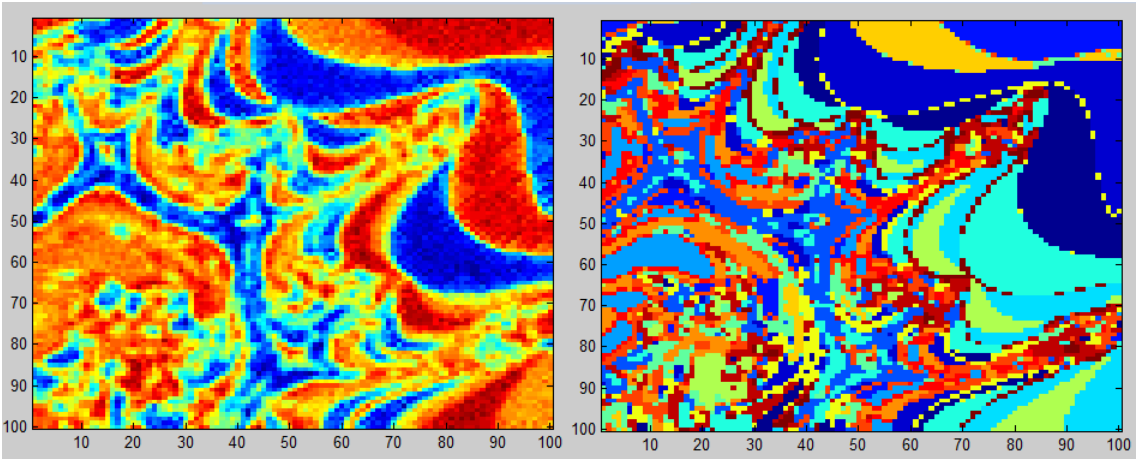

(a) (b)

Şekil 4.3 Sentetik veri (a) Oluşturulan sentetik verinin 50. bantı (b) ISODATA algoritması ile elde edilen sınıflandırma haritası

Sınıflandırma haritası çıkarıldıktan sonra, son-üye sayısı bilinmesi nedeniyle minimum sınıf sayısı 9'a, maksimum sınıf sayısı ise iki kat olacak şekilde 18'e ayarlanmıştır. Bu şekilde sınıflara ait temsilcilerin bulunması amacıyla RBSPP algoritması uygulanmıştır. Sonuç olarak bulunan temsilci spektral içeriklere ait bölgeler Şekil 4.4'te gösterilmiştir. Bundan sonra kalan bu pikseller üzerinden geometrik tabanlı son üye çıkarım yöntemleri uygulanabilir.

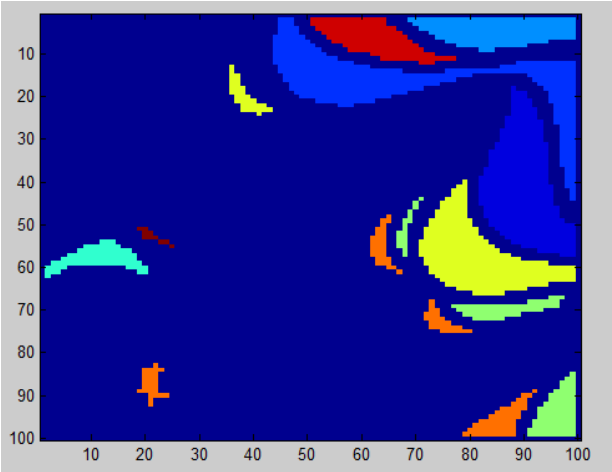

Şekil 4.4 Son-üye çıkarımı safhasında kullanılacak pikseller

BÖLÜM 5

HİPERSPEKTRAL GÖRÜNTÜLERDE GÜRÜLTÜ GİDERİMİ YÖNTEMLERİ

Hiperspektral görüntüler, uydu üzerindeki algılayıcıların güç kaynaklarındaki dalgalanmalar nedeniyle dürtü gürültüsü içerirler. Dürtü gürültüsü aynı zamanda algılayıcının cevabı doygunlaştığında ya da algılayıcı örneklemler alamayınca da oluşabilir. Hiperspektral görüntülerde dürtü gürültüsünün mevcudiyeti yeni incelenmiş bir konudur [32],[33],[34]. Hiperspektral görüntüler dürtü gürültüsü haricinde Gauss gürültüsü, dikey veya yatay çizgi gürültüleri de içerebilirler. Dolayısıyla hiperspektral görüntülerde gürültü giderimi işlemi birkaç karışık gürültüyü örneğin Gauss gürültüsünü ve ayrık gürültüyü içerebilir. Burada ayrık gürültü tabiri yalnızca bazı piksellerin yoğun olarak gürültüye maruz kaldıkları durumu ifade etmektedir. Hiperspektral görüntülerde gürültülerin ön-işleme süreciyle giderilmesi birçok uygulama için gerekmektedir.

5.1 Genel Analiz Öncelikli Algoritması (General Analysis Prior Algorithm-GAP)

Görüntülerdeki gürültünün giderimi için total varyasyon (Total variation-TV) düzenlemesi [35] sıklıkla kullanılmaktadır ve aşağıdaki şekilde formüle edilmiştir:

$$\|y - x\|_1 + \|D_h x\|_1 + \|D_v x\|_1 \tag{5.1}$$

D_h, D_v yatay ve dikey fark operatörleridir. y gürültülü görüntü ve x düzeltilmiş görüntüyü ifade eder. Bu formülasyon analiz öncelikli problem olarak tanımlanmıştır. Ancak bu çalışma tek bandda gürültü giderimi ile sınırlıdır. Hiperspektral görüntülerde

bu işlem tüm bantlar için ayrı ayrı yapılmaktadır ve bantlar arası korelasyonu hesaba katmamaktadır. [36]'daki çalışmada ise, tanımlanan GAP algoritması ile bu problem çözülmektedir. Bu algoritma dürtü gürültüsünün giderilmesi için hem spektral hem de uzamsal bilgiyi hesaba katar. Bu algoritmanın diğer gürültü giderici algoritmalara karşı zirve sinyal gürültü oranı (peak signal to noise ratio-PSNR) açısından üstünlüğü [36]'da gösterilmiştir.

(5.1)'deki formülü farklı olarak aşağıdaki şekilde de ifade edilebilir;

$$\arg\min \|Y - X\|_1 + \lambda\|D_h XD\|_1 + \lambda\|D_v XD\|_1 \tag{5.2}$$

$$\text{bağlı olarak } \begin{aligned} P &= Y - X \\ Q &= D_h XD \\ R &= D_v XD \end{aligned} \tag{5.3}$$

split-Bregman yaklaşımı kullanılarak yukarıdaki problem ceza fonksiyonunun eklenmesi ile kısıtlaması olmayacak şekilde aşağıdaki gibi ifade edilebilir;

$$\begin{aligned} &\min_{X,P,Q,R,S} \|P\|_1 + \lambda\|Q\|_1 + \lambda\|R\|_1 + \mu_1\left\|P - Y + X - B_1^k\right\|_F^2 \\ &+ \mu_2\left\|Q - D_h XD - B_2^k\right\|_F^2 + \mu_2\left\|R - D_v XD - B_3^k\right\|_F^2 \end{aligned} \tag{5.4}$$

Burada Bregman değişkenleri aşağıdaki şekilde güncellenir;

$$\begin{aligned} B_1^{k+1} &= B_1^k + Y - X - P \\ B_2^{k+1} &= B_2^k + D_h XD - Q \\ B_3^{k+1} &= B_3^k + D_v XD - R \end{aligned} \tag{5.5}$$

Çözüm kolaylığı açısından bazı değişkenler tanımlanmıştır;

$$\begin{aligned} &y_1 = vec(P - Y - B_1^k),\ y_2 = vec(Q - B_2^k), \\ &y_3 = vec(R - B_3^k), W_h = D^T \otimes D_h, W_v = D^T \otimes D_v \end{aligned} \tag{5.6}$$

Bu değişkenler de tanımlandıktan sonra (5.4)'teki problem dört ayrı probleme bölünerek çözümlenebilir.

$$\min_{x} \ \mu_1 \|y_1 + x\|_2^2 + \mu_2 \|y_2 - W_h x\|_2^2 + \mu_2 \|y_3 - W_v x\|_2^2 \tag{5.7}$$

$$\begin{aligned} &\min_{P} \|P\|_1 + \mu_1 \left\|Y - X - P + B_1^k\right\|_F^2 \\ &\min_{Q} \|Q\|_1 + \mu_2 \left\|Q - D_h X D - B_2^k\right\|_F^2 \\ &\min_{R} \|R\|_1 + \mu_2 \left\|R - D_v X D - B_3^k\right\|_F^2 \end{aligned} \tag{5.8}$$

(5.7)'deki problemin türevi alınabilir ve basitleştirme yapıldıktan sonra aşağıdaki sonuç elde edilir.

$$\left[\mu_1 I + \mu_2 W\right] x = \mu_2 \left(W_h^T y_2 + W_v^T y_3\right) - \mu_1 y_1 \tag{5.9}$$

En küçük kareler yöntemi (least squares-LSQR) [37], denklem (5.9)'u çözmek için kullanılır. Çümkü denklemin sol tarafında x'in katsayısı sabittir. Eşitliğin sağ tarafındaki değişken sonuçlara göre x tahmin edilmektedir. (5.8)'deki problemler ise yumuşak eşikleme yöntemi ile çözülürler. [36]'daki çalışmada Washington DC hiperspektral görüntüsüne yüzde 50 oranında tuz ve karabiber gürültüsü eklenmiş daha sonra GAP algoritması uygulanarak görsel olarak orjinal görüntüye yakın bir sonuç elde edilmiştir. Elde edilmiş görsel sonuçlar Şekil 5.1'de gösterilmiştir.

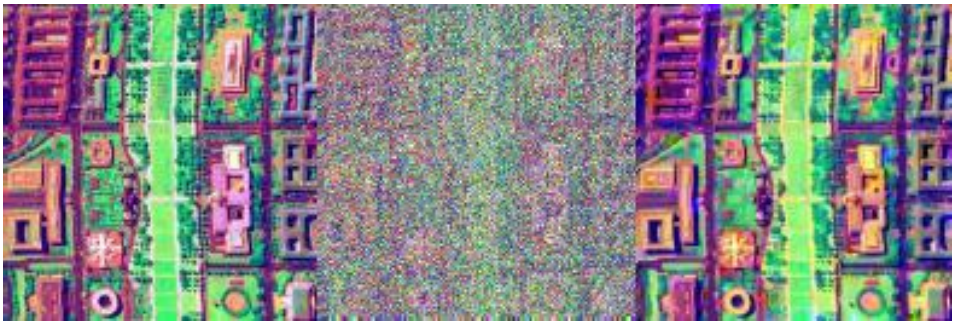

(a) (b) (c)

Şekil 5.1 GAP uygulama (a) Washington DC hiperspektral verisi (b) Gürültü eklenmiş görüntü (c) GAP algoritması uygulanmış görüntü [36]

5.2 Uzamsal-Spektral Total Varyasyon (Spatio-spectral total variation-SSTV)

Hiperspektral görüntülertülerdeki gürültülerin giderilmesi maksadıyla ortaya konulacak model yalnızca Gauss gürültüsünü değil aynı zamanda ayrık gürültüleri de hesaba

katarak gürültü giderim işlemini yapmalıdır. Görüntülerde Gauss gürültüsü ve ayrık gürültü bulunduğunda şu şekilde modellenir:

$$Y = X + S + G \tag{5.10}$$

Burada Y gürültülü görüntüyü, X orijinal görüntüyü, S ayrık gürültüyü, G ise gauss gürültüsünü göstermektedir. Doğal görüntülerin çoğunda pikseller komşuluğundaki pikseller ile uzamsal olarak korelasyonludur. Komşu bantlar da yine yüksek spektral korelasyona sahiptirler [38]. Bu ön bilgiler görüntüleri total varyasyon düzenlemesi ile modellerken kullanılabilir. Gri tonlamalı bir x görüntüsünde toplam varyasyon (TV) şu şekilde gösterilir:

$$TV(x) = \|D_h x\|_1 + \|D_v x\|_1 \tag{5.11}$$

Burada D_h ve D_v dikey ve yatay fark operatörleridir. Renkli görüntüler yani d bantlı görüntüler için bu formül şu şekli alır:

$$HTV(x) = \sum_{i=1}^{d} TV(x_i) \tag{5.12}$$

Gürültü giderim işlemi HTV modeli ile aşağıdaki şekli alır:

$$\min_{X,S} \|Y - X - S\|_F^2 + \lambda \|S\|_1 + \mu \times HTV(x) \tag{5.13}$$

Bu HTV tabanlı hiperspektral gürültü giderim modeli yalnızca uzamsal korelasyonu hesaba katar. Komşu bantlardaki spektral korelasyonu da içermesi için SSTV modeli geliştirilmiştir:

$$SSTV(x) = \|D_h XD\|_1 + \|D_v XD\|_1 \tag{5.14}$$

Gürültü giderim işlemi SSTV modeli ile aşağıdaki şekli alır:

$$\min_{X,S} \|Y - X - S\|_F^2 + \lambda \|S\|_1 + \mu \times SSTV(x) \tag{5.15}$$

Burada λ ve μ terimleri düzenleyici parametrelerdir. Burada (5.10)'dan anlaşılacağı üzere $G = Y - X - S$ olması nedeniyle formül ile gauss gürültüsünün varyansının düşürülmesi hedeflenmektedir. (5.15)'teki işlem açılırsa:

$$\min_{X,S} \|Y - X - S\|_F^2 + \lambda\|S\|_1 + \mu\|D_h XD\|_1 + \mu\|D_v XD\|_1 \tag{5.16}$$

$P = D_h XD$ ve $Q = D_v XD$ olarak iki değişken tanımlarsak (5.16) işlemi kısıtlamalı bir minimizasyon problemine dönüşür. Bahsekonu kısıtlandırılmış optimizasyon problemi ikinci dereceden bir ceza fonksiyonunun eklenmesi ile kısıtlamasız bir problem halini alır.

$$\begin{aligned} &\underset{P,Q,X,S}{küçültülecek} \|Y - X - S\|_F^2 + \lambda\|S\|_1 + \mu\|P\|_1 + \mu\|Q\|_1 \\ &+ \nu\|P - D_h XD\|_F^2 + \nu\|Q - D_v XD\|_F^2 \end{aligned} \tag{5.17}$$

Burada ν dikey ve yatay total varyasyon düzenleme terimidir. Yukarıdaki problem dört değişkenli hale gelmesine rağmen ayrılabilir problemlere dönüşmüştür. Split-Bregman yaklaşımı [39], bu problemin çözümü için kullanılmıştır. B_1 ve B_2 bregman değişkenleri kullanılarak problem aşağıdaki hale getirilebilir:

$$\begin{aligned} &\underset{P,Q,X,S}{küçültülecek} \|Y - X - S\|_1^2 + \lambda\|S\|_1 + \mu\|P\|_1 + \mu\|Q\|_1 \\ &+ \nu\|P - D_h XD - B_1\|_F^2 + \nu\|Q - D_v XD - B_2\|_F^2 \end{aligned} \tag{5.18}$$

Bu problem daha kolay çözüm için dört ayrı problem şeklinde de düşünülebilir:

$$\min_P \ \mu\|P\|_1 + \nu\|P - D_h XD - B_1\|_F^2 \tag{5.19}$$

$$\min_Q \ \mu\|Q\|_1 + \nu\|P - D_v XD - B_2\|_F^2 \tag{5.20}$$

$$\min_S \ \lambda\|S\|_1 + \|Y - X - S\|_F^2 \tag{5.21}$$

$$\min_X \|Y - X - S\|_F^2 + \nu\|P - D_h XD - B_1\|_F^2 + \nu\|Q - D_v XD - B_2\|_F^2 \tag{5.22}$$

İlk üç problem yumuşak eşikleme [40] ile çözülürken, son problem ise en küçük kareler yöntemi ile çözülmektedir. Washington DC hiperspektral verisine gauss gürültüsü, tuz ve biber gürültüsü, çizgi gürültüleri eklenmiş, sonrasında SSTV yöntemi uygulanarak bu gürültülerin giderilmesi sağlanmıştır. Elde edilen görsel sonuçlar Şekil 5.2'de sergilenmiştir.

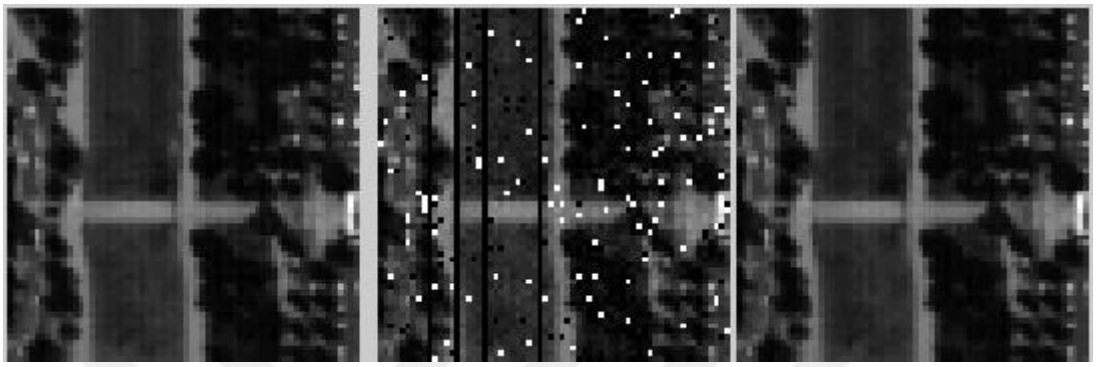

(a) (b) (c)

Şekil 5.2 SSTV uygulama (a) Washington DC hiperspektral verisi (b) Gürültü eklenmiş görüntü (c) SSTV yöntemi uygulanmış görüntü

BÖLÜM 6

DENEYSEL SONUÇLAR

6.1 Kullanılan Hiperspektral Veri

Kentsel HYDICE hiperspektral verisi [41] ayrıştırma problemleri için en yaygın kullanılan verilerden bir tanesidir. Görüntüde her bantta 307x307 piksel mevcuttur. Her bir piksel ise 2x2 m^2'lik bir alana tekabül eder. 400 ile 2500 nm. arasında kısa aralıklarla 210 ayrı dalga boyunda alınmış veriler bulunur. Spektral çözünürlük 10 nm.'dir. 12., 99., ve 171. bantların Kırmızı, Yeşil ve Mavi (RGB) bantlarına denk geldiği düşünülerek bu bantların birleşimi ile sahte renkli görüntü Şekil 6.1'deki şekilde elde edilir.

Şekil 6.1 Kentsel HYDICE veri setinin sahte renkli görüntüsü

Su buharı emilimi ve düşük SNR bantları görüntüden çıkarıldığında (1-4, 76, 87, 101-111, 136-153, 198-210) 162 kullanılabilir bant kalır. Görüntü incelendiğinde asfalt yol, beton, çatı, çimen, ağaçlar, metal son-üyelerinin bulunduğu görülmektedir. Algoritmaların doğruluğunun değerlendirilmesi için her bir son-üye için 15 tane olacak

şekilde 90 adet piksel seçilmiştir. Seçilen bu piksellerin ortalaması alınarak son-üyelere ait spektral imzalar referens spektra olarak adlandırılmıştır. Bu yöntem ile görüntü üzerinde 4,5 ve 6 son-üye bulunduğu varsayımına göre çıkarılan referans spektralar sırasıyla Şekil 6.2, Şekil 6.3 ve Şekil 6.4'te gösterilmiştir. Görüntüde 4 son üye bulunduğu varsayımına göre asfalt yol, çimen, ağaç, çatı son üyelerinin spektral imzaları verilmiştir. 5 son üye bulunması durumunda beton, 6 son üye bulunması durumunda ise metal son-üyesi de eklenmiştir.

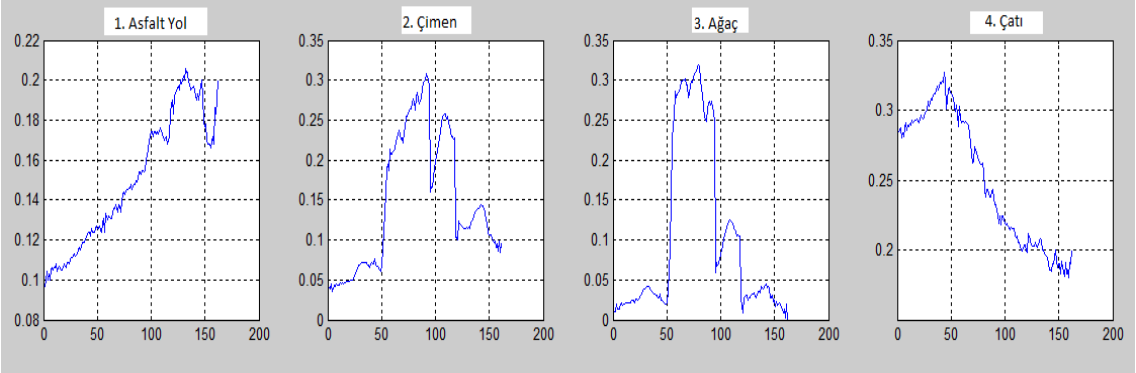

Şekil 6.2 Dört son üye için referans spektralar

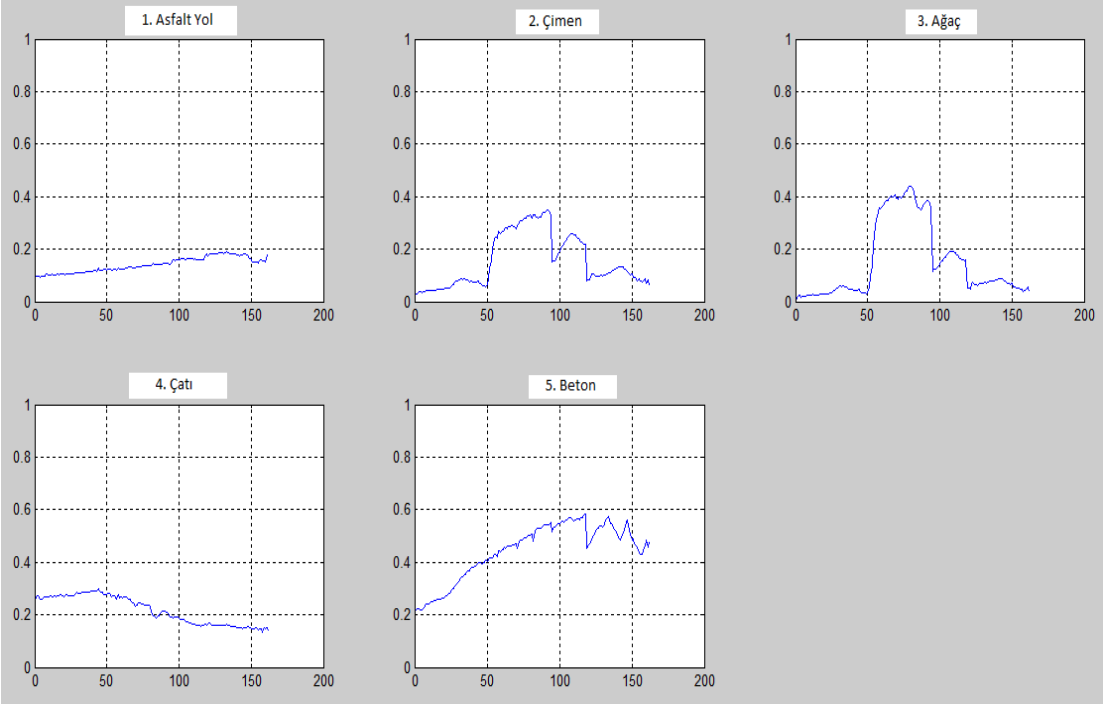

Şekil 6.3 Beş son üye için referans spektralar

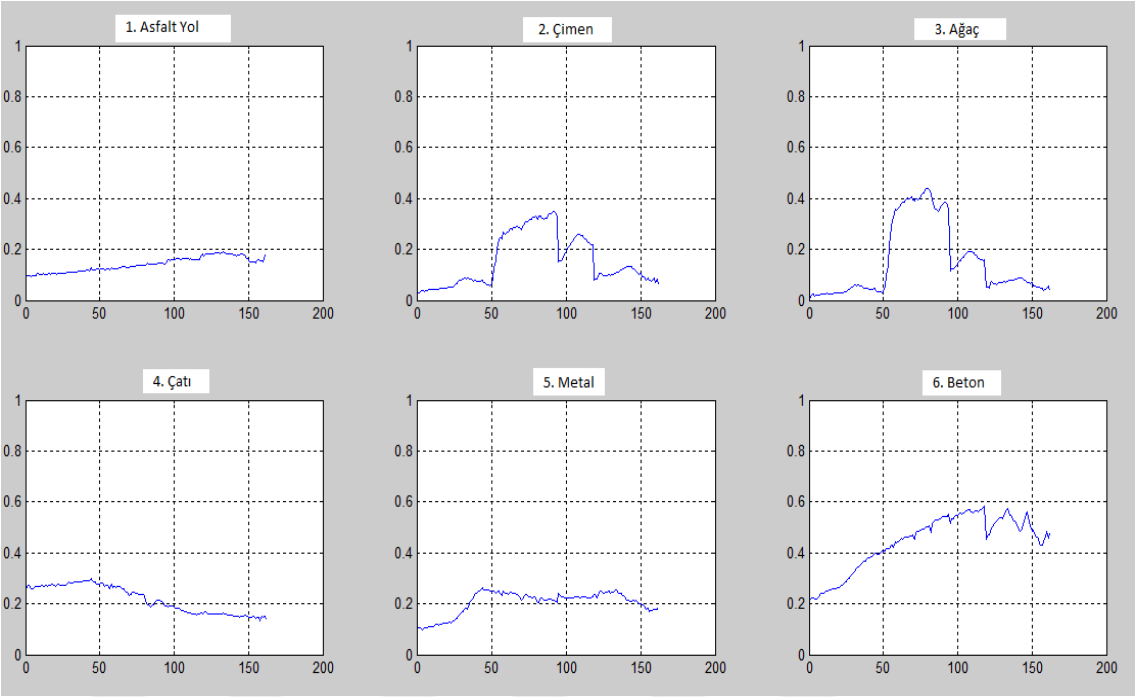

Şekil 6.4 Altı son üye için referans spektralar

6.2 Performans Kriterleri

Hiperspektral görüntülerde ayrıştırma problemlerinin çözümünde amaç, son-üyelerin spektral imzalarının doğruya yakın olarak bulunması ve görüntü içerisindeki her bir pikselde son-üyelerin hangi oranda bulunduklarının tespit edilmesidir. Bu nedenle uygulanan yöntemlerin etkinliklerinin ölçülmesi maksadıyla bazı yöntemler geliştirilmiştir. Bu çalışmada yöntemin bulduğu spektral imza ile referans spektranın benzerliğinin ölçümü için Spektral Açı Haritalama (Spectral Angle Mapper-SAM) [42], bolluk oranlarının karşılaştırılması için ise kök ortalama kare hatası (root mean square error-rmse) [43] kullanılmıştır.

6.2.1 Spektral Açı Haritalama (Spectral Angle Mapper-SAM)

SAM, referans spektrumlar ile algoritmalardan elde edilen spektrumlar arasındaki benzerliği ölçmek için kullanılır. SAM Şekil 6.5'de görüldüğü gibi iki spektrum arasındaki açıyı hesaplayarak birbirlerine benzerlik ölçümünü yapar. Açı ne kadar küçük olursa benzerlik o kadar fazla olur. Bu yöntem için ölçekleme gerekli değildir. Çünkü yöntem vektörlerin uzunluğunu kullanmak yerine sadece vektör yönlerini kullanır. Bu

karşılaştırma için SAM kullanılmasının ana nedenidir. Aradaki açı aşağıdaki şekilde hesaplanabilir; t hedef spektrum, r referans spektrum olmak üzere;

$$\cos^{-1}\left(\frac{\vec{t}\cdot\vec{r}}{\left\|\vec{t}\right\|\cdot\left\|\vec{r}\right\|}\right) \tag{5.1}$$

Aynı açı aşağıdaki şekilde de ifade edilebilir;

$$a = \arccos\frac{\sum_{t=1}^{n} x_i y_i}{\sqrt{\sum_{i=1}^{n} x_i^{\,2}}\sqrt{\sum_{i=1}^{n} y_i^{\,2}}} \tag{5.2}$$

Burada n bantların sayısını, x ve y ise spektral vektörleri göstermektedir.

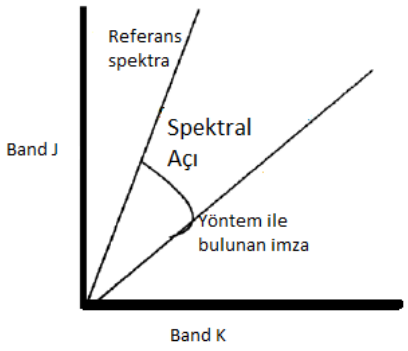

Şekil 6.5 Spektral açı gösterimi

6.2.2 Ortalama Karesel Hata (Root Mean Square Error-RMSE)

Diğer bir metrik olan RMSE ise yöntemler ile bulunan her bir piksele dair bolluk oranlarının, gerçek bolluk oranlara benzerliğinin ölçülmesi için kullanılmaktadır ve (5.3)'teki gibi hesaplanır.

$$rmse_k = \left(\frac{1}{K}\sum\left(S_{kj} - \hat{S}_{kj}\right)^2\right)^{\frac{1}{2}} \tag{5.3}$$

Bu formülde S gerçek bolluk oranlarını $\hat{S}$ ise tahmini bolluk oranlarını göstermektedir. rmse skoru ise benzerliği gösterir ve ne kadar düşük olursa benzerlik o kadar fazla olur.

6.3 Deneme Sonuçları (Çalışma 1)

Kentsel HYDICE verisi üzerinde son üye çıkarımı maksadıyla VCA, N-finder, MVSA, SISAL, AVMAX, SVMAX algoritmaları kullanılmıştır. Bu algoritmaları çalıştırmak için veri küpüne ve son-üye sayısına ihtiyaç vardır. Her bir algoritma için SAM ve RMSE hesaplamaları sırasıyla 4,5 ve 6 son üye sayılarına göre yapılmıştır. İlk önce algoritmaların orjinal veri üzerinde performansları değerlendirilmiş, sonrasında ise gürültüsü giderilmiş veri üzerinde sonuçlar elde edilmiştir. Görüntüde dürtü gürültüsünün giderimi için uzamsal-spektral korelasyondan yararlanan GAP algoritması kullanılmıştır. Orjinal görüntüdeki 80. ve 110. bant ve uzamsal-spektral korelasyonu yapılmış 80. ve 110. bant görüntüsü Şekil 6.6'da gösterilmiştir.

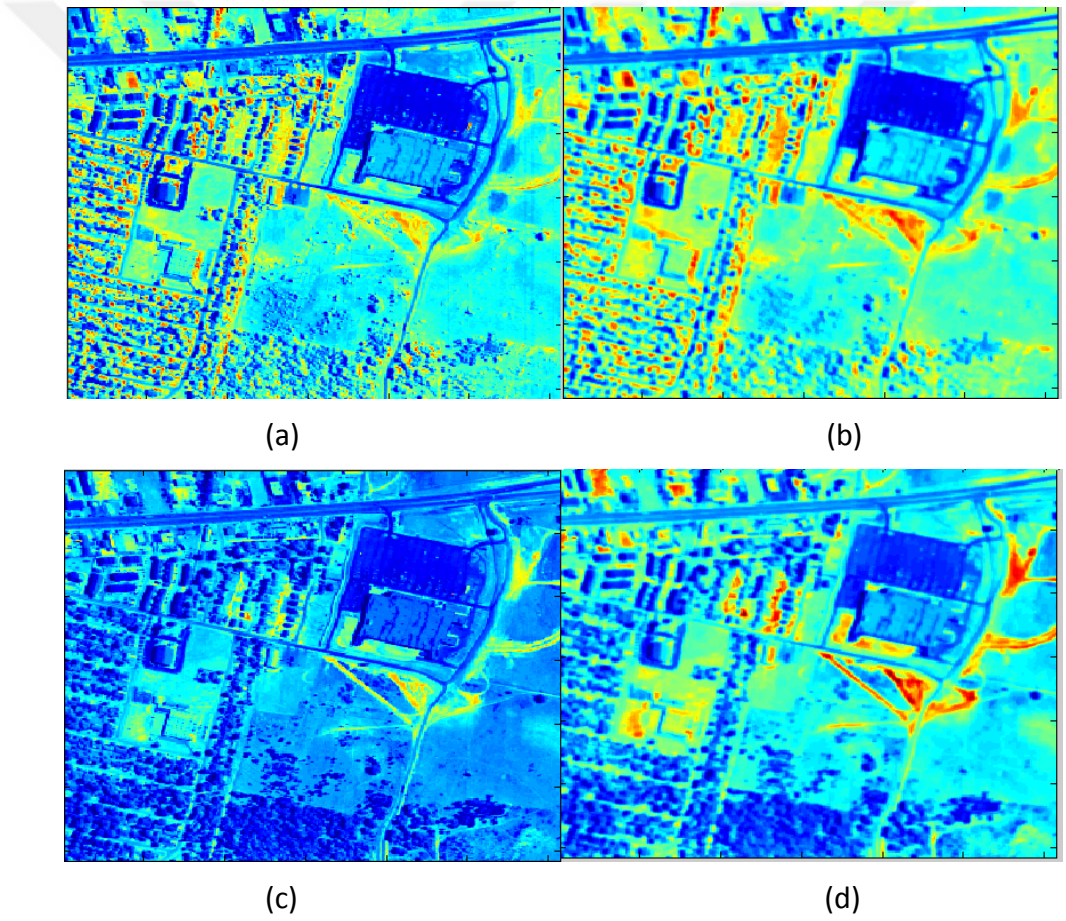

(a) (b)

(c) (d)

Şekil 6.6 GAP yöntemi (a) Kentsel HYDICE verisi (80. bant) (b) GAP uygulanmış veri (80. bant) (c) Kentsel HYDICE verisi (110. bant) (d) GAP uygulanmış veri (110. bant)

GAP algoritması uygulanırken parametreler ampirik olarak seçilmiştir. $(\lambda, \mu_1, \mu_2, \max iter) = (2,2,2,50)$. MATLAB 10 bant üzerinde hafıza hatası verdiğinden gürültü giderim işlemi önce 10 bant için sonra diğer 10'lu bantlar için yapılmış ve işlem

sonucunda bu bantlar birleştirilerek gürültüsü giderilmiş bantlar elde edilmiştir. Ancak bant sayısının arttırılmasının daha iyi bir gürültü giderimi sağlayacağı bilinmektedir. Çünkü algoritma uzamsal ve spektral bilgiyi birlikte kullanmaktadır. VCA, MVSA, SISAL, AVMAX gibi algoritmalar her çalıştırıldıklarında farklı sonuçlar vermesine neden olan rastgele başlangıç koşulları içerir. Bu nedenle bu algoritmalar 20'şer kez çalıştırılmış ve ortalama değerler alınmıştır. Görüntüde 4 son üye bulunduğu varsayımına göre elde edilmiş sonuçlar Çizelge 6.1'de, 5 son üye bulunduğu varsayımına göre edilmiş sonuçlar Çizelge 6.2'de, 6 son üye bulunduğu varsayımına göre elde edilmiş sonuçlar Çizelge 6.3'de sergilenmiştir.

Çizelge 6.1 Dört son üye varsayımına göre SAM sonuçları

YÖNTEM	SON ÜYE				
	Asfalt Yol	Çimen	Ağaç	Çatı	Ortalama
VCA (orijinal)	0,8198	0,5842	0,2784	0,8228	0,6263
VCA (GAP uygulanmış)	0,5838	**0,2164**	0,0827	0,438	0,3302
N-finder (orijinal)	1,1535	0,5937	0,0744	0,2174	0,5097
N-finder (GAP uygulanmış)	0,4902	0,3876	0,0678	0,1043	0,2625
AVMAX (orijinal)	1,1105	0,5754	0,0848	0,1676	0,3231
AVMAX (GAP uygulanmış)	0,4784	0,3728	0,1224	0,0919	0,2664
SVMAX (orijinal)	1,1231	0,4507	**0,0558**	0,1676	0,4493
SVMAX (GAP uygulanmış)	**0,3779**	0,3728	0,1224	0,0919	**0,2413**
OSP (orijinal)	1,1556	0,4689	0,0743	0,2174	0,4791
OSP (GAP uygulanmış)	0,434	0,3876	0,0678	**0,0907**	0,245
MVSA (orijinal)	2,6568	0,5547	0,4216	0,1647	0,9495
MVSA (GAP uygulanmış)	2,8098	0,5629	0,1637	0,1196	0,914
SISAL (orijinal)	2,5779	0,5496	0,3164	0,1982	0,9105
SISAL (GAP uygulanmış)	2,6313	0,555	0,2803	0,1478	0,9036

Koyu olarak belirtilmiş rakamlar algoritmalar içerisindeki en iyi sonuçları göstermektedir. En iyi sonuçlar bir son üye haricinde gürültüsü giderilmiş görüntülerde

elde edilmiştir. Ağaçların imzasına en yakın imza, orijinal görüntüye SVMAX algoritmasının uygulanması ile elde edilmesine rağmen, diğer sonuçların da birbirine yakın olduğu gözükmektedir. Görüntüde her bir son üye için saf piksel bulunduğu varsayımına dayanan yöntemler daha başarılı sonuçlar elde etmiştir. Asfalt yolun imzası geometrik tabanlı algoritmalar için en kötü sonuçların alındığı son üye olmuştur.

Çizelge 6.2 Beş son üye varsayımına göre SAM sonuçları

YÖNTEM	SON ÜYE					
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Beton**	**Ortalama**
VCA (orijinal)	0,8088	0,7233	0,3442	0,8283	0,326	0,6061
VCA (GAP uygulanmış)	0,5644	0,2791	0,1377	0,2324	0,2869	0,3001
N-finder (orijinal)	1,141	0,116	0,1227	0,174	0,2223	0,3552
N-finder (GAP uygulanmış)	0,4821	0,6369	0,1268	0,1009	0,0626	0,2819
AVMAX (orijinal)	1,1313	**0,1127**	0,1517	0,1388	0,2578	0,3585
AVMAX (GAP uygulanmış)	0,5605	0,2986	0,0801	**0,0851**	0,1849	0,2418
SVMAX (orijinal)	1,1313	**0,1127**	0,1103	0,1388	0,145	0,3276
SVMAX (GAP uygulanmış)	0,4755	0,6363	**0,0683**	0,0855	**0,057**	0,2645
OSP (orijinal)	1,1433	0,6569	0,1227	0,1462	0,1661	0,447
OSP (GAP uygulanmış)	**0,3021**	0,5186	0,0689	0,1011	0,0626	**0,2107**
MVSA (orijinal)	2,621	0,3461	0,5595	0,3826	0,3289	0,8476
MVSA (GAP uygulanmış)	2,5073	0,1347	0,2528	0,1993	0,2955	0,6779
SISAL (orijinal)	2,5633	0,1778	0,4097	0,3336	0,3161	0,7601
SISAL (GAP uygulanmış)	2,5533	0,1522	0,2579	0,1853	0,2481	0,6794

Görüntü içerisinde 5 adet son üye olması varsayımında beton elemanı 5. son üye olarak eklenmiştir. Yine asfalt yolun imzasının geometrik tabanlı algoritmalar ile tahmini, referans spektraya yakın bulunamamıştır. Çimen ve ağaçların spektral imzalarının birbirlerine yakın olmaları sebebi ile GAP algoritması ile spektral korelasyon uygulandıktan sonra ayırt edilememekte ve aynı son üye olarak görülmektedir.

Çizelge 6.3 Altı son üye varsayımına göre SAM sonuçları

YÖNTEM	SON ÜYE						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
VCA (orijinal)	0,5928	0,4428	0,3542	0,8129	0,685	0,3787	0,5444
VCA (GAP uygulanmış)	0,4812	0,4345	0,1998	0,1952	0,3473	0,1379	0,2993
N-finder (orijinal)	0,4754	0,116	0,1227	0,174	1,1624	0,2771	0,3879
N-finder (GAP uygulanmış)	0,5638	0,6423	0,0868	0,1009	0,2076	0,096	0,2829
AVMAX (orijinal)	1,1364	**0,1137**	0,1097	0,1397	0,2841	0,2713	0,3425
AVMAX (GAP uygulanmış)	0,5632	0,6369	0,0697	0,086	**0,206**	0,0699	0,272
SVMAX (orijinal)	1,1364	0,1137	0,1097	0,1397	0,2841	0,1538	0,3229
SVMAX (GAP uygulanmış)	0,4752	0,6369	**0,0676**	**0,0859**	**0,206**	**0,056**	**0,2546**
OSP (orijinal)	1,1433	0,6569	0,1227	0,1462	0,2742	0,1091	0,4087
OSP (GAP uygulanmış)	**0,4672**	0,6369	0,0689	0,1011	0,2105	0,0626	0,2579
MVSA (orijinal)	1,6643	1,0515	0,4603	0,5098	1,2594	0,3242	0,8783
MVSA (GAP uygulanmış)	1,8943	0,8288	0,2626	0,2089	1,1455	0,2388	0,7632
SISAL (orijinal)	1,9077	0,7402	0,363	0,3189	1,8632	0,2866	0,9133
SISAL (GAP uygulanmış)	1,8508	1,6237	0,2346	0,1854	1,0219	0,1972	0,8523

Görüntü içerisinde 6 adet son üye olması varsayımında metal elemanı 6. son üye olarak eklenmiştir. Yine asfalt yolun imzasının geometrik tabanlı algoritmalar ile tahmini, referans spektraya yakın bulunamamıştır.

Tüm sonuçlar incelendiğinde saf piksel varsayımına dayanan algoritmaların son üye çıkarımı safhasında daha başarılı oldukları görülmüştür. Buradan yüzey materyalleri için hiperspektral veri küpünde saf pikseller bulunduğu çıkarımı yapılabilir. Bir sonraki çalışmada bu nedenle yalnızca saf piksel varsayımına dayanan algoritmalar kullanılacaktır.

Bir pikselde mevcut son üyelerin bolluk oranlarının tahmini için tam kısıtlı en küçük kareler (Fully Constrained Least Squares-FCLS) yöntemi geliştirilmiştir [44]. Yöntem

hem toplamların bire eşit olma kısıtını (Denklem (2.2)), hem de negatif olamama kısıtını (Denklem (2.3)) sağlamaktadır. Çizelge 6.4'te yöntemler ile elde edilmiş bolluk oranlarının karşılaştırılmasını göstermektedir. Bunlar tüm son üyeler için elde edilen sonuçların ortalamasıdır. Algoritmaların bazı son üyeleri gerçeğe yakın olarak tahmin edememesi FCLS yöntemi sonuçlarını etkilemiştir. Buradan bolluk oran tahminlerinin son üye imzalarının doğru tahminine sıkıca bağlı olduğu anlaşılmaktadır. Yalnızca bir yanlış son üye tahmini, ortalama bolluk oran tahminlerinin daha kötü olarak sergilenmelerine neden olabilmektedir.

Çizelge 6.4 Kentsel veriden yöntemler ile elde edilen bolluk oranlarının rmse açısından benzerlik sonuçları

YÖNTEM	4 SON ÜYE	5 SON ÜYE	6 SON ÜYE
VCA (orijinal)	0,3418	0,371	0,3023
VCA (GAP uygulanmış)	0,2552	0,1845	0,2004
N-finder (orijinal)	0,3566	0,2178	0,1949
N-finder (GAP uygulanmış)	0,3971	0,2533	0,2273
AVMAX (orijinal)	0,3586	0,2029	0,2774
AVMAX (GAP uygulanmış)	0,397	0,2297	0,2209
SVMAX (orijinal)	0,3572	0,2174	0,2771
SVMAX (GAP uygulanmış)	0,4016	0,2547	0,2228
OSP (orijinal)	0,3558	0,2402	0,207
OSP (GAP uygulanmış)	0,4317	0,3226	0,2273
MVSA (orijinal)	0,3032	0,2223	0,2135
MVSA (GAP uygulanmış)	0,3226	0,2123	0,2181
SISAL (orijinal)	0,3103	0,2053	0,2161
SISAL (GAP uygulanmış)	0,3333	0,2122	0,2118

Şekil 6.7'de 6 son üye için referans spektraya FCLS uygulanması ile eldilen bolluk oran tahminleri elde edilmiştir. Burada saf beyaz yüzde yüz içeriği ifade ederken, saf siyah yüzde sıfır içeriği ifade etmektedir. Bu oranlar diğer yöntem sonuçları için referans sonuçlar olarak değerlendirilmiştir.

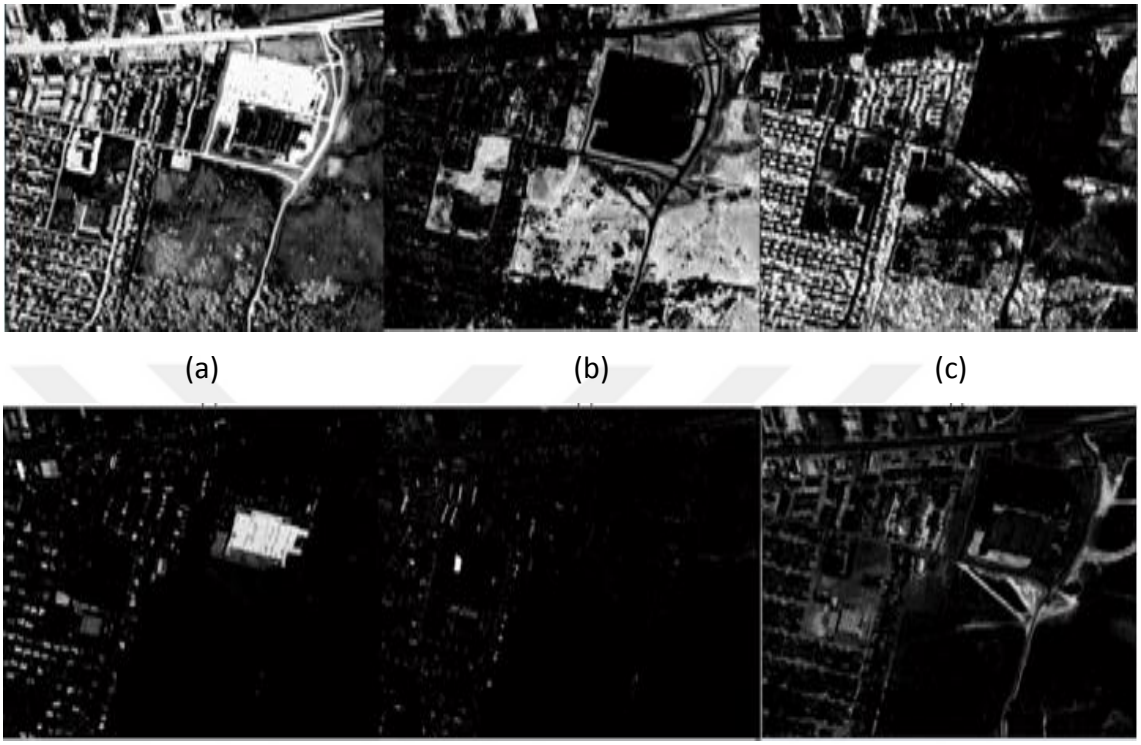

(a) (b) (c)

(c) (d) (e)

Şekil 6.7 Bolluk haritası tahmini (Referans spektra kullanılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Şekil 6.8'de 6 son üye için orijinal veri üzerinde yöntemler ile elde edilen en iyi SAM skoruna sahip imzalara FCLS uygulanması ile bulunan bolluk oranları gösterilmiştir.

(a) (b) (c)

(c) (d) (e)

Şekil 6.8 Bolluk haritası tahmini (Son üyeler algoritmalar vasıtasıyla orijinal veriden çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Şekil 6.9'da ise 6 son üye için GAP algoritması uygulanmış veri üzerinden yöntemler ile elde edilen en iyi son üye imzalarına FCLS uygulanması ile bulunan bolluk oranları gösterilmiştir.

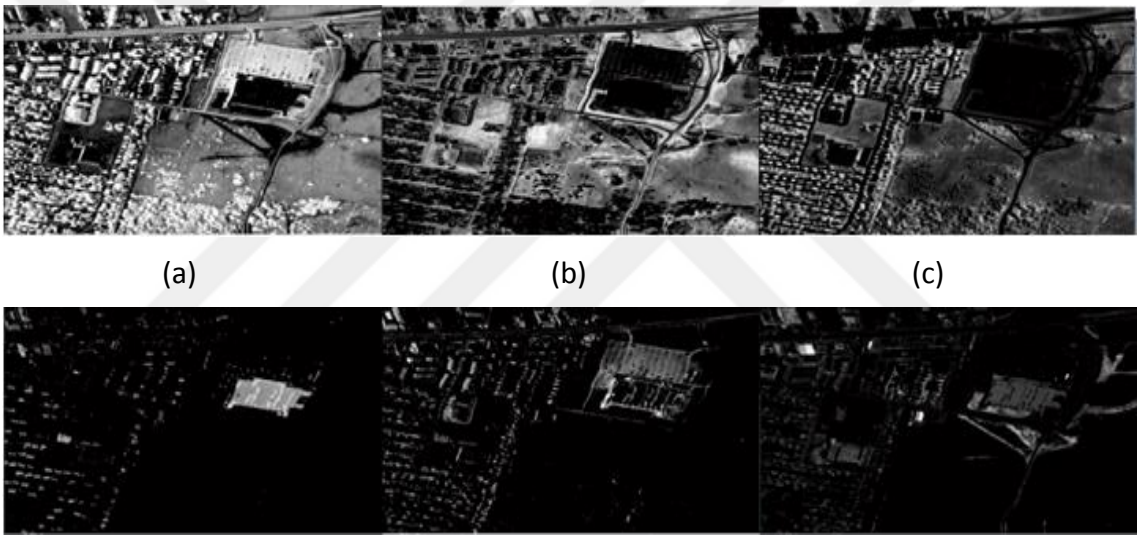

(a) (b) (c)

(c) (d) (e)

Şekil 6.9 Bolluk haritası tahmini (Son üyeler algoritmalar vasıtasıyla GAP uygulanmış veri üzerinden çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

6.4 Deneme Sonuçları (Çalışma 2)

Hiperspektral görüntülerin ayrıştırma problemlerinin çözümünde daha iyi sonuçlar elde edebilmek için uzamsal bilginin SPP yöntemiyle kullanılması ve gürültü giderici yöntemlerden SSTV yönteminin ön işleme adımı olarak uygulanması bu çalışmada önerilmiştir.

SPP yöntemi uygulanırken seçilen pencerenin sonuçlara etkisini görmek maksadıyla 3x3, 5x5, 7x7, 9x9 boyutlu 4 farklı pencere orijinal görüntüye uygulanmıştır. Orijinal

verideki 80. ve 110. bant görüntüsü Şekil 6.6'da verilmişti. Şekil 6.10'da ise kullanılan pencere boyutlarına göre elde edilmiş yeni veriler yine aynı bantlarda sergilenmiştir.

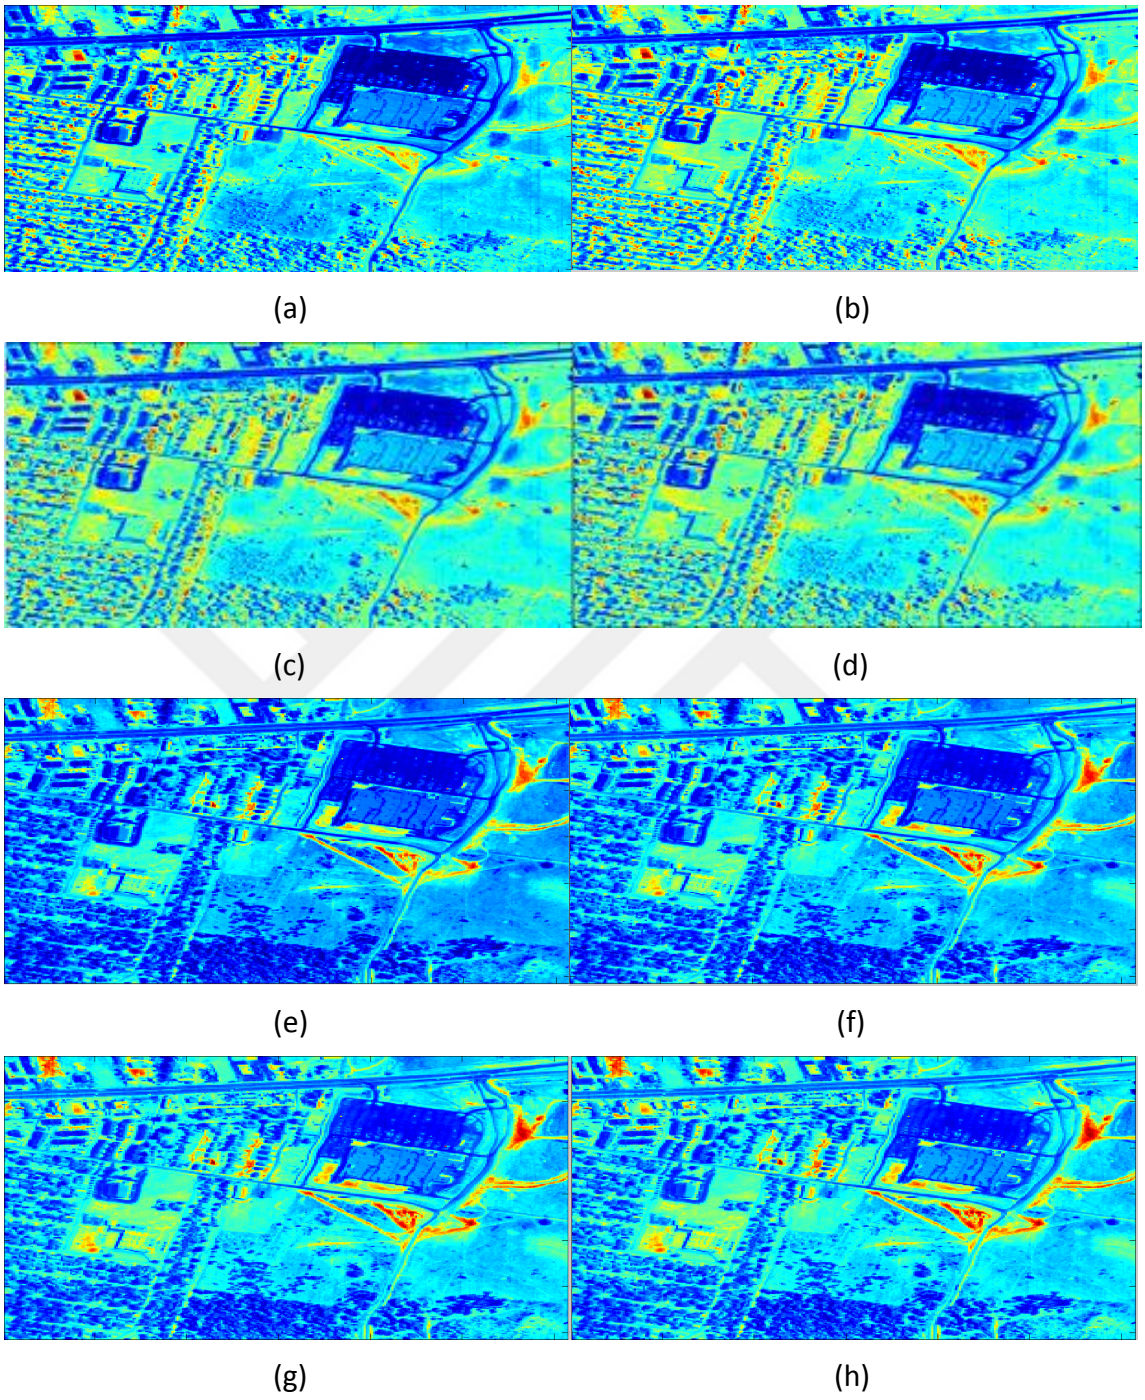

(a) (b)

(c) (d)

(e) (f)

(g) (h)

Şekil 6.10 Orijinal veriye SPP ile farklı pencereler uygulanarak elde edilmiş görüntüler (Bant 80-Bant 110) (a) 3x3 (b) 5x5 (c) 7x7 (d) 9x9 (e) 3x3 (f) 5x5 (g) 7x7 (h) 9x9

Görüntülerden de fark edileceği üzere pencere boyutu arttıkça daha geniş bir alanda, komşuluklardaki piksellerin spektral içerikleri önem kazanmaktadır. Homojen bir spektral alan içerisindeki piksellerin içeriği az değişkenlik gösterirken, benzer spektral

içeriğe sahip olmayan alanlardaki içerikler daha fazla değişikliğe uğramıştır. SPP uygulaması uzamsal içeriğin kullanılması için ön işleme adımı olarak uygulanmıştır. Sonrasında ise yalnızca spektral bilgiyi kullanan geometrik tabanlı ayrıştırma algoritmaları uygulanmış, elde edilen SAM sonuçları Çizelge 6.5'de gösterilmiştir.

Çizelge 6.5 SPP uygulandıktan sonra SAM skorları

YÖNTEM (pencere boyutu)	SON ÜYE						
	Asfalt Yol	Çimen	Ağaç	Çatı	Metal	Beton	Ort.
SPP-NFİNDER (3*3)	0,4421	0,6228	0,0617	0,1247	0,192	0,1905	0,2723
SPP-NFİNDER (5*5)	0,3912	0,5499	0,097	0,156	0,1904	0,0928	0,2462
SPP-NFİNDER (7*7)	0,3959	0,5513	0,0703	0,1649	0,1897	0,1533	0,2542
SPP-NFİNDER (9*9)	0,4251	0,5475	0,089	0,1684	0,1895	0,1513	0,2618
SPP-AVMAX (3*3)	0,4337	0,552	**0,0541**	0,1478	0,1948	0,1007	0,2472
SPP-AVMAX (5*5)	0,4039	0,5485	0,0762	**0,0628**	0,1884	0,1505	0,2384
SPP-AVMAX (7*7)	0,383	0,5838	0,0625	0,1168	0,2042	0,0937	0,2407
SPP-AVMAX (9*9)	0,4213	0,5919	0,0817	0,1149	0,1879	0,1116	0,2516
SPP-SVMAX (3*3)	0,3592	0,6226	**0,0541**	0,1114	0,1897	0,1007	0,2396
SPP-SVMAX (5*5)	0,3902	0,6058	0,0762	0,114	0,1884	0,0956	0,2450
SPP-SVMAX (7*7)	0,3948	0,4765	0,0853	0,1168	0,1879	**0,0769**	0,2230
SPP-SVMAX (9*9)	0,3861	0,473	0,0895	0,1149	0,1879	0,0814	0,2221
SPP-OSP (3*3)	0,2909	0,5743	0,0617	0,2756	**0,1781**	0,113	0,2489
SPP-OSP (5*5)	0,2807	0,5499	0,097	0,2838	0,181	0,1077	0,2500
SPP-OSP (7*7)	**0,2699**	0,5462	0,0885	0,2896	0,2306	0,0912	0,2527
SPP-OSP (9*9)	0,4056	0,4739	0,0925	0,2934	0,2294	0,0928	0,2646
SPP-VCA (3*3)	0,3825	0,3275	0,1063	0,0881	0,2263	0,2361	0,2278
SPP-VCA (5*5)	0,3902	**0,187**	0,0932	0,0817	0,3651	0,1757	0,2155
SPP-VCA (7*7)	0,3948	0,2301	0,091	0,0839	0,2568	0,1842	**0,2068**
SPP-VCA (9*9)	0,3923	0,4119	0,0933	0,2158	0,2036	0,1577	0,2458

Elde edilen sonuçlar, orijinal veriye geometrik tabanlı algoritmalar ve GAP algoritmasının uygulanması ile bulunan Çizelge 6.3'teki sonuçlarla kıyaslandığında daha iyi oldukları görülür. Aradaki tek fark ön işleme adımı olarak SPP yönteminin son üye çıkarımı safhasının öncesinde uygulanmış olmasıdır. En iyi sonuç SPP-VCA'da 7x7 pencere uygulandığında alınmıştır. Bu yöntem ile elde edilen tahmini imza ve gerçek imza kıyaslaması Şekil 6.11'de görselleştirilmiştir.

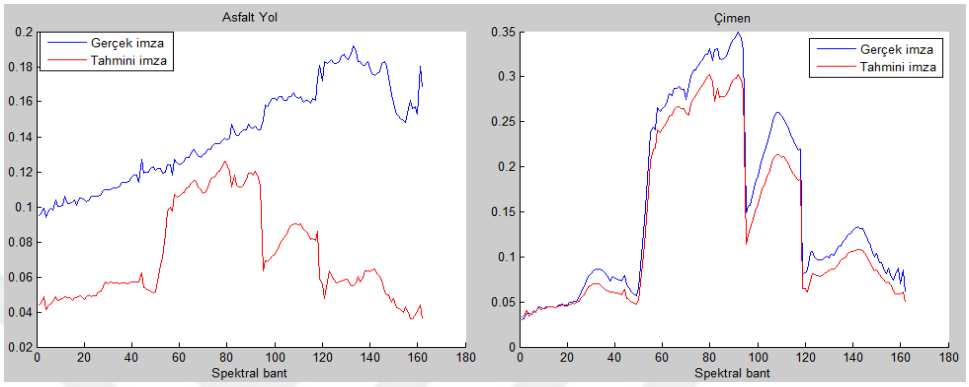

(a)

(b)

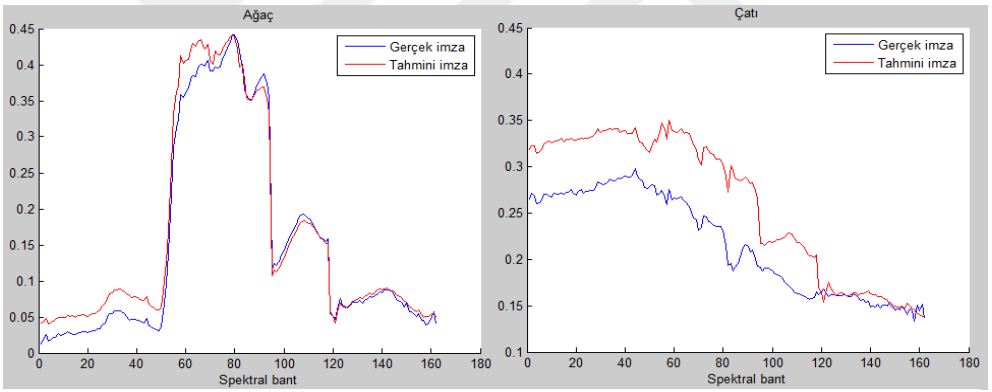

(c)

(d)

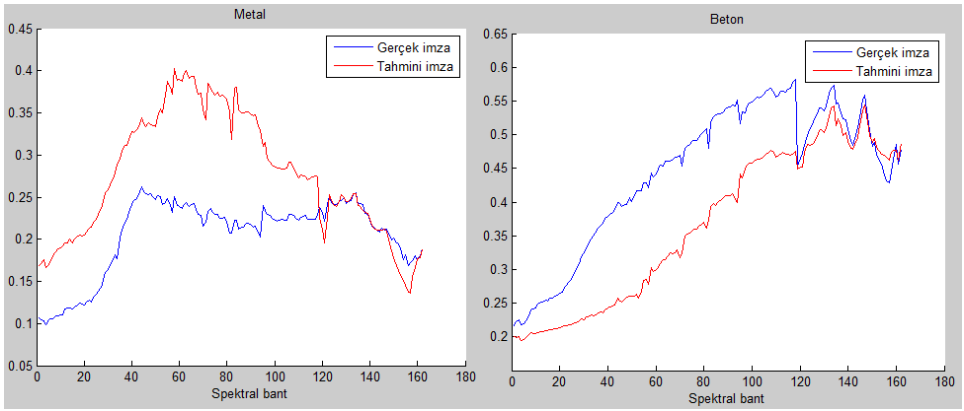

(e)

(f)

Şekil 6.11 SPP-VCA yöntemi ile 7x7'lik pencerede çıkarılan son üyeler (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Spektral imzalar incelendiğinde asfalt yolun tahmini imzasının gerçek imzasına benzemediği görülmektedir. Diğer tahminler ise gerçeğe yakın sonuçlar üretmiştir. Bu yöntem ile elde edilen imzalara FCLS yöntemi uygulanmış, elde edilen bolluk oranları Şekil 6.12'de, RMSE sonuçları ise Çizelge 6.6'da verilmiştir.

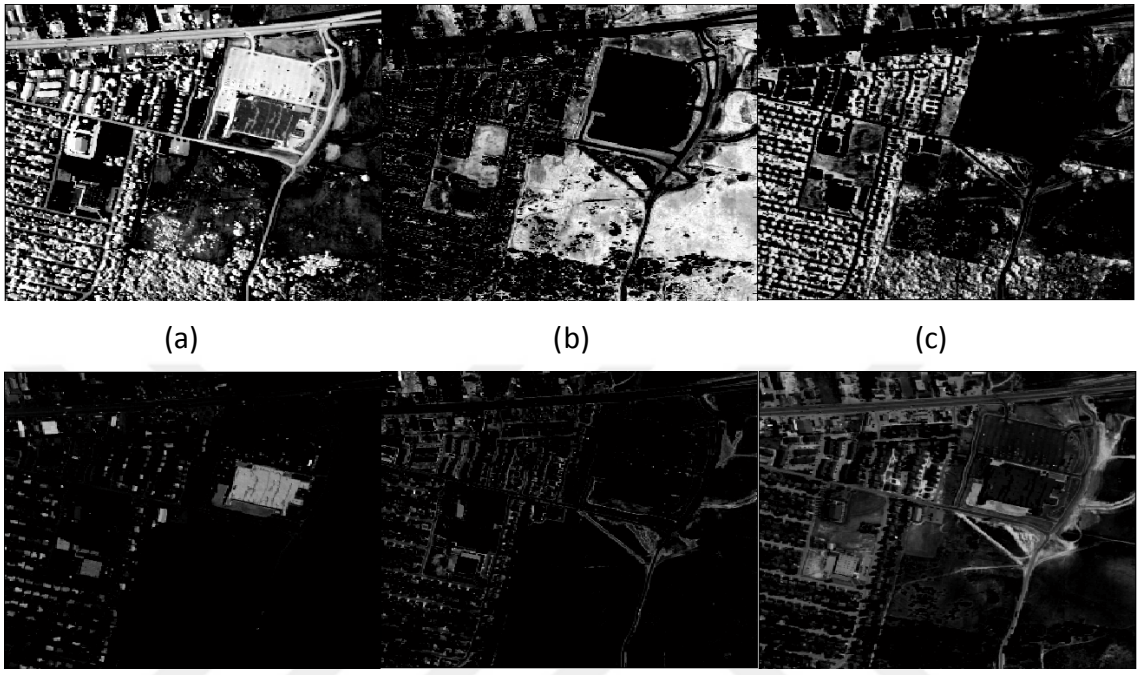

(a) (b) (c)

(c) (d) (e)

Şekil 6.12 Bolluk haritası tahmini (Son üyeler SPP-VCA (7x7 pencere) uygulamasıyla çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Çizelge 6.6 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (1)

YÖNTEM (pencere boyutu)	**SON ÜYE**						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
SPP-VCA (7*7)	0,244	0,211	0,1642	0,1131	0,1064	0,1104	0,1585

Bu adımların da öncesinde gürültü gideriminin de sonuçları iyileştireceği ön görülmektedir. Özellikle orijinal veri incelenirken birçok bandın çizgi gürültüsü ihtiva ettiği görülmüştür.

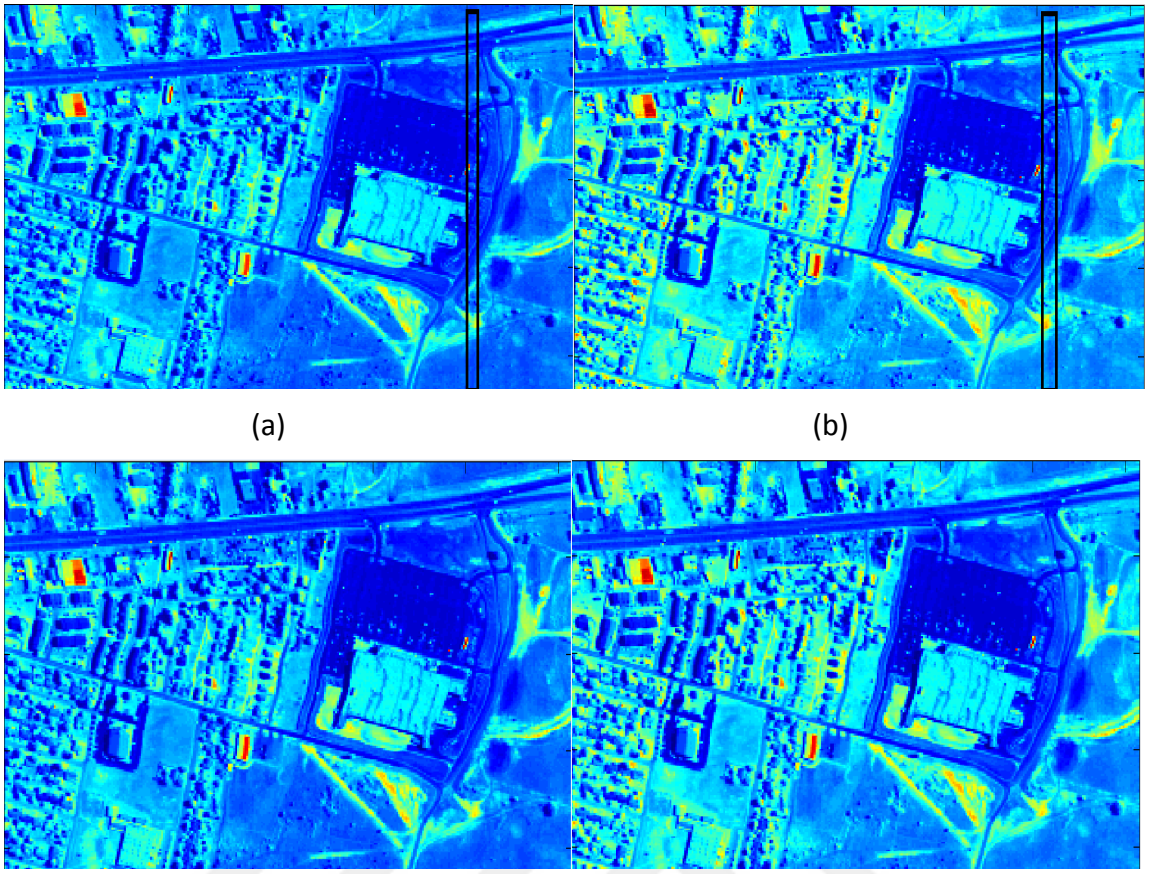

(a) (b)

(c) (d)

Şekil 6.13 Gürültü içeren bantlar (a) 54. bant (b) 55. bant (c) SSTV uygulanmış 54.bant (d) SSTV uygulanmış 55.bant

Gürültü giderimi için SSTV algoritması uygulanmıştır. Bu sayede görüntü içerisindeki dürtü, Gauss ve ayrık gürültülerin de giderilmesi hedeflenmiştir. 54 ve 55. bant görüntüsünde mevcut çizgi gürültüsü ve gürültüsü giderilmiş bantlar Şekil 6.13'de örnek olarak gösterilmiştir. Çizgi gürültüsü siyah dikdörtgen içerisinde gösterilmiştir. Görüntü içerisindeki bantlar ayrı ayrı incelendiğinde birçok bandın bu gürültüye sahip olduğu görülmüştür. SSTV algoritması uygulanırken parametreler ampirik olarak seçilmiştir. $(\lambda, \mu_1, \mu_2, \max iter) = (0.1, 0.2, 0.2, 40)$. Daha sonra bu veri değişik pencerelerde SPP ile uzamsal ön işleme tabi tutulmuş, son olarak son üye çıkarımı için geometrik tabanlı ayrıştırma algoritmaları uygulanmıştır. Bu şekilde elde edilen SAM skorları Çizelge 6.7'de gösterilmiştir.

Çizelge 6.7 SAM skorları (1)

YÖNTEM	SON ÜYE						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
SSTV-SPP-NFİNDER (3*3)	0,1944	0,2243	0,1035	0,1197	0,2906	0,0626	0,1659
SSTV-SPP-NFİNDER (5*5)	0,1262	0,2222	0,0957	0,1222	0,2702	0,0861	0,1538
SSTV-SPP-NFİNDER (7*7)	0,401	0,5542	0,069	0,164	0,1888	0,1484	0,2542
SSTV-SPP-NFİNDER (9*9)	0,1339	0,2041	0,1008	0,1244	0,2628	0,0902	0,1527
SSTV-SPP-AVMAX (3*3)	0,1869	0,2223	0,0567	0,1079	0,4084	0,1886	0,1951
SSTV-SPP-AVMAX (5*5)	0,1888	0,5028	0,0853	0,1531	0,3222	0,1005	0,2254
SSTV-SPP-AVMAX (7*7)	0,251	0,584	0,096	0,1151	0,2065	**0,0575**	0,2183
SSTV-SPP-AVMAX (9*9)	0,2007	0,2255	0,0989	0,1141	0,3431	0,1438	0,1877
SSTV-SPP-SVMAX (3*3)	**0,1164**	0,6262	0,0567	0,1079	0,1916	0,1057	0,2008
SSTV-SPP-SVMAX (5*5)	0,1286	0,6066	0,0853	0,1116	0,1903	0,1005	0,2038
SSTV-SPP-SVMAX (7*7)	0,3975	0,2012	0,096	0,1151	0,1525	0,0985	0,1768
SSTV-SPP-SVMAX (9*9)	0,3952	0,2016	0,1085	0,1141	0,1574	0,0971	0,179
SSTV-SPP-OSP (3*3)	0,2941	0,4897	0,0625	0,157	0,1967	0,0855	0,2143
SSTV-SPP-OSP (5*5)	0,2819	0,4784	0,0957	0,1229	0,194	0,0867	0,2099
SSTV-SPP-OSP (7*7)	0,2708	0,4732	0,1046	0,1259	0,287	0,1611	0,2371
SSTV-SPP-OSP (9*9)	0,2664	0,4695	0,1085	0,1244	0,1926	0,0902	0,2086
SSTV-SPP-VCA (3*3)	0,1238	0,3628	0,0757	0,0898	0,2347	0,1521	0,1732
SSTV-SPP-VCA (5*5)	0,2559	0,2431	**0,056**	**0,0819**	**0,1262**	0,17	**0,1555**
SSTV-SPP-VCA (7*7)	0,3539	0,2012	0,0693	0,084	0,2206	0,14	0,1782
SSTV-SPP-VCA (9*9)	0,2796	**0,1627**	0,0818	0,1565	0,2321	0,1549	0,1779

Elde edilen SAM skorları incelenerek bir önceki çalışmada Çizelge 6.3'te bulunan sonuçlarla kıyaslandığında gürültü giderim işleminin son üye çıkarımı safhasında daha başarılı sonuçlar elde edilmesine faydasının olduğu görülür. En iyi sonuç SSTV-SPP-VCA'da 5x5 pencere uygulandığında alınmıştır. Bu yöntem ile elde edilen tahmini imza ve gerçek imza kıyaslaması Şekil 6.14'de görselleştirilmiştir. Bu yöntem ile elde edilen imzalara FCLS yöntemi uygulanmış, elde edilen bolluk oranları Şekil 6.15'de, rmse sonuçları ise Çizelge 6.8'de verilmiştir.

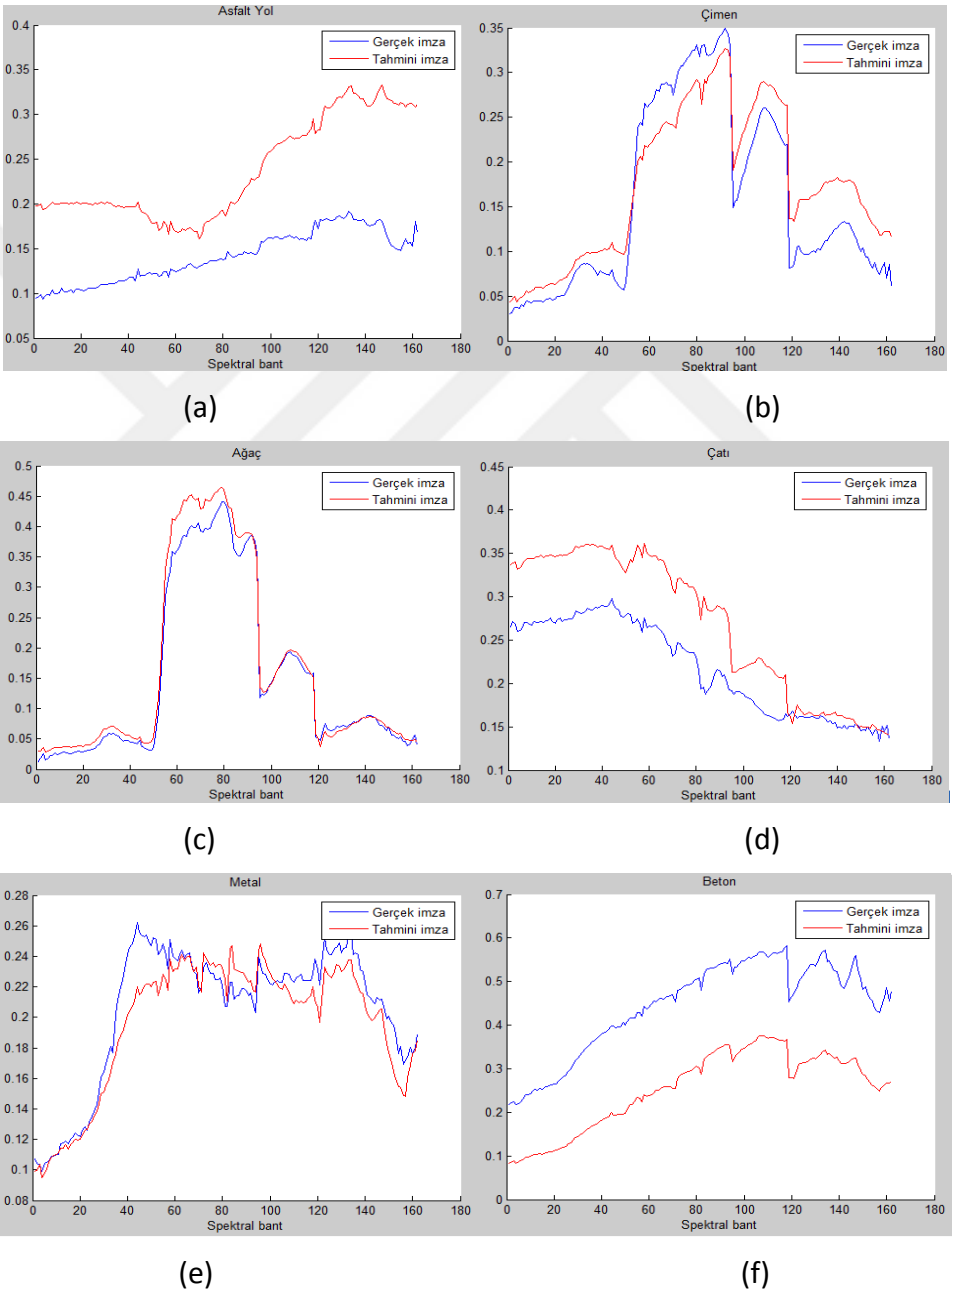

Şekil 6.14 SSTV-SPP-VCA yöntemi ile 5x5'lik pencerede çıkarılan son üyeler (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

(a) (b) (c)

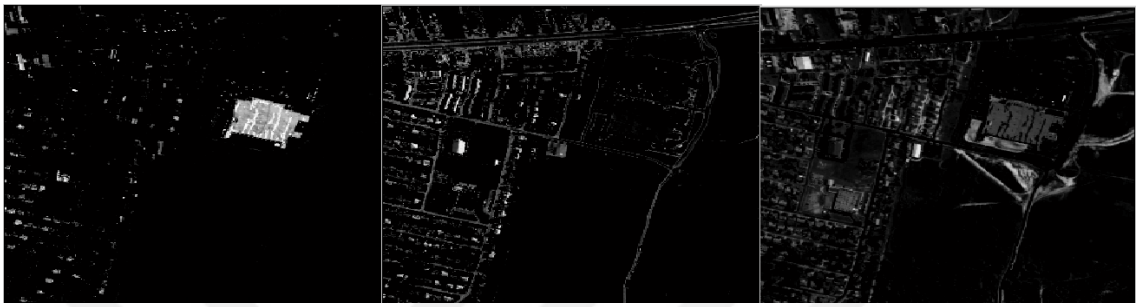

(c) (d) (e)

Şekil 6.15 Bolluk haritası tahmini (Son üyeler SSTV-SPP-VCA (5x5 pencere) uygulamasıyla çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Çizelge 6.8 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (2)

YÖNTEM (pencere boyutu)	SON ÜYE						
	Asfalt Yol	Çimen	Ağaç	Çatı	Metal	Beton	Ort.
SSTV-SPP-VCA (5*5)	0,243	0,1961	0,1559	0,104	0,0886	0,1139	0,1503

6.5 Deneme Sonuçları (Çalışma 3)

Hiperspektral görüntülerin ayrıştırma problemlerinin çözümünde daha iyi sonuçlar elde edebilmek için hem uzamsal hem de spektral bilginin RBSPP yöntemiyle kullanılması ve gürültü giderici yöntemlerden SSTV yönteminin ön işleme adımı olarak uygulanması bu çalışmada önerilmiştir.

RBSPP yöntemi öncelikle hiperspektral veri üzerinde eğiticisiz bir kümeleme işlemi yapmaktadır. Kümeleme işlemi için bu çalışmada ISODATA algoritması kullanılmıştır. Algoritma çalışırken minimum ve maksimum küme sayısını talep etmekte ve bu iki sayı arasında olacak şekilde kümeleri belirlemektedir. Bu çalışmada minimum küme sayısı olarak son üye sayısı yani 6, maksimum küme sayısı olarak ise bunun iki katı olacak şekilde 12 rakamı belirlenmiştir. Bu işlemden sonra elde edilen her bir kümenin

ortalama spektrumuna OSP yöntemi uygulanarak, tüm veri kullanılması yerine sadece kümeleri temsil eden verilerin kullanılması sağlanır. Kentsel HYDICE verisine ISODATA kümeleme işlemi uygulandığında oluşan 7 farklı küme Şekil 6.16'da gösterilmiştir. Bu görüntüde her bir renk farklı kümeyi göstermektedir.

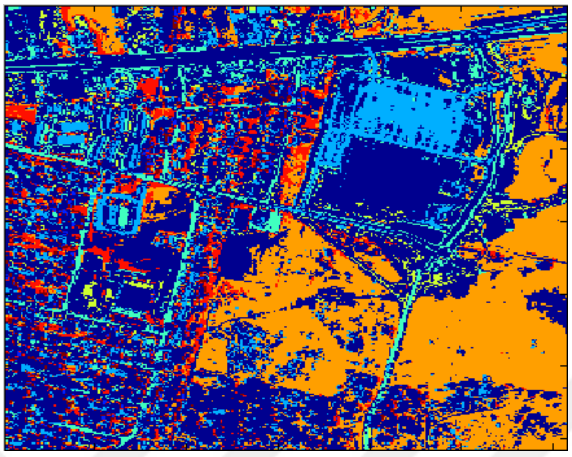

Şekil 6.16 ISODATA algoritması uygulanması ile oluşan 7 küme

Sonrasında ise RBSPP yöntemi ile dikgen izdüşümler yönteminin kullanılması suretiyle işlem yapılacak bölgeler belirlenmiştir. Bu bölgeler Şekil 6.17'de gösterilmiştir. Bu yöntem ile işlem yapılacak piksel vektör sayısı 94249'dan 12795'e indirilmiştir. Bu işlem de yapıldıktan sonra son üye çıkarımı safhasında geometrik tabanlı algoritmalar için tüm veri yerine sadece seçilen piksel vektörleri kullanılacaktır. Seçilen piksel vektörlerine geometrik tabanlı algoritmların uygulanması ile elde edilen SAM skorları Çizelge 6.9'da sergilenmiştir.

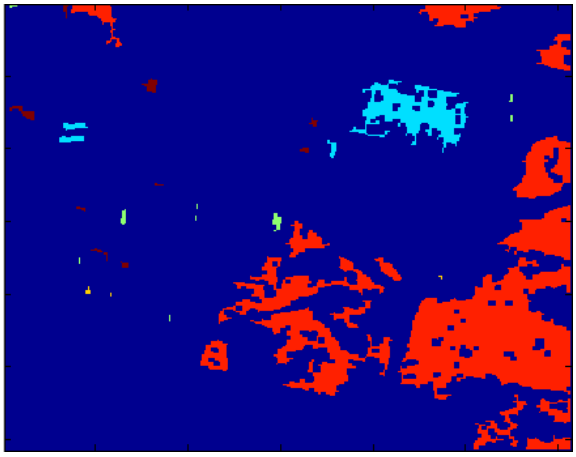

Şekil 6.17 RBSPP yöntemiyle seçilen kümelerdeki piksel vektörlerinin mevkileri

Çizelge 6.9 SAM skorları (2)

METHOD	SON ÜYE						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
RBSPP-NFİNDER	0,1092	0,1024	0,0687	0,6312	**0,0188**	0,0645	0,1658
RBSPP-VCA	0,1073	0,1253	0,0757	0,622	0,1333	0,1012	0,1941
RBSPP-OSP	**0,0649**	0,0957	0,0735	**0,5083**	0,0236	**0,0559**	**0,137**
RBSPP-AXMAX	0,1144	0,1036	**0,0607**	0,6349	0,0591	0,0683	0,1735
RBSPP-SVMAX	0,0797	**0,0943**	**0,0607**	0,5903	0,0591	0,0593	0,1572

Elde edilen sonuçlar incelenerek Çizelge 6.5'deki skorlarla kıyaslandığında, geometrik tabanlı algoritmaların hepsinin daha iyi neticeler verdiği görülmektedir. Bu görece iyi sonuçlar RBSPP'nin SPP yöntemine göre üstünlüğünden kaynaklanmaktadır. Bunun da temel nedeni RBSPP'nin ön işleme adımı olarak kullanılması esnasında uzamsal ve spektral içerik bilgilerinin ikisinin de kullanmasıdır. En iyi sonuçların elde edildiği RBSPP-OSP yönteminin bulduğu imzalar ile gerçek imzalar Şekil 6.18'de görselleştirilmiştir.

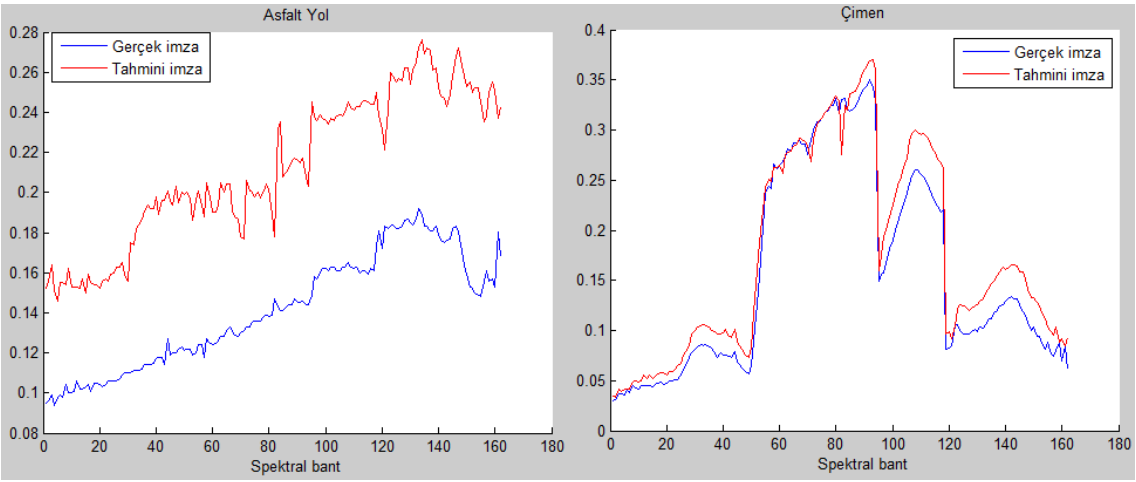

(a) (b)

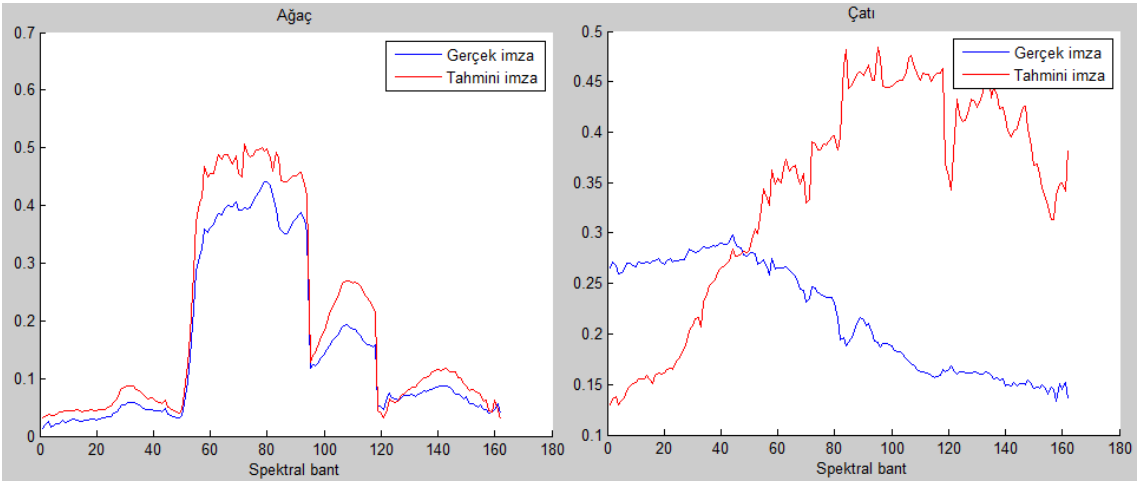

(c) (d)

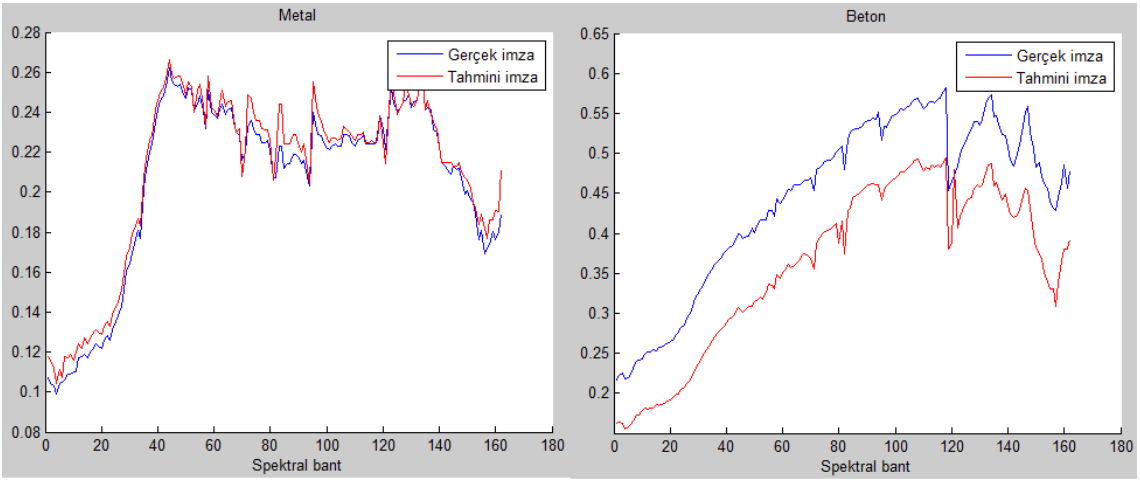

(e) (f)

Şekil 6.18 RBSPP-OSP yöntemi ile çıkarılan son üyeler (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Spektral imzalar incelendiğinde çatı son üyesinin tahmini imzasının gerçek imzasına benzemediği görülmektedir. Diğer tahminler ise gerçeğe yakın sonuçlar üretmiştir. Bunun nedeni ise RBSPP yöntemi ile seçilen kümelere ait piksel vektörlerinin arasında çatıya dair temsilcilerin bulunmamasıdır. Bu yöntem ile elde edilen imzalara FCLS methodu uygulanmış, elde edilen bolluk oranları Şekil 6.19'da, RMSE sonuçları ise Çizelge 6.10'da verilmiştir.

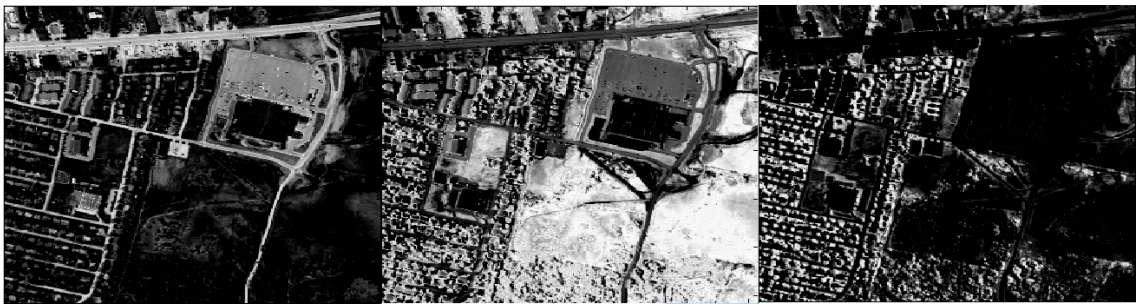

(a) (b) (c)

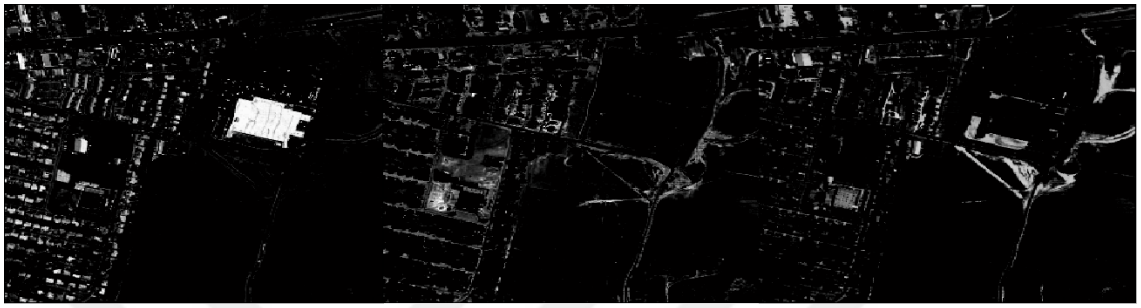

(c) (d) (e)

Şekil 6.19 Bolluk haritası tahmini (Son üyeler RBSPP-OSP uygulamasıyla çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Çizelge 6.10 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (3)

METHOD (pencere boyutu)	**SON ÜYE**						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
RBSPP-OSP	0,2698	0,3603	0,1804	0,201	0,1858	0,1172	0,2191

Çalışmanın devamında ise sonuçları iyileştirmek için, gürültü giderimi maksadıyla ön işleme adımı olarak SSTV uygulanmıştır. Bu işlem sonrasında uygulanan ISODATA algoritması ile elde edilen kümeleme haritası Şekil 6.20'de gösterilmiştir.

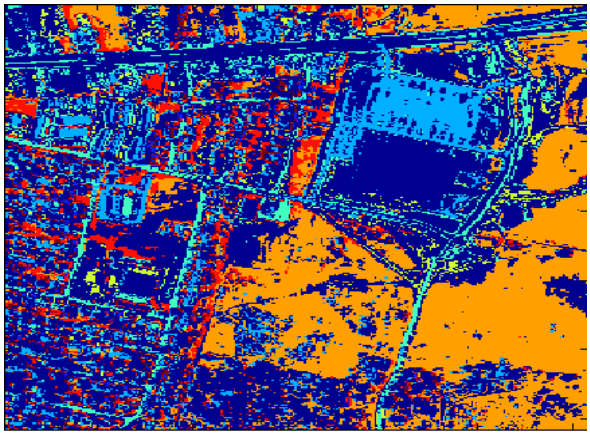

Şekil 6.20 Gürültü giderimi sonrası ISODATA algoritması uygulanması ile oluşan 7 küme

Temsilci bölgelerin seçimi için uygulanan RBSPP yönteminin sonucunda bulunan piksel vektör mevkileri Şekil 6.21'de gösterilmiştir. Burada seçilen piksel vektör sayısı 12849 olarak bulunmuştur.

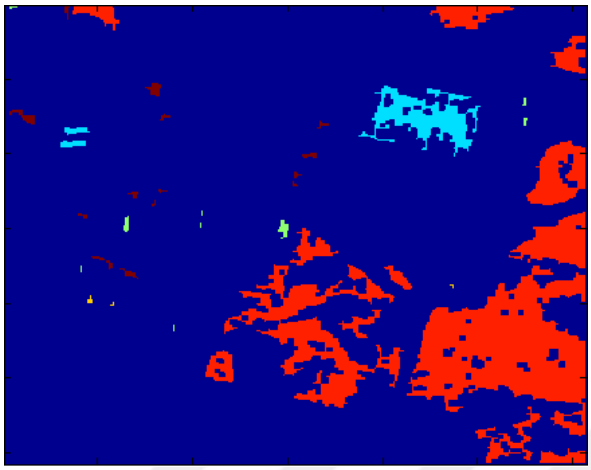

Şekil 6.21 Gürültü giderimi sonrası RBSPP yöntemiyle seçilen kümelerdeki piksel vektörlerinin mevkileri

Seçilen piksel vektörlerine geometrik tabanlı algoritmların uygulanması ile elde edilen SAM skorları Çizelge 6.11'da sergilenmiştir.

Çizelge 6.11 SAM skorları (3)

METHOD	SON ÜYE						
	Asfalt Yol	Çimen	Ağaç	Çatı	Metal	Beton	Ort.
SSTV-RBSPP-NFİNDER	0,1085	0,0798	0,0726	0,66	0,0298	0,066	0,1695
SSTV-RBSPP-VCA	0,0955	0,1283	0,0686	0,6017	0,0743	0,1391	0,1846
SSTV-RBSPP-OSP	**0,0665**	**0,0573**	0,0746	0,5078	**0,0143**	**0,0519**	**0,1287**
SSTV-RBSPP-AXMAX	0,1	0,0825	**0,0599**	0,6123	0,0582	0,068	0,1635
SSTV-RBSPP-SVMAX	0,0786	0,0968	**0,0599**	**0,5007**	0,0537	0,0576	0,1412

Spektral imzalar incelendiğinde çatı son üyesinin tahmini imzasının gerçek imzasına benzemediği görülmektedir. Diğer tahminler ise gerçeğe yakın sonuçlar üretmiştir. Çizelge 6.9'la kıyaslandığında ise NFINDR haricinde diğer algoritmalarda daha iyi

neticeler alınmıştır. Bunun nedeni ise ön işleme adımı olarak gürültü giderimi maksadıyla SSTV algoritmasının uygulanmış olmasıdır. En iyi SAM skorunun alındığı SSTV-RBSPP-OSP yönteminin bulduğu son üyeler Şekil 6.22'de görselleştirilmiştir.

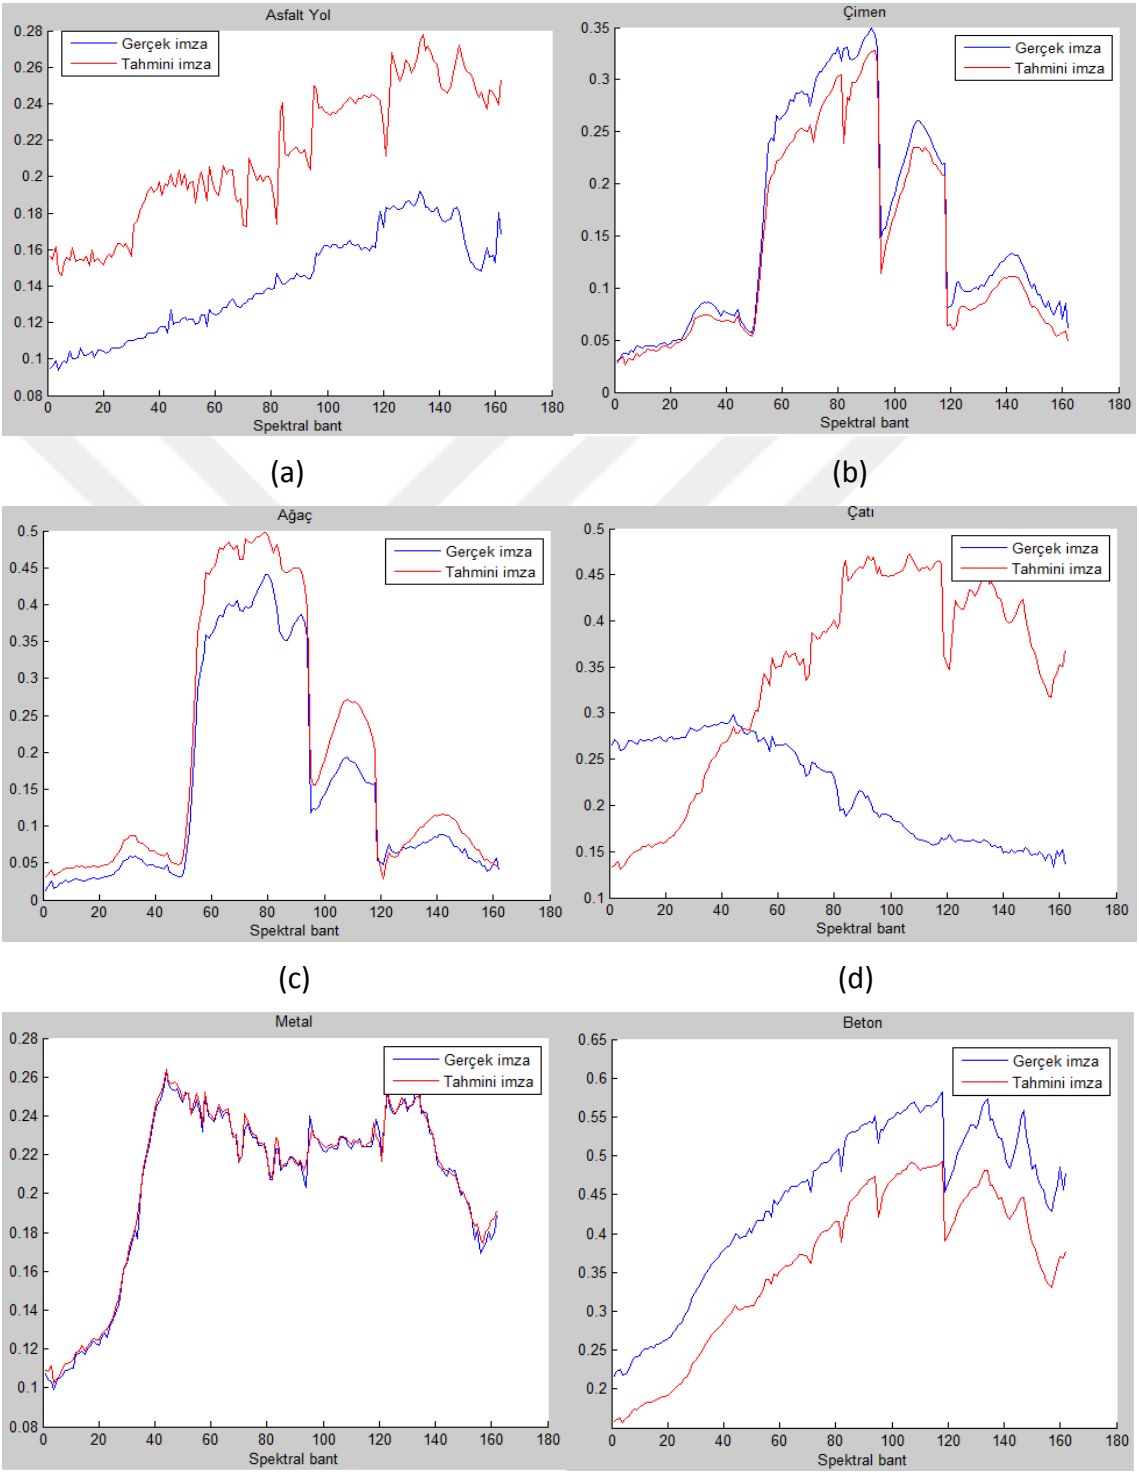

Şekil 6.22 SSTV-RBSPP-OSP yöntemi ile çıkarılan son üyeler (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Bu yöntem ile elde edilen imzalara FCLS methodu uygulanmış, elde edilen bolluk oranları Şekil 6.23'de, rmse sonuçları ise Çizelge 6.12'de verilmiştir.

(a) (b) (c)

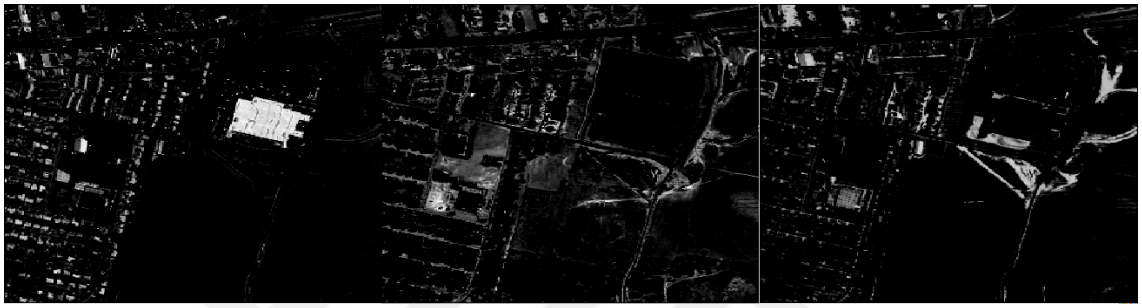

(c) (d) (e)

Şekil 6.23 Bolluk haritası tahmini (Son üyeler SSTV-RBSPP-OSP uygulamasıyla çıkarılmıştır.) (a) asfalt yol (b) çimen (c) ağaç (d) çatı (e) metal (f) beton

Çizelge 6.12 Bolluk oran tahminlerinin gerçek oranlarla arasındaki rmse skorları (4)

METHOD (pencere boyutu)	**SON ÜYE**						
	Asfalt Yol	**Çimen**	**Ağaç**	**Çatı**	**Metal**	**Beton**	**Ort.**
SSTV-RBSPP-OSP	0,3093	0,4381	0,2144	0,2153	0,1623	0,1184	0,2429

BÖLÜM 7

SONUÇ VE ÖNERİLER

Bu çalışmada hiperspektral görüntülerde ayrıştırma probleminin çözümü için, ön işleme adımlarının ve geometrik tabanlı son üye çıkarım algoritmalarının birlikte kullanılması önerilmiştir. Ön işleme adımları olarak hiperspektral görüntülerde gürültü gideriminin ve uzamsal bilginin kullanılmasının ayrıştırma problemlerine olan etkisi incelenmiştir.

Kentsel HYDICE verisi üzerinde dürtü gürültüsünün giderimi için uzamsal-spektral korelasyondan yararlanan GAP algoritması kullanılmıştır. Gürültüsü giderilmiş veri üzerine geometrik tabanlı son üye çıkarım algoritmalarının uygulanması sonucu, görüntü içerisinde 4,5 ve 6 son üye bulunduğu varsayımına göre referans imzalara istinaden elde edilen SAM skorları iyileşme göstermiştir. Bu da spektral imzaların doğruya daha yakın olarak tahmin edildikleri anlamına gelmektedir. Dolayısıyla bu çalışma ile gürültü giderim işleminin hiperspektral ayrıştırma problemlerinin çözümüne etkisi irdelenmiştir.

Hiperspektral ayrıştırma problemlerinin çözümünde uzamsal bilginin kullanılmasının da faydalı olacağından yola çıkılarak ön işleme adımı kapsamında SPP ve RBSPP yöntemlerinden de yararlanılmıştır. Bu sayede saf piksel varsayımına dayanan tüm algoritmaların imza tahmininde, ön işleme adımı kullanılmadan elde edilen tahminlere göre daha başarılı olduğu tespit edilmiştir. Ancak imzalardaki iyileşmenin her zaman bolluk oranlarında da iyileşmeye neden olacağı anlamına gelmediği, bunun nedeninin

de bolluk oran tahminlerinin tüm son üyelerin doğruya yakın olarak tahmin edilmesine sıkıca bağlı olmasından kaynaklandığı görülmüştür.

Ön işleme adımları, Gauss gürültüsünün ve ayrık gürültünün giderilmesini hedefleyen SSTV algoritması ve uzamsal bilginin kullanılmasını hedefleyen SPP ve RBSPP yöntemleri ile birlikte iki safhadan oluşacak şekilde oluşturulduğunda ise son üye çıkarımı için kullanılan geometrik tabanlı algoritmalar en iyi imza tahminlerini sağlamıştır.

Çalışma neticesinde yukarıda bahsedilen sonuçlarla birlikte, bir takım konuların da ileriye dönük çalışmalarda kullanılmak üzere ortaya çıktığı değerlendirilmektedir.

Gelecek çalışmalarda diğer gürültü giderim yöntemlerinin de hiperspektral ayrıştırma problemlerinin çözümüne etkisinin incelenmesinin gerekli olduğu düşünülmektedir.

Bu tez çalışması kapsamında son üye çıkarımı safhasında yalnızca geometrik tabanlı ayrıştırma algoritmaları incelenmiştir. Son üye çıkarımı safhasında kullanılan diğer yöntem olan istatistiksel yöntemlerin kullanılması ve gürültü giderimi, uzamsal ön işleme adımlarının bu yöntemlere etkisi devam çalışması olarak gözükmektedir.

Son üye çıkarımında safhasında bazı yöntemler bir son üye imzasını bulamazken, diğer bir yöntem bu son üye için doğruya yakın bir tahmin verebilmektedir. Bu nedenle farklı yöntemlerin iyi son üye tahminlerinden yararlanabilmek için hibrit bir algoritma ihtiyacı bulunmaktadır.

KAYNAKLAR

[1] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M.Parente, Q. Du, P. Gader ve J. Chanussot, (2012). “Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches”, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 5(2): 354-379.

[2] N. Keshava ve J. F. Mustard, (2002). "Spectral unmixing", IEEE Signal Processing Magazine, 19(1): 44-57.

[3] N. Keshava, J. Kerekes, D. Manolakis ve G. Shaw, (2000). "An algorithm taxonomy for hyperspectral unmixing", Algorithms for Multispectral, Hyperspectral and Ultraspectral Imagery, 6(4049): 42-63.

[4] Green, A. G., Berman, M., Switzer, P. ve Craig, M.D., (1988). "A transformation for ordering multispectral data in terms of image quality with implications for noise removal", IEEE Trans. Geosci. Remote Sens., 26(1): 65-74.

[5] J. B. Lee, S. Woodyatt ve M. Berman, (1990). "Enhancement of high spectral resolution remote-sensing data by noise-adjusted principal components transform", IEEE Trans. Geosci. Remote Sens., 28(3): 295-304.

[6] J. W. Boardman, (1994). "Geometric mixture analysis of imaging spectrometery data", Proc. Int. Geoscience and Remote Sensing Symp., (4): 2369-2371.

[7] M. E. Winter, (1999). "N-finder: An algorithm for fast autonomous spectral endmember determination in hyperspectral data", Proc. Image Spectrom., V(3753): 266-277.

[8] R. A. Neville, K. Staenz, T. Szeredi, J. Lefebvre, ve P. Hauff, (1999). "Automatic endmember extraction from hyperspectral data for mineral exploration", n Proc. 4th Int. Airborne Remote Sens. Conf. and Exhib./21st Can. Symp. Remote Sens., (21): 21-24.

[9] J. M. P. Nascimento ve J. M. Dias, (2005). "Vertex component analysis: A fast algorithm to unmix hyperspectral data", IEEE Trans. Geosci. Remote Sens., 43(4): 898-910.

[10] C.-I. Chang, C.-C. Wu, W. Liu, ve Y.-C. Ouyang, (2006). "A new growing method for simplex-based endmember extraction algorithm", IEEE Transactions on Geoscience and Remote Sensing, 44(10): 2804-2819.

[11] T. H. Chan, W. K. Ma, A. Ambikapathi ve C. Y. Chi, (2011). "A simplex volume maximization framework for hyperspectral endmember extraction", IEEE Transactions on Geoscience and Remote Sensing, 49: 4177-4193.

[12] J. Li ve J. Bioucas-Dias, (2008). "Minimum volumesimplex analysis: a fast algorithm to unmix hyperspectral data", IEEE International Geoscience and Remote Sensing, 3: 250-253.

[13] J. Bioucas-Dias, (2009). "A variable splitting augmented lagrangian approach to linear spectral unmixing", IEEE GRSS Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 9: 1-5.

[14] R. Green, M. Eastwood, C. Sarture, T. Chrien, M. Aronsson, B. Chippendale J. Faust, B. Pavri, C. Chovit ve M. Solis, 1998. ", Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS)", Remote Sensing of Environment,65(3): 227-248.

[15] Elektromanyetik Spektrum, http://pages.csam.montclair.edu/~chopping/rs/-hyperspectralRobila.ppt, 2 Kasım 2016.

[16] Dalla Mura, M., An Overview on Hyperspectral Unmixing, http://www-ljk.imag.fr/membres/Faouzi.Triki/projetPbsInverses/Pre/DallaMura_unmixing.pdf, 13 Ekim 2016.

[17] B. Hapke, (1981). " Bidirection reflectance spectroscopy. I. theory ", J. Geophys. Res., 86: 3039-3054.

[18] R. N. Clark ve T. L. Roush, (1984). "Reflectance spectroscopy: Quantitative analysis techniques for remote sensing applications", J. Geophys. Res., 89(7): 6329-6340.

[19] A. Plaza, G. Martin, J. Plaza, M. Zortea ve S. SanchezJames, (2011). "Recent developments in spectral unmixing and endmember extraction", Optical Remote Sensing, 12: 235-267.

[20] A. Plaza, P. Martinez, R. Perez ve J. Plaza, (2004). "A quantitative and comparative analysis of endmember extraction algorithms from hyperspectral data", IEEE Transactions on Geoscience and Remote Sensing, 42(3): 650-663.

[21] G. Shaw ve H. Burke, (2003). " Spectral imaging for remote sensing", Lincoln Lab. J., 14(1): 3-28.

[22] J. C. Harsanyi ve C. -I. Chang, (1994). " Hyperspectral Image Classification and Dimensionality Reduction: An Orthogonal Subspace Projection Approach", IEEE Transactions on Geoscience and Remote Sensing, 32(4): 779-785.

[23] A. Plaza ve C. -I. Chang, (2005). "An improved n-findr algorithm in implementation," Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XI, 5806: 298-306.

[24] M. M. Oskouei ve R. Poormirzaee, (2009). "Estimation of virtual dimensionality of hyperspectral data by principle component analysis and higher order statistical method", Proceedings of the 5th WSEAS International Conference on Remote Sensing, 67-71.

[25] J. Harsanyi, W. Farrand, and C.-I Chang, (1993). " Determining the number and identity of spectral endmembers: An integrated approach using Neyman-Pearson eigenthresholding and iterative constrained RMS error minimization", Proc. Thematic Conf. Geologic Remote Sens., 1: 1-10.

[26] Hernández, G., M., (2013). Design and implementation of new methods for spatial preprocessing prior to spectral unmixing of remotely sensed hyperspectral data, Doktora Tezi, University of Extremadura, İspanya.

[27] M. Zortea, A. Plaza, (2009). "Spatial pre-processing for endmember extraction", IEEE Transactions on Geoscience and Remote Sensing, 47: 2679-2693.

[28] G. Martin ve A. Plaza, (2010). "Spatial preprocessing for endmember extraction using unsupervised clustering and orthogonal subspace projection concepts", Geoscience and Remote Sensing Symposium (IGARSS), 959-962.

[29] G. Martin ve A. Plaza, (2011). "Region-Based Spatial Preprocessing for Endmember Extraction and Spectral Unmixing" IEEE Geoscience and Remote Sensing Letters, 8(4): 745-749.

[30] J. A. Richards and X. Jia, (2006). Remote Sensing Digital Image Analysis: An Introduction, Springer, New York.

[31] G. Ball ve D. Hall, (1965). "ISODATA, a novel method of data analysis and classification", Tech. rept., Stanford Research Institute, 1-61.

[32] Q. Yuan, L. Zhang, ve H. Shen, (2012). "Hyperspectral Image Denoising Employing a Spectral-Spatial Adaptive Total Variation Model", IEEE Transactions on Geoscience and Remote Sensing, 50(10): 3660-3677.

[33] Q. Yuan, L. Zhang, ve H. Shen, (2014). " Hyperspectral Image Denoising With a Spatial-Spectral View Fusion Strategy", IEEE Transactions on Geoscience and Remote Sensing, 52(5): 2314-2325.

[34] H. Zhang, W. He, L. Zhang, H. Shen, ve Q. Yuan (2014). " Hyperspectral Image Restoration Using Low-Rank Matrix Recovery", IEEE Transactions on Geoscience and Remote Sensing, 52(8): 4729-4743.

[35] L. I. Rudin, S. Osher, ve E. Fatemi, (1992). " Nonlinear Total Variation Based Noise Removal Algorithms", Phys. D Nonlinear Phenom. 60(1): 259-268.

[36] H. K. Aggarwal ve A. Majumdar, (2015). "Exploiting spatio-spectral correlation for impulse denoising in hyperspectral images", SPIE Journal of Electronic Imaging, 24(1): 013-017.

[37] M. A. Saunders, (1995). " Solution of Sparse Rectangular Systems Using LSQR and CRAIG", BIT Numer. Math., 35(4): 588-604.

[38] H. K. Aggarwal ve A. Majumdar, (2016). "Hyperspectral image denoising using spatio-spectral total variation", IEEE Geoscience and Remote Sensing Letters, 13: 442-446.

[39] T. Goldstein and S. Osher, (2009). "The split Bregman method for L1-regularized problems", SIAM J. Imag. Sci., 2(2): 323-343.

[40] M. A. T. Figueiredo and R. D. Nowak, (2003). "An EM algorithm for waveletbased image restoration", IEEE Trans. Image Process., 12(8): 906-916.

[41] F. Zhu, Datasets and Ground truths: Urban dataset, http://www.escience.cn/people/feiyunZHU/Dataset_GT.html, 16 Kasım 2016.

[42] Kruse, F. A., A. B. Lefkoff, J. W. Boardman, K. B. Heidebrecht, A.T. Shapiro, J. P. Barloon, ve A. F. H. Goetz, (1993). " The spectral image processing system (SIPS): Interactive visualization and analysis of imaging spectrometer data", Remote Sensing Environ., 44(2-3): 145-163.

[43] A. Plaza, P. Martinez, R.Perez, J.Plaza, (2004)."A quantitive and comparative analysis of endmember extraction algorithms from hyperspectral data", IEEE Transactions on Geoscience and Remote Sensing, 42(3): 650-663.

[44] D. Heinz and C. I. Chang, (2001)."Fully constrained least squares linear mixture analysis for material quantification in hyperspectral imagery", IEEE Transactions on Geoscience and Remote Sensing, 39: 529-545.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Bilal KOCAKUŞAKLAR

Doğum Tarihi ve Yeri : 02.11.1987 - BALIKESİR

Yabancı Dili : İngilizce

E-posta : bilex6084@hotmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Elektronik Müh.	Deniz Harp Okulu	2010
Lise	Fen Bilimleri	Deniz Lisesi	2006

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2010-	Deniz Kuvvetleri Komutanlığı	Subay

YAYINLARI

Makale

1. Kocakuşaklar B., Kahraman N., (2016). " THE EFFECT OF IMPULSE DENOISING ON GEOMETRIC BASED HYPERSPECTRAL UNMIXING", International Journal of Natural Sciences Research, 4(5), 83-91.