

HİPERSPEKTRAL GÖRÜNTÜLERDE LİDAR DESTEKLİ SPEKTRAL BÖLÜTLEME

LIDAR AIDED SPECTRAL SEGMENTATION ON HYPERSPPECTRAL IMAGES

ORHAN TORUN

YRD. DOÇ. DR. SENİHA ESEN YÜKSEL

Tez Danışmanı

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

2017

ORHAN TORUN'un hazırladığı “**Hiperspektral Görüntülerde Lidar Destekli Spekt-
ral Bölütleme**” adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK - ELEKTRONİK
MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.


Doç. Dr. Özgül Salor Durna

Başkan



Yrd. Doç. Dr. Seniha Esen Yüksel

Danışman




Prof. Dr. Birsen Saka Tanatar

Üye



Doç. Dr. Ali Ziya Alkar

Üye



Yrd. Doç. Dr. Yakup Sabri Özkazanç

Üye



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

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- ☐ Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etseniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- ☒ Tezimin/Raporumun 10/06/2018 tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- ☐ Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.

- ☐ Serbest Seçenek/Yazarın Seçimi

13 / 09 / 2017

(İmza)

Öğrencinin Adı Soyadı

Orhan TORUN

ETİK

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

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

beyan ederim.

13 / 09 / 2017


Orhan TORUN

ÖZET

HİPERSPEKTRAL GÖRÜNTÜLERDE LİDAR DESTEKLİ SPEKTRAL BÖLÜTLEME

Orhan TORUN

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

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

Eylül 2017, 101 sayfa

Bu tez çalışmasında, hiperspektral görüntüler ile LiDAR (Light Detection and Ranging) verileri spektral bölütleme yöntemleriyle kaynaştırılarak hiperspektral görüntülerin denetlemesiz bölütlenmesi yapılmıştır. Hiperspektral görüntüler normal KYM görüntülerden farklı olarak yüzlerce bantta görüntü oluştururlar. Bu yüksek boyutlarından ötürü hiperspektral verileri işlemek büyük problem haline gelmektedir. Bu sebeple, görüntü işlemede boyut indirgeme ve bölütleme önemli bir yere sahiptir. Bu çalışmada, hiperspektral görüntülerin bölütlenmesi için herhangi bir ön bilgiye ihtiyaç duymayan spektral bölütleme yöntemleri kullanılmıştır.

Hiperspektral görüntüler birçok spektral banda sahip olmasının yanı sıra piksel başına yüksek uzamsal çözünürlüğe de sahiptir. Uzamsal ve spektral bilgiler her ne kadar bölütlemeye katkı sağlasalar da aynı sahnede yer alan benzer spektral özelliklere sahip nesnelerin sadece bu bilgiler kullanılarak ayırt edilmesi zorlaşmaktadır. Bu benzer spektral özelliklere sahip nesneler farklı yüksekliklere sahiplerse, yükseklik bilgileri kullanılarak ayırt edilmeleri mümkündür. Ancak, hiperspektral görüntüler herhangi bir yükseklik bilgisi içermemektedir. Bu sebeple, hiperspektral görüntüler ile yükseklik bilgisi içeren başka kaynakların birleştirilmesi, verilen bir sahnedeki nesneler daha detaylı yorumlanabilir. Bu tez kapsamında, LiDAR verilerinden elde edilen yükseklik bilgisi ile hiperspektral görüntülerden elde edilen uzamsal-spektral bilgiler birleştirilerek hiperspektral görüntülerin bölütlenmesi sağlanmıştır.

Spektral bölütleme, görüntü hakkında herhangi bir ön bilgiye ihtiyaç duymaması, standart doğrusal cebir yöntemleriyle kolayca çözülmesi ve geleneksel yöntemlerden daha iyi sonuçlar vermesinden dolayı son yıllarda popüler bir yöntem haline gelmiştir. Hiperspektral görüntüler bölütlemesinde spektral bölütleme yöntemleri olan Düzgelenmiş Kesit (Normalized Cut) ve Schroedinger Özharitalar (Schroedinger Eigenmaps) kullanılmıştır. Bu yöntemlerin kullandığı benzeşim matrisi LiDAR ve hiperspektral veriler kullanılarak oluşturulmuştur. Özellikle, Nokta Tabanlı Karşılıklı Bilgi (Pointwise Mutual Information-PMI) yöntemiyle oluşturulan benzeşim matrisi kullanılarak önemli bölütleme sonuçları elde edilmiştir. Ayrıca, bu spektral bölütleme yöntemlerinin farklı çözümleri ile oluşturulan bölütleme sonuçları incelenmiş ve karşılaştırılmıştır. Uzamsal ve spektral bilgilerin yanı sıra LiDAR'dan elde edilen yükseklik bilgisinin bölütlemeye sağladığı katkı incelenmiş ve önerilen birleştirme yöntemlerin sonuçları ve mevcut yöntemlerle elde edilen bölütleme sonuçları karşılaştırılmıştır.

Anahtar Kelimeler: Hiperspektral Görüntüler, LiDAR, Denetlemesiz Bölütleme, Spektral Bölütleme

ABSTRACT

LIDAR AIDED SPECTRAL SEGMENTATION ON HYPERSPECTRAL IMAGES

Orhan TORUN

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

Supervisor: Asst. Prof. Seniha Esen YÜKSEL

September 2017, 101 pages

In this thesis, hyperspectral images and LiDAR (Light Detection and Ranging) data has been fused by using spectral clustering methods in order to obtain unsupervised hyperspectral image segmentation. Hyperspectral Images, unlike ordinary RGB images, contain hundreds of spectral bands. Because of these high dimensions, it becomes a huge problem to process hyperspectral data. For this reason, dimension reduction and segmentation in image processing have an important position. In this work, spectral clustering methods that do not require a prior information are used for segmentation of hyperspectral images.

Hyperspectral images have many spectral bands as well as high spatial resolution per pixel. Although spatial and spectral information contribute to segmentation, it is difficult to distinguish objects with similar spectral characteristics in the same scene using only this information. If these objects which comprise similar spectral information have different altitudes, it is possible to distinguish them using elevation information. However, hyperspectral images do not contain any elevation information. Therefore, hyperspectral images and other sources of elevation information can be combined to provide a more detailed interpretation of the objects in a given scene. In this thesis, elevation information obtained from LiDAR data and spatial-spectral information are fused to provide hyperspectral image segmentation.

Spectral segmentation has become a popular method in recent years because it does not need any priori information about the image, it is easily solved by standard linear algebra methods and gives better results than traditional methods. Normalized Cut and Schroedinger Eigenmaps, which are spectral clustering methods, have been used in order to segment hyperspectral images. The affinity matrix used by these methods has been constructed using LiDAR and hyperspectral data. In particular, significant segmentation results have been obtained by using the affinity matrix generated by the Pointwise Mutual Information (PMI) method. In addition, the segmentation results generated by different solutions of these spectral segmentation methods have been examined and compared. Besides the spatial and spectral information, the contribution of the elevation information obtained from LiDAR to the segmentation is examined and the segmentation results of the proposed fused methods and the segmentation results of the available methods are compared.

Keywords: Hyperspectral Imagery, LiDAR, Unsupervised Segmentation, Spectral Clustering

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde yardım ve rehberliğini esirgemeyen, değerli fikirleriyle katkıda bulunan, sabır ve anlayışından dolayı tez danışmanım Yrd. Doç. Dr. Seniha Esen Yüksel'e en içten teşekkürlerimi ve saygılarımı sunarım.

Bana sunduğu imkanlardan ötürü TÜBİTAK-BİLGEM-İLTAREN'e, moral ve motivasyon kaynağım olan değerli iş arkadaşlarıma sonsuz teşekkür ederim.

Hayatım boyunca hep yanımda olan, maddi ve manevi destekleriyle beni her zaman kucaklayan canımdan çok sevdiğim aileme çok teşekkür ederim.

Öğretim hayatım boyunca desteklerini esirgemeyen tüm öğretmenlerime teşekkürlerimi ve saygılarımı sunarım.

Bu çalışma Tübitak tarafından 115E318 no'lu proje kapsamında desteklenmiştir.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGELER	viii
ŞEKİLLER	ix
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Hiperspektral Görüntü Bölütlemeye Mevcut Yöntemler	4
1.2. Tezin Amacı	8
1.3. Tezin Kapsamı ve Akışı	9
2. SPEKTRAL BÖLÜTLEME	11
2.1. Benzerlik Çizgesi	11
2.1.1. Çizgenin Matematiksel Gösterimi	12
2.1.2. Çizgenin Bölütlenmesi	13
2.2. Düzgelenmiş Kesit	14
2.2.1. Özyinelemeli 2-Ncut (Recursive 2-Ncut)	20
2.2.2. k-ortalamalar (k-means)	21
2.2.3. Çok katmanlı Ncut (Multiclass Ncut)	22
2.2.4. Spektral Pb + UCM	23
2.3. Laplacian Özharitaları	24
2.4. Schroedinger Özharitaları	25
2.5. Benzeşim Matrisi	26
2.5.1. Shi-Malik (SM) Benzeşim Matrisi	26
2.5.2. Gilles-Bowles (GB) Benzeşim Matrisi	27

2.5.3. Hou-Zhang-Ye-Zheng (HZYZ) Benzeşim Matrisi	28
2.5.4. Nokta tabanlı karşılıklı bilgi (Pointwise mutual information-PMI) Benzeşim Matrisi	28
3. HİPERSPEKTRAL GÖRÜNTÜLERİN BÖLÜTLENMESİ	31
3.1. SM Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (SMTNcut)	33
3.2. SE Tabanlı HSG'lerin Denetlemesiz Bölütlenmesi (SET)	35
3.3. PMI Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (PMITNcut):	38
4. GERÇEK VERİLER ÜZERİNDE DENEYSEL SONUÇLAR	43
4.1. Gerçek Veri Kümesi	43
4.2. Denetlemesiz Bölütleme Sonuçlarının Nesnel Olarak Karşılaştırılması	45
4.3. SMTNcut Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları	46
4.4. SET Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları	51
4.5. PMITNcut Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları	55
4.6. Mevcut ve Önerilen Yöntemlerin Karşılaştırılması	59
5. SONUÇLAR	66
KAYNAKLAR	69
EKLER	74
ÖZGEÇMİŞ	87

ÇİZELGELER

	<u>Sayfa</u>
Çizelge 4.1. CASI-1500 hiperspektral görüntüleyicinin teknik özellikleri	43
Çizelge 4.2. Optech ALTM Gemini LiDAR sensörünün teknik özellikleri	44
Çizelge 4.3. Farklı r değerleri için SMTNcut yöntemin ortalama BD'si ($\beta_{spektral} = 0.3$, $\gamma_{uzamsal} = 5$, $\delta_{lidar} = 2$ ve kullanılan özdeğer sayısı=30) .	52
Çizelge 4.4. Farklı denemeler için PMITNcut yönteminin ortalama BD değerleri ile genel ortalama BD ve standart sapma değeri	59
Çizelge 4.5. Yöntemlerin veri kümesinin 150x220 piksellik bölümü kullanılarak elde edilen ortalama BD'leri	65

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1.1. Hiperspektral veri küpü	3
Şekil 1.2. LiDAR ve hiperspektral için elektromanyetik spektrum bölgeleri	3
Şekil 2.1. Ağırlıklandırılmış yönsüz benzerlik çizgesi	12
Şekil 2.2. Çizge bölütlenmesi	13
Şekil 2.3. Kesit değerinin en az indirgenme yönteminin kötü sonuçları	14
Şekil 2.4. Nokta kümesi	20
Şekil 2.5. Özdeğer ve bunlara karşılık gelen bazı özvektörler	20
Şekil 3.1. SMTNcut spektral bölütleme yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi	36
Şekil 3.2. SET spektral bölütleme yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi	39
Şekil 3.3. Kullanılan veri kümesinin PCA ile elde edilen en büyük 20 özdeğeri ...	41
Şekil 3.4. PMITNcut yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi .	42
Şekil 4.1. MUUFL Gulfport veri kümesinin KYM görüntüsü	44
Şekil 4.2. MUUFL Gulfport veri kümesinin bölüt doğrulama haritası	45
Şekil 4.3. Sırasıyla: Kullanılan verinin 121x121 piksellik KYM görüntüsü (sol üst), 425nm bandı, 465nm bandı, 515nm bandı, 565nm bandı, 615nm bandı, 665nm bandı, 715nm bandı, 765nm bandı, 815nm bandı, 865nm bandı, 915nm bandı, 965nm bandı, 1015nm bandı, 1050nm bandı ve LiDAR ile oluşturulan yükseklik haritası(sağ alt)	47
Şekil 4.4. Sırasıyla: Veri kümesinin 121x121 piksellik bölümü bilgileri kullanılarak oluşturulan benzeşim matrisi ($\beta_{spektral} = 0.3$, $\gamma_{uzamsal} = 5$, $\delta_{lidar} = 2$ ve $r = 5$), belli bir bölgesi yakınlaştırılmış benzeşim matrisi	48
Şekil 4.5. Veri kümesinin 121x121 piksellik bölümü kullanılarak özvektör sistemiyle oluşturulan en büyük 30 tane özdeğer (sol üst) ve ilk 8 en büyük özdeğere karşılık gelen görüntünün boyutlarına dönüştürülmüş özvektörler (y)	49

Şekil 4.6. Sürekli özvektörlerin ayrıklaştırılması sonucu oluşturulan ve görüntünün boyutlarına dönüştürülmüş ilk 8 ayırık özvektör (y')	50
Şekil 4.7. (a) Kullanılan verinin 121x121 piksellik KYM görüntüsü, (b) Verinin bölütleme doğruluk haritası, (c) SMTNcut yöntemiyle HSG'lerin bölütleme sonucu	50
Şekil 4.8. Veri kümesinin 121x121 piksellik bölümü kullanılarak özvektör sistemiyle oluşturulan en büyük 5 tane özdeğer karşılık gelen özvektörler ve bu 5 vektör ile elde edilen sPb sonucu (sağ alt)	53
Şekil 4.9. (a) $\alpha = 0$ iken bölütleme sonucu, (b) $\alpha = 4$ iken bölütleme sonucu, (c) Verinin 121x121 piksellik KYM görüntüsü, (d) $\alpha = 10$ iken bölütleme sonucu, (e) $\alpha = 50$ iken bölütleme sonucu, (f) Verinin bölütleme doğruluk haritası	54
Şekil 4.10. α 'nın değişimine bağlı olarak ortalama BD'nin değişimi	55
Şekil 4.11. Verinin 121x121 piksellik sahnesinin PCA ile oluşturulan ilk 7 temel bileşeni	57
Şekil 4.12. Verinin 121x121 piksellik sahnesinin: (a) orijinal yükseklik haritası, (b) Gauss filtresinden geçirilmiş yükseklik haritası	58
Şekil 4.13. (a) Kullanılan verinin 121x121 piksellik KYM görüntüsü, (b) Verinin bölütleme doğruluk haritası, (c) sPb ile oluşturulan görüntünün kenar bilgisi, (d) PMITNcut yöntemiyle HSG'lerin bölütleme sonucu	60
Şekil 4.14. (a) Veri kümesinin 150x220 piksellik bölümünün KYM görüntüsü, (b) Gauss filtresinden geçirilmiş yükseklik haritası, (c) Bölütleme doğruluk haritası	61
Şekil 4.15. SMTNcut yöntemin bölütleme sonucu (solda, $r=10$), bölütleme sonucu kullanılarak elde edilen kenar bilgisi (sağda)	62
Şekil 4.16. (a) SET yöntemin bölütleme sonucu (UCM eşik değeri 0.15), (b) PMITNcut yöntemin bölütleme sonucu (UCM eşik değeri 0.05) (c) Bölütleme doğruluk haritası	63

Şekil 4.17. (a) Önerilen PMITNcut yöntemin LiDAR'sız bölütleme sonucu, (b) Önerilen PMITNcut yöntemin LiDAR'lı bölütleme sonucu , (c) GB yöntemiyle oluşturulan bölütleme sonucu (LiDAR'sız), (d) Önerilen SET yönteminin bölütleme sonucu (e) SM yöntemiyle oluşturulan bölütleme sonucu (LiDAR'sız), (f) Önerilen SMTNcut yönteminin bölütleme sonucu 64



SİMGELER VE KISALTMALAR

Simgeler

D	Çizgenin derece matrisi
$d_{spektral}$	Spektral bilgiler arasındaki Euclidean uzaklığı
$d_{uzamsal}$	Uzamsal bilgiler arasındaki Euclidean uzaklığı
d_{lidar}	Yükseklik bilgileri arasındaki Euclidean uzaklığı
E	Çizgedeki boğumlar arası kenarlar
G	Benzerlik çizgesi
L	Laplacian matrisi
N	Çizgedeki boğum sayısı
P	Potansiyel matrisi
V	Çizgedeki boğumlar
W	Benzeşim matrisi
$w_{i,j}$	i . ile j . pikseller arasındaki kenar ağırlığı
$\mathbf{x}_i^u$ ve $\mathbf{x}_i^1$	i . pikselin uzamsal bilgisi
$\mathbf{x}_i^s$ ve $\mathbf{x}_i^2$	i . pikselin spektral bilgisi
$\mathbf{x}_i^y$ ve $\mathbf{x}_i^3$	i . pikselin yükseklik bilgisi
α	Potansiyel matrisi ağırlıklandırma katsayısı
$\beta_{spektral}$	Spektral benzerliği kontrol parametresi
$\gamma_{uzamsal}$	Uzamsal benzerliği kontrol parametresi
δ_{lidar}	Yükseklik benzerliği kontrol parametresi
Ω	Spektral ayrıştırma gücü

Kısaltmalar

BD	Segmentation Accuracy	Bölütleme Doğruluğu
HSG	Kernal Density Estimation	Çekirdek Yoğunluk Kestirimi
kde	Hyperspectral Image	Hiperspektral Görüntü

KYM	Red Green Blue	Kırmızı Yeşil Mavi
LE	Laplacian Eigenmaps	Laplacian Özharitaları
LiDAR	Light Detection and Ranging	Lazerle Tespit ve Menzil Tayini
LWIR	Long-Wave Infrared	Uzun-Dalga Kızılötesi
MWIR	Mid-Wave Infrared	Orta-Dalga Kızılötesi
Ncut	Normalized Cut	Düzgelenmiş Kesit
OWT	Oriented Watershed Transform	Yönlendirilmiş Havza Dönüşümü
PCA	Principle Component Analysis	Temel Bileşen Analizi
PMI	Pointwise Mutual Information	Nokta Tabanlı Karşılıklı Bilgi
PWSD	Power of Spectral Discrimination	Spektral Ayırıştırma Gücü
SAM	Spectral Angle Mapper	Spektral Açık Haritalayıcı
sam	Spectral Angle Measure	Spektral Açık Ölçüsü
SAR	Sythetic Aperture Radar	Yapay Açıklık Radarı
SE	Schroedinger Eigenmaps	Schroedinger Özharitaları
sPb	Spectral Probability of Boundary	Spektral Sınır Olasılığı
SWIR	Short-Wave Infrared	Kısa-Dalga Kızılötesi
UA	Remote Sensing	Uzaktan Algılama
UCM	Ultrametric Contour Map	Ultrametric Kontur Haritası
UV	ultraviolet	Morötesi
VNIR	Visible and Near Infrared	Görünür ve Yakın Kızılötesi

1. GİRİŞ

Uzaktan algılama (UA) nesnelerle fiziksel bir temas olmaksızın, herhangi bir uzaklıktan nesneler hakkında bilgi toplama ve yorumlama bilimi olarak tanımlanabilir [1]. UA'nın kullanılmasındaki en temel neden, bize dünyaya bakmanın farklı bir yolunu veriyor olmasıdır. Özellikle, ulaşılması zor olan ve duyu organlarımızla algılayamadığımız nesnelerin belirlenmesi ve özelliklerinin çıkartılıp yorumlanması bakımından UA büyük önem taşımaktadır. UA, sensör olarak bilinen mekanik aygıtlar yardımıyla yapılır. Bu sensörler; uçaklar, uydular veya başka platformlar kullanılarak algılanması istenilen nesnenin uzağına yerleştirilir. Çoğu algılama cihazı, bir nesnenin yüzeyinden yansıyan veya yayılan elektromanyetik enerjinin iletimini ölçerek nesne hakkındaki bilgileri kaydeder.

Kullanılan enerjiye göre UA sistemleri, pasif UA ve aktif UA diye iki gruba ayrılır. Pasif sistemler uzaktan algılamada herhangi bir enerji üretmezler ve güneş enerjisini kullanırlar. Aktif sistemler ise kendi enerjisini üretirler ve yansıttıkları enerjinin geriye dönüşünü toplayarak bilgi oluştururlar. Pasif UA sistemlerinin üretimi kolay ve maliyeti düşük olduğundan aktif UA sistemlerine göre daha çok tercih edilmektedir. Ancak, aydınlatma kaynağının kontrolüne sahip olan aktif UA sistemleri, pasif UA sistemlerine göre birçok avantajı vardır [2]. Aktif UA, gece ve gündüz şartlarından bağımsız olarak ölçüm alabilirler. Pasif UA teknikleri ile hedeften çıkarılabilecek bilgilerin çoğu, algılanan sinyalin genliği ile ilgilidir; aktif sistemlerde ise aydınlatma sinyalinin genlik, frekans, faz ve kutuplaşma parametrelerinin tam olarak bilinmesi hedefin kapsamlı bir şekilde incelenmesine olanak sağlamaktadır. Diğer bir avantaj, aktif sistemlerde frekansta veya dalga boyundaki algılanan değişmelerin ölçülmesi, hareket eden hedefin göreceli hızını belirlemek için Doppler tekniklerine olanak tanımasıdır. Son yıllarda, sensör teknolojilerinin gelişmesiyle birlikte UA uygulamaları da hızla artmaktadır. Örneğin, bu uygulamalardan bazıları:


- Doğal kaynak yönetimi ve işletimi [3],
- Arazi kullanım planlaması [4],
- Savunma ve istihbarat amaçlı uygulamalar [5],

- Jeolojik, jeomorfolojik ve tektonik amaçlı uygulamalar [6],
- Hidrolojik amaçlı uygulamalar [7],
- Tarımsal amaçlı uygulamalar [8],
- Çevre değişim analizi [9],
- Kentsel planlama [10],

Hiperspektral görüntüleme, yüzlerce dalga boyunda görüntü oluşturan yeni nesil pasif UA teknolojisidir. Hiperspektral görüntüleme sensörleri, insan gözünün algıladığı görünür ışıktaki elde edilen klasik görüntülerinden farklı olarak çok sayıdaki bitişik bantta görüntü oluşturur. Bu görüntüler nesnelerin farklı dalga boylarında ışığı ne kadar yansıttıklarının ölçümüdür. Her nesnenin ışığı yansıtma özelliği kendisine ait spektral imzasını oluşturur [11]. Şekil 1.1’de hiperspektral veri küpü ve farklı nesneler içeren beş pikselin spektral imzaları gösterilmektedir. Yüzlerce dalga boyuna bakıldığında, hiperspektral görüntülerden (HSG) her bir pikselde hangi materyal olduğu anlaşılabilir. HSG’ler bölütleme, sınıflandırma, hedef tespiti işlemlerine olanak sağladığından, askeri ve sivil uygulamalarda sıkça kullanılmaktadır [12].


Hiperspektral görüntüleme, yukarıda bahsedildiği gibi, pasif UA yöntemine dayandığından güneşten gelen ışınların yüzeydeki nesnelerden değişik dalga boylarındaki farklı yansıma özelliklerinden faydalanır. Spektral imzayı oluşturan değer spektral yansımadır. Bu yansıma, her dalga boyu için yansıyan enerjinin gelen enerjiye oranından oluşmaktadır. Hiperspektral alıcıların en belirgin özelliği önceki teknoloji olan çok bantlı (multispektral) görüntülerden farklı olarak birbirine bitişik çok daha fazla bantta olmalarıdır. Hiperspektral sensörleri, $0.01 \mu m$ gibi dar bir bant genişliğinde ve elektromanyetik spektrumun $0.4 \mu m$ ile $14 \mu m$ dalga boyunu içeren kısımda çalışırlar. Hiperspektral görüntü sensörleri, uygulama alanlarına göre dört dalga boyu aralığında görüntü toplayacak biçimde tasarlanmıştır. Şekil 1.2’de verilen elektromanyetik spektrumda da görülebileceği gibi, bu bölgeler aşağıdaki gibi sıralanabilir:

- Görünür ve yakın kızılötesi bant (VNIR, $0.4-1.1 \mu m$),



Şekil 1.1. Hiperspektral veri küpü

- Kısa dalga kızılötesi bant (SWIR, 1.1-3 μm),
- Orta dalga kızılötesi bant (MWIR, 3-5 μm),
- Uzun dalga kızılötesi bant (LWIR, 5-14 μm),



Şekil 1.2. LiDAR ve hiperspektral için elektromanyetik spektrum bölgeleri

LiDAR (Light Detection and Ranging) bir nesneyi algılamak için optik aralıktaki elektromanyetik enerjiyi kullanan, hedef ile sensör arasındaki mesafeyi belirlemek ve ışıma

ile etkileşime dayalı nesnenin fiziksel özelliklerini belirleyen aktif bir UA tekniğidir. LiDAR sistemleri enerji kaynağı olarak genellikle lazer kullanırlar. Hedef nesneye lazer darbeleri gönderilir ve yansıyan enerjiyi toplayarak hedef hakkında bilgi çıkarılır. Lazer kullanılmasının sebebi, normal ışıktan farklı olarak kaynaktan uzaklaştıkça dağılmasından ve tutarlı (coherent) olmasından kaynaklanmaktadır. Şekil 1.2’de gösterildiği gibi, LiDAR elektromanyetik spektrumun 0.3-2 μm dalga boyu bölgesi olan morötesi (UV), görünür-yakın kızılötesi (VNIR) ve kısa dalga kızılötesi (SWIR) bantlarında çalışmaktadır. Uygulama alanına göre LiDAR üç gruba ayrılabilir [13]. Bunlar:

- **Menzil Bulma LiDAR’ı:** Bir nesnenin uzaklığı belirlemek için kullanılır. Kısa dalga kızılötesi bandında çalıştıklarından, küçük hedeflerin menzillerinin hesaplanmasında etkili bir yöntemdir. Gelişmiş menzil bulma LiDAR’ı hedefin yüzeyini tarayarak, mesafenin yanı sıra hedefin şeklini ve boyutunu da belirleyebilir.
- **Diferansiyel Emilim LiDAR’ı:** Atmosferde bulunan gazların ve aerosollerin (duman, sis vb.) sıcaklığını, yoğunluğunu ve basıncını ölçmek için kullanılır.
- **Doppler LiDAR’ı:** Tutarlı (coherent) özelliğine sahip olan lazerleri kaynak olarak kullanan LiDAR sistemleri, Doppler kayması yardımıyla hedef nesnenin hızını belirlemede kullanılır.

1.1 Hiperspektral Görüntü Bölütlemeye Mevcut Yöntemler

HSG’ler iki boyutu uzamsal ve bir boyutu da spektral olmak üzere, Şekil 1.1’de verildiği gibi, üç boyutlu bir veri küpü oluşturmaktadır. Son yıllarda hiperspektral sensörler ve hiperspektral görüntüleme teknolojilerinde kaydedilen ilerlemelerle yüksek boyutluluk, veri işlemede problem haline gelmiştir. Bu nedenle HSG analizinde en hayati görevlerden biri, görüntüdeki ayrıntıları kaybetmeden görüntüyü etkin bir şekilde bölütlemektir. HSG bölütleme süreci, uzaktan algılanan bu görüntülerin yorumlaması, analiz edilmesi ve sonraki uygulamalarda kullanılması açısından önemli bir adımı oluşturmaktadır [14].

Genel anlamda görüntü bölütleme, benzer özelliklere sahip pikselleri anlamlı bölgelere ayırma işlemidir. Son yıllarda, HSG bölütleme için birçok yöntem önerilmiştir. Bu yöntemler temelde iki gruba ayrılabilir: denetlemeli (supervised) bölütleme ve denetlemesiz

(unsupervised) bölütleme. Hiperspektral görüntülerin denetlemeli bölütlemesine yönelik birçok yöntem önerilmiştir. Kullanılan bu HSG sınıflandırma yaklaşımlarının bazıları sadece spektral bilgilere dayanmaktadır [15, 16]. Bu yöntemlerle spektral özellikler, ilk önce temel bileşen analizi (principal component analysis-PCA) ve bağımsız bileşen analizi (independent component analysis-ICA) gibi bir öznitelik çıkarma yöntemi kullanılarak çıkarılmaktadır. Ayıklanan bu özellikler daha sonra bir sınıflandırıcıyı eğitmek amacıyla kullanılmaktadır. Bu yaklaşımlar yalnızca spektral bilgileri dikkate almakta ve görüntüdeki farklı pikseller arasındaki ilintiyi göz ardı etmektedir. Bu yöntemler hem uzamsal hem de spektral bilgiler kullanan diğer yöntemlere kıyasla düşük performans göstermektedirler.

Gerçek görüntülerde komşu pikseller aslında birbiriyle ilişkilidir. Bu nedenle, her bir pikselin hem uzamsal hem de spektral bilgisi kullanılarak sınıflandırma sonuçları iyileştirilebilir. Son zamanlarda, Markov Rastgele Alan (Markov Random Field) ile uzamsal ve spektral bilgiler kullanılarak HSG'lerin bölütlenmesi ve sınıflandırılması gerçekleştirilmiştir [17]. Diğer bir yöntem ise yama tabanlı öznitelik çıkarma yöntemidir [18]. Yama tabanlı yöntem sınıflandırıcı eğitilmeden önce kare pencereler kullanarak komşu pikselleri gruplar ve sonra bir alt-uzay öğrenme tekniği kullanarak her yerel pencereye dayanan özellikleri çıkararak sınıflandırma yapmaktadır. Ancak, HSG'lerde denetlemeli bölütleme ve sınıflandırma yöntemleri malzemelerin spektral imzaları ve/veya bölütleme haritaları gibi önsel bilgilere ihtiyaç duyarlar. Malzemelerin spektral imzalarının elde edilmesi zor ve pahalı bir işlemdir ve gerçek UA problemlerinde bölütleme haritaları bilinmemektedir. Bu sebeplerden ötürü, denetlemeli bölütlemenin uygulama alanları sınırlıdır [19].

Denetlemeli bölütlemeye kıyasla, denetlemesiz hiperspektral görüntü bölütlemesi nispeten daha az ilgi görmüştür. Bununla birlikte, denetlemesiz bölütleme herhangi bir önsel bilgiye gereksinim duymadığından birçok uygulama alanında kullanılabilir. Bu sebeple, halen daha da geliştirilmesi gereken önemli bir alandır. Denetimsiz bölütleme, hiperspektral görüntülerin içeriğini herhangi bir ön bilgi olmadan keşfetmeye ve anlamaya olanak sağlar. Hiperspektral görüntülerin bölütlenmesini sağlamak için spektral ve uzamsal bilgileri dikkate alarak denetlemesiz teknikler geliştirilmesine ilgi artmakta-

dır. Yakın tarihte, Watershed dönüşüm tabanlı bölütleme hiperspektral görüntülerin denetlemesiz bölütlemesi için önerilmiş bir tekniktir [20]. Watershed dönüşümü genelde, tek banttan oluşan görüntülerin gradyan fonksiyonuna uygulanır. Gradyan, bölgeler arasındaki geçişleri tanımlar; homojen bölgelerdeki nesneler ve minimumlar arasındaki sınırlarda yüksek değerlere sahiptir. Diğer bir deyişle, gradyan görüntüdeki nesnelerin kenar çizgilerine karşılık gelmektedir. Bu gradyan fonksiyonuna Watershed dönüşümü uygulandığında görüntüyü anlamlı bölgelere ayırmak mümkün hale gelmektedir. Ancak, HSG'ler birden çok bant içerdiğinde gradyan fonksiyonun hesaplanması için uygun hale getirilmelidir. HSG'ler, temel bileşen analizi ve bağımsız bileşen analizi gibi yöntemler ile tek banda indirdikten sonra oluşturulan gradyan fonksiyonu kullanarak veya [20]'de anlatılan vektörel gradyan yöntemleri kullanarak Watershed dönüşümüne uygun hale getirilmektedir. Bu yöntemle elde edilen bölütleme haritası daha sonra sınıflandırma performanslarını iyileştirmek için kullanılır. Bununla birlikte, eğer temel hedef denetlemesiz bölütleme ise, Watershed tabanlı tekniğin kullanılması genelde görüntüdeki nesneleri gereğinden fazla bölüte ayırmaktadır.

Doğru bölütleme sonuçlarının elde edilmesine yönelik alternatif bir diğer yol, işaretleyici (marker) kontrollü bölütleme uygulamaktır. İşaretleyici kontrollü yöntemlerde temel fikir, her uzamsal nesne için, bu nesneye ait bir veya birkaç pikseli, yani bir işaretleyici seçmektir. Ardından, seçilen işaretleyicilerden bölgeler büyütülmekte, böylelikle bölütleme haritası elde edilmektedir. Bölge işaretleyicileri, zaman alıcı bir yöntem olan elle veya otomatik olarak seçilebilmektedir. Otomatik yaklaşımda, verilere sınıflandırma yöntemleri uygulanmakta ve daha sonra en güvenilir şekilde sınıflandırılmış pikseller ilgili bölgelerin işaretleyicileri olarak seçilmektedir. Literatürde, bu bölge işaretleyicilerden Minimum Yayılmış Orman (Minimum Spanning Forest-MSF) oluşturulmasıyla bölütleme yapan bir yöntem önerilmiştir [21]. Bölge işaretleyicileri tabanlı diğer bir yöntem ise Hiyerarşik Bölütleme (Hierarchical Segmentation - HSEG) yöntemidir [22]. Bu yöntemde işaretleyicilerin kullanılması, tek bir bölütün otomatik olarak seçilmesini sağlar. Bu yöntemlerin dezavantajı, güvenilir işaretleyicilerin belirlenmesi için bölütleme doğruluk haritaları gibi elde edilmesi zor ve pahalı bilgiler gerektirmesidir.

Diğer bir yöntem, dokusal bölgelerin özniteliklerini yakalamayı hedefleyen Markov Rast-

gele Alan (Markov Random Field - MRF) modelidir [23]. Nispeten daha eski olan bu yöntem, doğrudan piksel üzerinde çalışmak yerine, fazla bölütlenmiş görüntü için iki aşamalı bir algoritma kullanmaktadır. İlk aşamada, fazla bölütlenmiş bölgeler için bölge yakınlık grafiği çizilmektedir. MRF modelinin enerji fonksiyonu, bölge içi homojenlik ve bölgeler arası benzerlik temelinde tanımlanmaktadır. İkinci aşamada, Fischer dağılımına dayalı bir eşik ile karşılaştırıldığında bu enerji fonksiyonun değerine dayalı olarak bölge birleştirme gerçekleştirilmektedir. Yine yakın tarihte, ağırlıklandırılmış kümeleme yoluyla başlatılan ve spektral-uzamsal bilgileri kullanarak Uyarlanabilir Sınır Ayarı (Adaptive Boundary Adjustment - ABA) tabanlı denetlemesiz HSG bölütleme yöntemi önerilmiştir [24]. Bu model, hiperspektral verilerinin iki temel özelliğini kullanmaktadır: spektral ilinti ve uzamsal bant tercihi. Bant tercihi, her bir bantta bulunan ayırt edici bilgi ile tanımlanmakta, spektral ilintinin korunması ve gerçek yapının uzamsal boyutlarla eşleştirilmesi için uyarlanabilir bir mekanizma önerilmektedir. Bölütleme işlemi, görüntüyü farklı bant gruplarına bölerek her banttaki bilgi gücüyle uyarlanabilir şekilde ayarlanmaktadır. Yakın tarihte önerilen diğer bir yöntem ise, hiperspektral veri gibi çok yüksek boyutlu verileri işlemek için İkili Bölme Ağacı (Binary Partition Tree- BPT) tabanlı yöntemdir [25]. BPT, bir görüntünün ağaç yapısında hiyerarşik bölge tabanlı gösterimidir. Çoğunlukla, ağaç yapısı budanma olarak adlandırılan işlemde geçirilerek görüntülerin bölütlere ayrılması sağlanmaktadır. Bu yöntem, kullanıcıların farklı bölütleme ölçeklerinde görüntüyü incelemelerine olanak sağlamaktadır. Ancak, bu yöntem ABA tabanlı yöntemle göre daha düşük performans göstermektedir.

Görüntü bölütlemesi konusunda çizge tabanlı bölütleme algoritmaları, yüksek performansı nedeniyle oldukça popüler ve olgun hale gelmiştir. HSG'lerin bölütlemesinde de yakın tarihte çizge tabanlı algoritmaya dayanan bir spektral yöntem önerilmiştir [26]. Bu yöntemle çizgenin kenar ağırlıkları, pikseller arasındaki uzamsal ve spektral mesafelerin ağırlıklı birleşimi ile oluşturulmaktadır. Ardından görüntü, yinelemeli olarak bölütlere ayrılmaktadır. Matematiksel olarak basit çözümü olmasına rağmen, yinelemeli yöntemin sonlandırma kistasını belirlemek zordur. Bu tez kapsamında, geliştirdiğimiz algoritmalar da çizge tabanlı bölütleme alanına girmektedir.

Bu yeni yöntemlere kıyasla günümüze göre daha eski olan çalışmalar da mevcuttur.

Örneğin, piksek benzerliklerini kullanarak bölütleme yapan morfolojik bir yöntem önerilmiştir [27]. Hiperspektral görüntüleri doğru bir şekilde bölütlemek için, karşılıklı bilgi [28] ve faz korelasyonu [29] gibi teknikler kullanılmıştır. HSG'lerde istatistiksel denetlemesiz bölütleme yöntemi olarak Gauss Karışım Modelleri (Gaussian Mixture Models - GMM) kullanılmıştır [30].

1.2 Tezin Amacı

Mevcut HSG bölütleme ve sınıflandırma algoritmaların çoğu ya spektral uzayda ya da uzamsal uzayda çalışmaktadır. Teknolojini gelişmesiyle HSG'lerin uzamsal çözünürlükleri artmıştır. Bununla birlikte, bölütleme ve sınıflandırma sonuçlarını daha da geliştirmek için HSG'lerin uzamsal ve spektral bileşenleri birlikte kullanılmaya başlanmıştır [26, 31, 32]. HSG'ler, çok sayıda spektral bant içerdiklerinden dolayı, farklı spektral özellikler taşıyan nesnelerin ayırt edilmesine olanak sağlamaktadırlar. Ancak, uzamsal ve spektral bilgiler her ne kadar bölütlemeye katkı sağlasa da aynı sahnede yer alan benzer spektral özelliklere sahip nesnelerin sadece bu bilgiler kullanılarak ayırt edilmesi zorlaşmaktadır. Bundan dolayı; bölütleme, sınıflandırma ve hedef tespiti uygulamalarında performansı iyileştirmek amacıyla HSG'lerden elde edilen uzamsal-spektral bilgiler ile tamamlayıcı nitelikte olan farklı veri kaynaklarına başvurmak gerekebilir. Bu amaçla, literatürde farklı kaynaklardan toplanan verilerin kaynaştırılması üzerine çalışmalar mevcuttur [33, 34, 35]. Eğer, aynı sahnede yer alan benzer spektral özelliklere sahip nesneler farklı yüksekliklere sahiplerse, yükseklik bilgileri kullanılarak ayırt edilebilir. Ancak, hiperspektral görüntüler herhangi bir yükseklik bilgisi içermemektedir. Bu sebeple, hiperspektral görüntüler ile yükseklik bilgisi içeren başka kaynakların birleştirilmesi verilen bir sahnedeki nesnelerin daha detaylı yorumlanması gerçekleştirilebilir.

Bu tez çalışmasında, yükseklik bilgisi kaynağı olarak yeni bir UA teknoloji olan LiDAR kullanılmıştır. LiDAR'dan elde edilen yükseklik bilgisi, hiperspektral görüntüleri tamamlayıcı niteliktedir. Örneğin, bölütlemeye sorun teşkil eden benzer spektral malzemelerin yükseklik haritaları kullanarak ayırmak mümkündür. Bu nedenle, HSG bölütlenmesinde LiDAR'dan türetilmiş yükseklik bilgisinin kullanılması göz önüne alınmalıdır. HSG'lerin denetlemesiz bölütlenmesi için hiperspektral verilerden elde edilen uzamsal ve spektral bilgilerle LiDAR'dan elde edilen yükseklik bilgisi verimli bir şekilde birleştirilmesi gerek-

mektedir. Bu amaçla, çalışmamızda, çizge tabanlı spektral bölütleme yöntemleri kullanılarak hiperspektral verileri ve LiDAR verileri birleştirilerek bölütleme sonuçları geliştirilmiştir. Günümüzde, spektral bölütleme popüler bir yöntem haline gelmiştir. Standart doğrusal cebir yöntemleriyle verimli bir şekilde çözülebilir olması ve k-ortalamlar (k-means) ile tek bağlı (single linkage) gibi geleneksel yöntemlerden daha iyi sonuçlar üretmesi nedeniyle tercih edilmektedir [36]. Spektral kümeleme yöntemiyle komşu pikseller arasındaki spektral ve yükseklik benzerlikleri göz önüne alınarak çizge elde edilir. Oluşturulan bu çizgede farklı grupta yer alan pikseller arasındaki kenarların düşük ağırlık alması, aynı grup içindeki piksellerin arasındaki kenarların da yüksek ağırlık alması amaçlanır. Bu amacı gerçekleştirmek için, spektral bölütlemeye en önemli nokta benzeşim matrisinin (similarity matrix) probleme uygun seçilmesidir. Bu çalışmada, hem uzamsal-spektral hem de yükseklik bilgilerini birleştirecek yeni benzeşim matrisleri önerilmiştir. Elde edilen bu benzeşim matrisleri spektral bölütlemeye kullanılarak HSG'lerin bölütlenmesi gerçekleştirilmiştir. Bu kapsamda, spektral bölütleme yöntemlerinden Düzgelenmiş Kesit (Normalized Cut-Ncut) ile Schroedinger Özharitalar (Schroedinger Eigenmaps-SE) algoritmaları kullanılmış, önerilen yeni benzeşim matrisleri ile bu algoritmaların farklı çözümleri ele alınarak bölütleme sonuçları incelenmiştir. LiDAR'dan elde edilen yükseklik bilgisinin hiperspektral görüntü bölütlemesine sağladığı katkılar tartışılmıştır.

1.3 Tezin Kapsamı ve Akışı

Tezin geri kalanı şu şekilde organize edilmiştir:

İkinci bölümde, spektral bölütlemenin temeli olan çizge teorisi anlatılmıştır. Çizge oluştururken dikkat edilmesi gereken noktalara değinilmiş ve çizgedeki boğumlar arasındaki kenarların ağırlıklarının nasıl belirleneceği açıklanmıştır. Çizge oluşturulduktan sonra bölütlerin elde edilmesi için spektral bölütleme yöntemleri olan Düzgelenmiş Kesit (Ncut) ve Schroedinger Özharitalar (SE) algoritmalarının matematiksel çıkarımları geniş bir şekilde ele alınmıştır. Bu algoritmaların farklı çözümleri anlatılmış ve çözümlerin birbirlerine göre avantaj ve eksiklikleri belirtilmiştir. Spektral bölütlemeye önemli nokta olan benzeşim matrisini oluşturmak için literatürde mevcut olan yöntemlere değinilmiştir.

Bu tez kapsamında, KYM görüntü bölütlemesi için Shi-Malik [38] tarafından önerilen spektral yöntem temel alınarak, HSG'ler bölütlenmesi çalışılmıştır. HSG bölütleme doğruluğunu arttırmak amacıyla LiDAR'dan elde edilen yüksek bilgisi, spektral ve uzamsal bilgilerle uygun şekilde birleştirilmesi için araştırmalar yapılmış ve uygun yöntemler geliştirilmiştir. Bu amaç doğrultusunda üçüncü bölümde, HSG'lerin bölütlenmesi için yeni yöntemler önerilmiştir. Ncut ve SE spektral bölütleme algoritmalarının kullandığı benzeşim matrisi, HSG'lerden elde edilen uzamsal ve spektral bilgiler ile LiDAR'dan elde edilen yükseklik bilgisini kullanacak şekilde geliştirilmiştir. Benzeşim matrisi oluşturulurken ilgili parametrelerin seçilmesi ve bu parametrelerin bölütleme sonuçlarına etkisi tartışılmıştır. Spektral bölütlemenin farklı çözümleri kullanılarak görüntü bölütleme doğruluğu arttırılmıştır. Tez boyunca çalışılan SM benzeşim matrisi tabanlı Ncut yöntemiyle HSG'lerin denetlemesiz bölütlenmesi, SE tabanlı HSG'lerin denetlemesiz bölütlenmesi ve PMI benzeşim matrisi tabanlı Ncut yöntemiyle HSG'lerin denetlemesiz bölütlenmesi algoritmaları üçüncü bölümde ayrıntılı olarak açıklanmıştır.

Dördüncü bölümde, denetlemesiz bölütleme için kullanılan MUUFL Gulfport gerçek veri kümesi tanıtılmıştır. Önerilen denetlemesiz bölütleme yöntemleri bu gerçek veri kümesine uygulanmıştır. Denetlemesiz bölütleme sonuçlarının performanslarını değerlendirebilmek ve farklı yöntemlerle elde edilen bölütleme haritalarının doğruluğunu karşılaştırmak için istatiksel bir yöntem olan Spektral Ayırıştırma Gücü (Power of Spectral Discrimination-PSD) kullanılmıştır. Spektral bölütleme yöntemlerinin kullandığı parametrelere farklı değerler verilerek bölütleme üzerindeki etkileri karşılaştırılmış ve yorumlanmıştır. LiDAR'dan elde edilen yükseklik bilgisinin bölütleme sonuçlarına katkıları tartışılmıştır. Mevcut yöntemlerle önerilen yöntemler karşılaştırılmıştır.

Son bölümde ise tez genelinde önerilen HSG bölütleme yöntemleri ve sonuçları ile ilgili çıkarımlara yer verilmiştir.

2. SPEKTRAL BÖLÜTLEME

Görüntü bölütleme, görüntüdeki nesneleri gruplama tekniğidir. Diğer bir deyişle, bir görüntüyü benzer özelliklere sahip farklı bölgelere ayırma yöntemidir. Bölütleme, veri analizi için sıklıkla kullanılmaktadır. Temel olarak, görüntü bölütlemenin amacı aşağıdaki gibi sıralanabilir:


- Görüntü veya görüntü gruplarından yararlı bilgiler çıkartmak,
- Nesneleri arka plandan ayırmak,
- Farklı nesneleri birbirinden ayırmak,

Bir önceki bölümde de bahsedildiği gibi, standart doğrusal cebir yöntemleriyle çözülebilen ve geleneksel yöntemlerden daha iyi sonuçlar vermesinden dolayı spektral bölütleme son yıllarda popüler bir yöntem haline gelmiştir. Bu bölümde, spektral bölütleme için gerekli olan çizge teorisi anlatılmış ve HSG'lerin bölütlemesi için kullanılan spektral bölütleme yöntemlerinin teorileri verilmiştir.

Konuya başlamadan önce, hiperspektral görüntülerde ve spektral bölütlemelerde yer alan "spektral" kelimesinden dolayı aralarında bir bağlantı olduğu düşünülebilir, ancak ifade ettikleri kavramlar tamamen farklıdır. Daha önce belirtildiği gibi hiperspektral görüntüler, çok sayıdaki bitişik bantta toplanan görüntü topluluğudur. Diğer yandan spektral bölütleme ise; bir nokta topluluğuyla, bir KYM görüntüyle veya bir hiperspektral görüntüyle çizge oluşturarak ilgili bu veri kümelerini bölütlere ayırma yöntemidir.

2.1 Benzerlik Çizgesi

Bir veri kümesi içindeki noktaları kümelendirmenin amacı, birbirine benzeyen noktaları aynı grubun içine dahil ederek ve birbirlerine benzemeyenleri ise farklı gruplara yerleştirerek bölmektir. Veri noktaları arasındaki benzerliklerden daha fazla bilgiye sahip değilsek, verileri temsil etmenin güzel bir yolu benzerlik çizgesi, $\mathbf{G} = (\mathbf{V}, \mathbf{E})$, oluşturmaktır [36]. Bir $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi, $\mathbf{V}$ boğumlarının $\mathbf{E}$ kenarları ile birleştirilmesi sonucunda oluşturulur. Burada $\mathbf{V}$ boğumları, veri kümesindeki noktaları ifade etmektedir. $\mathbf{E}$ ise veri




Şekil 2.1. Ağırlıklandırılmış yönsüz benzerlik çizgesi

kümesindeki nokta çiftlerinin arasındaki kenarları ifade eder. Şekil 2.1’de A ve B sınıflarından oluşan çizgede, boğumlar ve bu boğumları birbirine bağlayan kenarlar gözük-mektedir. Her bir boğumu birbirine bağlayan kenarlara bir ağırlık verildiğinde, bu çizgeye ağırlıklandırılmış çizge denilmektedir. Şekilde gözüktüğü gibi i ve j adındaki iki boğumu bağlayan kenar ağırlıkları $w_{i,j}$ ile ifade edilmektedir. Bu ağırlıklar, boğumların birbirine olan benzerlikleri kullanılarak hesaplanmaktadır. İki boğumun benzerliği yüksekse ke-nar ağırlığı 1’e yakın, aksi halde 0’a yakındır, yani aralarında bağlantı yok demektir. Eğer bir $G = (V, E)$ çizgesindeki kenar ağırlıkları $w_{i,j} = w_{j,i}$ koşulunu sağlıyorsa, bu çizge yönsüz çizge diye adlandırılmaktadır.

2.1.1 Çizgenin Matematiksel Gösterimi

$G = (V, E)$, kenar ağırlıkları $w_{i,j}$ olan bir ağırlıklandırılmış yönsüz çizge olsun. $W(i, j) = \{w_{i,j}\}$ matrisi çizgenin benzerlik matrisi olarak tanımlanır. Bu matrisin her bir indisi i ve j boğumlarını birleştiren $w_{i,j}$ ile ifade ettiğimiz kenarın ağırlığıdır. Çizgede toplamda n tane boğum varsa, i . boğumun derecesi $d_i = \sum_{j=1}^n w_{i,j}$ olarak hesaplanır. Aslında, bu toplam yalnızca i . boğuma komşu kenarlar üzerinden hesaplanır, diğer tüm kenarların ağırlıkları sıfıra eşittir. D ise köşegenleri $d_1, \dots, d_n$ olan diyagonal bir matristir ve çiz-genin derece matrisi olarak adlandırılır. Son olarak, ilerde matematiksel gösterimlerde kullanacağımız ve Laplacian matrisi olarak adlandırılan L matrisi denklem (2.1)’de gös-terildiği gibi hesaplanır.

$$L = D - W \quad (2.1)$$



Şekil 2.2. Çizge bölütlenmesi

2.1.2 Çizgenin Bölütlenmesi

Çizgeyi bölütlemedeki amacımız, çizgeyi ayırık boğum kümelerine ayırmaktır. Öyle ki, her bir boğum sadece bir grupta yer alacak ve tüm grupların toplamı çizgeyi oluşturacak şekilde sınıflandırmaktır. Bir örnek üzerinde olaya bakacak olursak, Şekil 2.2’de gösterilen çizgeyi A ve B gibi ayırık gruplara bölmek hedeflenmektedir. Yani, $A \cup B = V$ ve $A \cap B = \emptyset$ olacak şekilde çizgeyi bölmek gerekmektedir. Bunu yaparken önemli iki soru karşımıza çıkmaktadır:

1. İyi bir bölütleme için kesin kıstas nedir?
2. Böyle bir bölütleme nasıl verimli bir şekilde hesaplanabilir?

Çizgedeki A ve B grupları arasındaki farklılık derecesi, bu iki grup arasındaki kenar ağırlıklarının toplamı olarak ifade edilebilir. Çizge teorisinde, bu değer kesit (*cut*) olarak ifade edilir ve denklem (2.2)’deki gibi hesaplanır.


$$cut(A, B) = \sum_{i \in A, j \in B} w_{i,j} \quad (2.2)$$

Çizgeyi en iyi bölüte ayırmanın yolu, denklem (2.3)’te verildiği gibi bu kesit değerini en aza indirmekle eşdeğerdir [37]. Denklem (2.3)’e göre, i boğumları A sınıfında ve

j boğumları B sınıfında kalacak şekilde, boğumlar arasındaki ağırlıkların en küçük olduğu kenarlardan ayırmak hedeflenmektedir. Böylece birbirine benzeyen boğumlar aynı gruba yerleştirilir ve diğer boğumlardan ayrılması gerçekleştirilir.

$$\min cut(A, B) = \min \sum_{i \in A, j \in B} w_{i,j} \quad (2.3)$$

Fakat, Şekil 2.3'te verilen çizge örneğinde olduğu gibi çizgedeki uç boğumların kesit değeri küçük olduğundan, denklem (2.3)'ün sonucunda uç boğumlar yanlış sınıflandırılabilir. Bunu önlemek amacıyla Düzgelenmiş Kesit yöntemi geliştirilmiştir [38].



Şekil 2.3. Kesit değerinin en az indirgenme yönteminin kötü sonuçları

2.2 Düzgelenmiş Kesit

Yukarıda bahsedilen ve Şekil 2.3'te gösterildiği gibi, kesit değerinin ayrık uç boğumları bölütlemesindeki bu doğal olmayan eğilimini önlemek için denklem (2.2)'nin düzgelenmesi gerekmektedir. Bu problemin çözümü için [38]'de Düzgelenmiş Kesit (Normalized Cut-Ncut) yöntemi önerilmiştir. Kesit değeri çizgede mevcut olan tüm bağlantılarla düzgelesek denklem (2.4)'te verilen Ncut yöntemi elde edilmektedir. Denklem (2.5)'te verilen *assoc*, A 'daki boğumların çizgedeki tüm boğumlara olan bağlantısını ifade etmektedir.

$$Ncut(A, B) = \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)} \quad (2.4)$$

ve

$$assoc(A, V) = \sum_{i \in A, j \in V} w_{i,j} \quad (2.5)$$

Düzgelenmiş Kesit yöntemi, boğumlar arasındaki bağların kuvvetine göre gruplarken, A ve B gibi gruplar arasındaki ayırımı azaltıp, grupların kendi içindeki ilişkiyi arttırmayı amaçlar [38]. Bunu gerçekleştirmek için Ncut maliyetinin minimize edilmesinin gerekir. Ancak, bu maliyet fonksiyonun minimize edilmesinin Belirsiz Çokterimli Tam (Nondeterministic Polynomial Complete- NPC) problem sınıfına girdiği [38]'de ispatlanmıştır. NPC problemleri çözümleme zamanı arttıkça artan bir yapıya sahiptirler. Fakat ayrık çözüme sahip Ncut problemi reel sayılar kümesinden değer alacak şekilde genişletilirse, yaklaşık bir ayrık çözüm bulunabilmektedir. Bu çözüm [38]'de ispatlanmış, aşağıda da detaylı olarak verilmiştir.

Şekil 2.2'de A ve B sınıflarından oluşan $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi verilsin ve $\mathbf{x}$ çizgedeki boğum sayısını, yani $N = |\mathbf{V}|$ boyutunda bir gösterge vektörünü temsil etsin. Bir i boğumu A sınıfında yer aldığı için $\mathbf{x}_i = 1$ değerini alırken, bu boğum B sınıfında yer alırsa $\mathbf{x}_i = -1$ değerini almaktadır. Bu anlamda, denklem (2.4)'te verilen Ncut değerini yeniden yazarsak:

$$\begin{aligned} Ncut(A, B) &= \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)} \\ &= \frac{\sum_{\mathbf{x}_i > 0, \mathbf{x}_j < 0} -w_{i,j} \mathbf{x}_i \mathbf{x}_j}{\sum_{\mathbf{x}_i > 0} \mathbf{d}_i} + \frac{\sum_{\mathbf{x}_i < 0, \mathbf{x}_j > 0} -w_{i,j} \mathbf{x}_i \mathbf{x}_j}{\sum_{\mathbf{x}_i < 0} \mathbf{d}_i} \end{aligned} \quad (2.6)$$

Denklem (2.6)'nın sonucunu üzerinde işlem yapılacak hale getirmek için; tüm girdileri bir olan $N \times 1$ boyutunda $\mathbf{1}$ vektörü verildiğinde, gösterge vektörünün $\mathbf{x}_i > 0$ değerleri için $\frac{\mathbf{1} + \mathbf{x}}{2}$ ve $\mathbf{x}_i < 0$ değerleri için de $\frac{\mathbf{1} - \mathbf{x}}{2}$ değeri kullanılabilir. Denklem (2.7)'deki bölüme de k dersek:

$$k = \frac{\sum_{\mathbf{x}_i > 0} \mathbf{d}_i}{\sum_i \mathbf{d}_i} \quad (2.7)$$

Denklem (2.6)'daki $Ncut$, denklem (2.8)'deki gibi düzenlenebilir.

$$\begin{aligned}
 4[Ncut(\mathbf{x})] &= \frac{(\mathbf{1} + \mathbf{x})^T (\mathbf{D} - \mathbf{W})(\mathbf{1} + \mathbf{x})}{k \mathbf{1}^T \mathbf{D} \mathbf{1}} + \frac{(\mathbf{1} - \mathbf{x})^T (\mathbf{D} - \mathbf{W})(\mathbf{1} - \mathbf{x})}{(1 - k) \mathbf{1}^T \mathbf{D} \mathbf{1}} \\
 &= \frac{\mathbf{x}^T (\mathbf{D} - \mathbf{W}) \mathbf{x} + \mathbf{1}^T (\mathbf{D} - \mathbf{W}) \mathbf{1}}{k(1 - k) \mathbf{1}^T \mathbf{D} \mathbf{1}} + \frac{2(1 - 2k) \mathbf{1}^T (\mathbf{D} - \mathbf{W}) \mathbf{x}}{k(1 - k) \mathbf{1}^T \mathbf{D} \mathbf{1}}
 \end{aligned} \tag{2.8}$$

Takip kolaylığı amacıyla denklem (2.8)'deki bazı terimler yerine aşağıda verilen simgelerle devam edilecektir.

$$\begin{aligned}
 \alpha(\mathbf{x}) &= \mathbf{x}^T (\mathbf{D} - \mathbf{W}) \mathbf{x}, \\
 \beta(\mathbf{x}) &= \mathbf{1}^T (\mathbf{D} - \mathbf{W}) \mathbf{x}, \\
 \gamma &= \mathbf{1}^T (\mathbf{D} - \mathbf{W}) \mathbf{1}, \\
 M &= \mathbf{1}^T \mathbf{D} \mathbf{1}
 \end{aligned} \tag{2.9}$$

Bu simgeleri kullanarak, denklem (2.8) aşağıdaki gibi daha geniş şekilde yazılabilir:

$$\begin{aligned}
 4[Ncut(\mathbf{x})] &= \frac{(\alpha(\mathbf{x}) + \gamma) + 2(1 - 2k)\beta(\mathbf{x})}{k(1 - k)M} \\
 &= \frac{(\alpha(\mathbf{x}) + \gamma) + 2(1 - 2k)\beta(\mathbf{x})}{k(1 - k)M} - \frac{2(\alpha(\mathbf{x}) + \gamma)}{M} + \frac{2\alpha(\mathbf{x})}{M} + \frac{2\gamma}{M}
 \end{aligned} \tag{2.10}$$

Yukardaki denklemin sağdaki son terimi sıfır olduğundan, $\gamma = 0$, ihmal edilebilir. Denk-

lem (2.10)'u yeniden düzenlersek:

$$\begin{aligned}
 4[Ncut(\mathbf{x})] &= \frac{(1 - 2k + 2k^2)(\alpha(\mathbf{x}) + \gamma) + 2(1 - 2k)\beta(\mathbf{x})}{k(1 - k)M} + \frac{2\alpha(\mathbf{x})}{M} \\
 &= \frac{\frac{(1 - 2k + 2k^2)}{(1 - k)^2}(\alpha(\mathbf{x}) + \gamma) + \frac{2(1 - 2k)}{(1 - k)^2}\beta(\mathbf{x})}{\frac{k}{1 - k}M} + \frac{2\alpha(\mathbf{x})}{M}
 \end{aligned} \tag{2.11}$$

Denklem (2.11)'deki $\frac{k}{1 - k}$ 'ye b dersek ve $\gamma = 0$ olduğundan bu denklem aşağıdaki gibi düzenlenebilir:

$$\begin{aligned}
 4[Ncut(\mathbf{x})] &= \frac{(1 + b^2)(\alpha(\mathbf{x}) + \gamma) + 2(1 - b^2)\beta(\mathbf{x})}{bM} + \frac{2b\alpha(\mathbf{x})}{bM} \\
 &= \frac{(1 + b^2)(\alpha(\mathbf{x}) + \gamma)}{bM} + \frac{2(1 - b^2)\beta(\mathbf{x})}{bM} + \frac{2b\alpha(\mathbf{x})}{bM} + \frac{2b\gamma}{bM}
 \end{aligned} \tag{2.12}$$

Denklem (2.9)'daki $\alpha(\mathbf{x})$, $\beta(\mathbf{x})$, γ ve M değerlerini denklem (2.12)'de yerlerine koyarsak:

$$\begin{aligned}
 4[Ncut(\mathbf{x})] &= \frac{(1 + b^2)(\mathbf{x}^T(\mathbf{D} - \mathbf{W})\mathbf{x} + \mathbf{1}^T(\mathbf{D} - \mathbf{W})\mathbf{1})}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &\quad + \frac{2(1 - b^2)\mathbf{1}^T(\mathbf{D} - \mathbf{W})\mathbf{x}}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &\quad + \frac{2b\mathbf{x}^T(\mathbf{D} - \mathbf{W})\mathbf{x}}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &\quad + \frac{2b\mathbf{1}^T(\mathbf{D} - \mathbf{W})\mathbf{1}}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &= \frac{(\mathbf{1} + \mathbf{x})^T(\mathbf{D} - \mathbf{W})(\mathbf{1} + \mathbf{x})}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &\quad + \frac{b^2(\mathbf{1} - \mathbf{x})^T(\mathbf{D} - \mathbf{W})(\mathbf{1} - \mathbf{x})}{b\mathbf{1}^T\mathbf{D}\mathbf{1}} \\
 &\quad + \frac{2b(\mathbf{1} - \mathbf{x})^T(\mathbf{D} - \mathbf{W})(\mathbf{1} + \mathbf{x})}{b\mathbf{1}^T\mathbf{D}\mathbf{1}}
 \end{aligned} \tag{2.13}$$

Son olarak denklem (2.13)'ün sonucunu düzenlersek:

$$4[Ncut(\mathbf{x})] = \frac{[(\mathbf{1} + \mathbf{x}) - b(\mathbf{1} - \mathbf{x})]^T (\mathbf{D} - \mathbf{W}) [(\mathbf{1} + \mathbf{x}) - b(\mathbf{1} - \mathbf{x})]}{b\mathbf{1}^T \mathbf{D}\mathbf{1}} \quad (2.14)$$

Denklem (2.14)'teki $(\mathbf{1} + \mathbf{x}) - b(\mathbf{1} - \mathbf{x})$ 'ye $\mathbf{y}$ dersek ve $b = \frac{k}{1-k} = \frac{\sum_{\mathbf{x}_i > 0} \mathbf{d}_i}{\sum_{\mathbf{x}_i < 0} \mathbf{d}_i}$ olduğundan (2.15)'te ve (2.16)'da yer alan eşitliklere kolay bir şekilde ulaşılabilir.

$$\mathbf{y}^T \mathbf{D}\mathbf{1} = \sum_{\mathbf{x}_i > 0} \mathbf{d}_i - b \sum_{\mathbf{x}_i < 0} \mathbf{d}_i = 0 \quad (2.15)$$

ve

$$\begin{aligned} \mathbf{y}^T \mathbf{D}\mathbf{y} &= \sum_{\mathbf{x}_i > 0} \mathbf{d}_i + b^2 \sum_{\mathbf{x}_i < 0} \mathbf{d}_i \\ &= b \sum_{\mathbf{x}_i < 0} \mathbf{d}_i + b^2 \sum_{\mathbf{x}_i < 0} \mathbf{d}_i \\ &= b \left(\sum_{\mathbf{x}_i < 0} \mathbf{d}_i + b \sum_{\mathbf{x}_i < 0} \mathbf{d}_i \right) \\ &= b\mathbf{1}^T \mathbf{D}\mathbf{1} \end{aligned} \quad (2.16)$$

En iyi bölütün hesaplanması için Ncut'ın minimize edilmesi gerektiğinden yukarıda bahsedilmişti. Denklem (2.14), (2.15) ve (2.16)'nın sonuçlarını birleştirirsek problemimiz aşağıda verilen optimizasyon problemine indirgenmiş olur:

$$\min_{\mathbf{x}} Ncut(\mathbf{x}) = \min_{\mathbf{y}} \frac{\mathbf{y}^T (\mathbf{D} - \mathbf{W}) \mathbf{y}}{\mathbf{y}^T \mathbf{D}\mathbf{y}} \quad (2.17)$$


Burada, $\mathbf{y}(i) \in \{1, -b\}$ ve $\mathbf{y}^T \mathbf{D}\mathbf{1} = 0$ kısıtlarını sağlamak zorundadır. Denklem (2.17)'deki ifade Rayleigh bölümüdür (Rayleigh quotient) [39]. Eğer $\mathbf{y}$ gösterge vektörü reel sayılar alacak şekilde serbest bırakılırsa, (2.17)'deki denklemi (2.18)'de verilen genelleştirilmiş özvektör sistemi çözülerek minimize edilebilir.

$$(\mathbf{D} - \mathbf{W})\mathbf{y} = \lambda \mathbf{D}\mathbf{y} \quad (2.18)$$


Özvektörler elde edildikten sonra, $\mathbf{x}$ gösterge vektörünün tanımı gereği $\mathbf{y}$ vektörünün bazı kısıtları sağlaması gerekmektedir. $\mathbf{y}$ üzerindeki $\mathbf{y}^T \mathbf{D} \mathbf{1} = 0$ kısıtı özvektör sisteminin çözümüyle otomatik olarak sağlanmaktadır [38]. İkinci kısıt ise $\mathbf{y}$ vektörünün 1 veya -b gibi ayırık değerleri almasıdır. Özvektör sisteminin çözümü ile elde edilen özvektörler reel değerler aldığından, $\mathbf{y}(i)$ 'nin iki ayırık değer alması birinci kısıt gibi otomatik olarak sağlanamamaktadır. $\mathbf{y}$ vektörlerinin Ncut çözümü için ayırık hale getirilmesi gerekmektedir. Bu durum kendi başına bir sınıflandırma metodu gerektirmektedir. Bunu gerçekleştirmek için literatürde farklı yöntemler vardır. İlerleyen alt bölümlerde, literatürde yer alan bazı yöntemler avantaj ve dezavantajlarıyla ele alınmıştır.

Ayrıklaştırma yöntemlerine geçmeden önce; konunun özünü anlamak amacıyla bir örnek üzerinden gidecek olursak, Şekil 2.4'teki 130 noktadan oluşan kümeyi sınıflara ayırmak istersek, öncelikle çizge oluşturmak gerekmektedir. Çizgeyi her nokta ikilisi arasındaki kenar ağırlığı $w_{i,j} = e^{-\frac{d(i,j)}{\sigma}}$ olacak şekilde oluşturalım. Burada, $d(i,j)$ i . ve j . nokta (boğum) arasında Euclidean uzaklığını ifade etmektedir ve σ ise kenar ağırlıklarını ayarlamak amacıyla seçilen kontrol parametresidir. Noktalar arasındaki uzaklık arttıkça kenar ağırlıkları da azalacaktır. Tüm kenar ağırlıkları hesaplanıp $\mathbf{W}$ benzerlik matrisi ve $\mathbf{D}$ derece matrisi oluşturulur. Bu matrisler oluşturulduğunda noktaların hangi sıraya göre yerleştirildiğinin önemi yoktur. Ancak, kolay anlaşılması amacıyla, benzerlik matrisinin 1-80 arası satır ve sütunlarına şekildeki dairesel halka oluşturan noktalar saatin tersi yönünde sırasıyla yerleştirilmiş, 81-90 arası satır ve sütunlarına dairesel halkanın içinde kalan noktalar yerleştirilmiş, 91-110 arası satır ve sütunlarına sağ üstteki noktalar yerleştirilmiş ve 110-130 arası satır ve sütunlarına ise sağ alttaki noktalar yerleştirilmiştir. Bu adımdan sonra, denklem (2.18)'deki özvektör sistemi çözümü sonucu elde edilen özdeğer ve bunlara karşılık gelen bazı özvektörler Şekil 2.5'te verilmiştir. Laplacian matrisi, yani $\mathbf{L} = \mathbf{D} - \mathbf{W}$, artı yarı-belgili (positive semidefinite) bir matris olduğundan, özvektör sistemi sonucu elde edilen özdeğerler $\lambda_1 = 0 < \lambda_2 < \lambda_3 < \dots < \lambda_n$ şeklinde sıralanmaktadır. $\lambda_1 = 0$ özdeğere karşılık gelen özvektör girdileri Şekil 2.5'te gözüktüğü gibi sabit değerler içermektedir. Ancak, λ_2 'ye karşılık gelen özvektöre baktığımızda girdileri iki seviyede toplanmıştır. Bu tam olarak Şekil 2.4'te yer alan soldaki noktaların oluşturduğu dairesel halka ve ortasındaki nokta kümesi ile sağda yer alan nokta kümelerini ikiye ayıracak şekilde farklı seviyeler almıştır. λ_2 'den büyük diğer öz-

değerlere karşılık gelen özvektörler ise noktaları farklı bölgelerden, birden çok sınıfa ayıracak şekilde seviyeler oluşturmuştur. Ancak, bu seviyeler arasında ikinci özvektörde olduğu gibi keskin bir ayırım yoktur.



Şekil 2.4. Nokta kümesi



Şekil 2.5. Özdeğer ve bunlara karşılık gelen bazı özvektörler

2.2.1 Özyinelemeli 2-Ncut (Recursive 2-Ncut)

Nokta örneğinde olduğu gibi 2. özvektör daima iki ayrı seviye almaktadır ve bu vektör aynı zamanda Ncut maliyetini minimize eden çözümlerden bir tanesidir. Bu yöntem, 2. özvektörü kullanarak çizgeyi özyinelemeli olarak ikiye bölerek bölütler oluşturur. Bu algoritma aşağıdaki gibi özetlenebilir [38]:

1. $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi oluşturulur, kenar ağırlıkları hesaplanır ve $\mathbf{W}$ benzeşim matrisi

ile **D** derece matrisi elde edilir,

2. Denklem (2.18)'deki sistemin çözümü ile küçük özdeğerlere karşılık gelen özvektörler hesaplanır,
3. Ncut en aza indirgenecek şekilde çizgeyi ikiye bölmek için ikinci en küçük özdeğere karşılık gelen özvektör kullanılır,
4. Kesitin kararlılığı kontrol edilerek bölütlere ayrılması gerekip gerekmediğine karar verilir ve Ncut maliyetinin önceden belirlenmiş değerin altında olduğundan emin olunur,
5. Her bir bölüt özyinelemeli şekilde yukarıdaki basamaklar takip edilerek ikiye bölünür,

Bu yöntem özyinelemeli olarak çizgeyi sürekli oluşturduğundan yavaş bir yöntemdir. Ayrıca, algoritmanın 4. basamağında yer alan Ncut için minimum seviyenin belirlenmesi bölüt doğruluğu açısından zor bir durumdur.

2.2.2 k-ortalamlar (k-means)

Genelleştirilmiş özvektör sistemi sonucu elde edilen özvektörleri ayrık hale getirilmesi bir sınıflandırma problemi olduğu yukarıda değinilmişti. Bunun için klasik yöntem olan k-ortalamları literatürde sıklıkla kullanılmaktadır. k-ortalamlar kullanan bölütleme algoritması aşağıda verilmiştir [36, 38]:

1. $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi oluşturulur, kenar ağırlıkları hesaplanır ve **W** benzeşim matrisi ile **D** derece matrisi elde edilir,
2. Denklem (2.18)'deki sistemin çözümü ile küçük k tane özdeğere karşılık gelen özvektörler hesaplanır,
3. Elde edilen $\mathbf{y}_1, \dots, \mathbf{y}_k \in \mathbb{R}^n$ özvektörleri sütunlara yerleştirilerek bir $\mathbf{Y} \in \mathbb{R}^{n \times k}$ matrisi elde edilir,
4. k-ortalamlar algoritmasıyla **Y** matrisinin her bir satırı $\mathbf{S}_1, \dots, \mathbf{S}_k$ sınıflarına ayrılır,

5. Aynı sınıfa düşen girdilerle k adet bölüt elde edilir,

Bu yönteminle k sayısına karar vermek bölütleme doğruluğu için kritik önem taşımaktadır. k 'nin yüksek bir değer seçilmesi çizgeyi daha çok bölüte ayırmak anlamına gelmektedir fakat bu da gereksiz yere fazla bölüt oluşturmaya sebep olabilmektedir (over-segmentation). Ayrıca, görüntü bölütlemesinde bu yöntem görüntüde tekdüze büyük alanlar olduğunda yanlış bölütlemelere sebep olmaktadır. Diğer taraftan k 'nin düşük seçilmesi de çizgede olduğundan daha az bölüte ayırmak demektir (under-segmentation). Bölütleme problemlerinde bu iki durum da istenmemektedir. Bu durumlardan kaçınmak için kullanılan özvektör sayısının probleme uygun seçilmesi gerekmektedir. Ancak; kullanılacak özvektör sayısını belirlemek, hakkında önsel bilgimiz olmayan çizge için zor bir durumdur.

2.2.3 Çok katmanlı Ncut (Multiclass Ncut)

k-ortalamalar yöntemiyle oldukça benzer bir yöntem olmakla beraber bölüt oluşturmada daha verimli sonuçlar vermektedir. Bu yöntemle genelleştirilmiş özvektör sisteminin özvektörleri bulunduktan sonra, bu optimum çözüme en yakın ayrık çözüm bulunmaya çalışılır. Ayrıklaştırma, Tekil Değer Ayrıştırması (Singular Value Decomposition) ve Maksimum Olmayan Bastırma (Nonmaximum Suppression) kullanarak yinelemeli bir biçimde ve verimli bir şekilde hesaplanır. Bu yöntemin özet algoritması aşağıda verilmiştir, detaylı algoritma için [40]'a bakılabilir:

1. $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi oluşturulur, kenar ağırlıkları hesaplanır ve $\mathbf{W}$ benzeşim matrisi ile $\mathbf{D}$ derece matrisi elde edilir,
2. Denklem (2.18)'deki sistemin çözümü ile büyük k tane özdeğere karşılık gelen özvektörler hesaplanır,
3. Elde edilen $\mathbf{y}_1, \dots, \mathbf{y}_k \in \mathbb{R}^n$ özvektörleri sütunlara yerleştirilerek bir $\mathbf{Y} \in \mathbb{R}^{n \times k}$ matrisi elde edilir,
4. $\mathbf{Y}$ matrisinin her bir satırı Tekil Değer Ayrıştırması ve Maksimum Olmayan Bastırma kullanılarak yenilemeli bir biçimde $\mathbf{S}_1, \dots, \mathbf{S}_k$ sınıflarına ayrılır,

5. Aynı sınıfa düşen girdilerle k adet bölüt elde edilir,

Bu yöntemle de çizgenin kaç bölüte ayrılacağını, yani k değerinin, önceden bilinmesi gerekmektedir.

2.2.4 Spektral Pb + UCM

Görüntü bölütlenmesi düşünüldüğünde, özvektör sistemi sonucu elde edilen özvektörler kenar bilgisi taşımaktadır. Bu özvektörler denklem (2.19)'da verilen spektral sınır olasılığı (spectral probability of boundary-sPb) kenar bulma algoritmasıyla birleştirilerek görüntünün kenar bilgisi elde edilir [41]. Burada, denklem (2.18)'de elde edilen özvektörlerin ($\mathbf{y}_k$) yönlü türevleri alınıp özdeğerler (λ_k) ile normalleştirildikten sonra toplanarak kenarlar elde edilmektedir. Denklem (2.19)'da gösterildiği gibi, θ ile gösterilen farklı yönlerden alınan türevlerin en büyük değerleri alındığında kenar bulma sonuçları iyileşmektedir. Son işlem olarak, bu kenar sonuçları kullanılarak Ultrametric Contour Maps (UCM) yardımıyla bölütler oluşturulur [42]. Hiyerarşik sınıflandırma çerçevesinde UCM, iç içe bölütlemelerin bir ailesi ile ilişkili olan yumuşak sınır görüntüsüdür. UCM algoritması, bölge sınırları boyunca yerel kenar kanıtlarını birleştirerek ve bu bilgiyi bölge içi niteliklerle tamamlayarak kenar bilgisi çıkarma için ultrametrik tanımlanmaktadır. UCM'nin matematiksel modeli ve daha fazla bilgi için [42]'ye bakılabilir.

$$sPb = \max_{\theta} \sum_{i=1}^k \frac{1}{\sqrt{\lambda_i}} \nabla_{\theta} \mathbf{y}_i \quad (2.19)$$

Bu yöntemin algoritması aşağıda verilmiştir:

1. $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi oluşturulur, kenar ağırlıkları hesaplanır ve $\mathbf{W}$ benzeşim matrisi ile $\mathbf{D}$ derece matrisi elde edilir,
2. Denklem (2.18)'deki sistemin çözümü ile en büyük k tane özdeğere karşılık gelen özvektörler hesaplanır,
3. Denklem (2.19)'da verilen sPb, özdeğerler ve bunlara karşılık gelen özvektörler birleştirilerek hesaplanır,

4. sPb sonucu belirlenen eşik değeriyle UCM algoritması geçirilir ve bölütler oluşturulur,

Bu algoritmada k yeterince büyük seçilebilir, çünkü burada bölüt sayısı bu değerden bağımsız olarak belirlenmektedir. Öncelikle kenar bilgisi çıkartıldığından, yukarıdaki diğer yöntemlerin aksine, görüntüdeki tekdüze büyük alanları bölütlemeye başarılı sonuçlar vermektedir. sPb ile elde edilen kenar bilgisiyle ve UCM algoritmasının eşik değeri değiştirilerek istenilen sayıda ve doğrulukta bölütler elde edilmektedir.

2.3 Laplacian Özharitaları

Laplacian Özharitaları (Laplacian Eigenmaps-LE) doğrusal olmayan bir boyut indirgeme yöntemidir [43]. $\mathbf{x}_1, \dots, \mathbf{x}_k \in \mathbb{R}^n$ gibi bir veri kümesi verildiğinde bu kümeyi $\mathbf{y}_1, \dots, \mathbf{y}_k \in \mathbb{R}^m (m \ll n)$ gibi daha düşük boyutlu bir uzayda göstermek mümkündür. LE, boyut indirgemesi yaparken yerel bilgileri en iyi şekilde korumak için denklem (2.20)'deki ifadeyi minimize etmeye çalışır.

$$\sum_{i,j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 w(i,j) = \text{tr}(\mathbf{Y}^T \mathbf{L} \mathbf{Y}) \quad (2.20)$$

ve $\mathbf{Y}^T \mathbf{L} \mathbf{Y} = \mathbf{I}$

Denklem (2.20)'de $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_k]$ iken, $\mathbf{L}$ ise $\mathbf{x}_i$ verisinin Laplacian matrisidir. Burada, $\mathbf{x}_i$ ve $\mathbf{x}_j$ birbirine yakınsa, $\mathbf{y}_i$ ile $\mathbf{y}_j$ birbirinden uzaklaştığında ağır bir ceza verilmiş olunur. Dolayısıyla bu minimizasyon düşük boyutta benzer yapıyı sağlayabilir. Denklemdeki kısıt, ölçeklendirme faktörlerini ortadan kaldıracak ve boyutların $m - 1$ 'den küçük bir alt uzayına düşmesini önleyecektir. Denklem (2.20)'deki ifadenin minimumu genelleştirilmiş özvektör sisteminin çözümü sonucu elde edilen m tane aşikar olmayan ($\lambda \neq 0$) özdeğere karşılık gelen özvektörlerin oluşturduğu matrisinin sütunlarıdır. LE algoritmasını kısaca özetlersek:

1. $\mathbf{x}_1, \dots, \mathbf{x}_k \in \mathbb{R}^n$ verileriyle $\mathbf{G} = (\mathbf{V}, \mathbf{E})$ çizgesi oluşturulur, kenar ağırlıkları hesaplanır ve $\mathbf{W}$ benzeşim matrisi ile $\mathbf{D}$ derece matrisi elde edilir,

2. Denklem (2.18)'deki sistemin çözümü ile küçük $m+1$ tane özdeğere karşılık gelen özvektörler hesaplanır,
3. Elde edilen sıralı özdeğerlere, $\lambda_0 \leq \dots \leq \lambda_m$, karşılık gelen özvektörler $\mathbf{f}_0, \dots, \mathbf{f}_k$ olsun, sonuç olarak $\mathbf{y}_1^T, \dots, \mathbf{y}_k^T$ boyutu indirgenmiş veri kümesi $\mathbf{F} = [\mathbf{f}_1, \dots, \mathbf{f}_k]$ matrisinin satırları olarak tanımlanır,

LE algoritmasının çözümü, Ncut algoritmanın reel sayılarda değer alacak şekilde serbest bırakılan çözümü ile aynı olduğu gözükmemektedir. LE algoritması, yakın noktaların yerel yapısını koruyarak yüksek boyutlu uzaydaki verileri düşük boyuta indirgeyen bir yaklaşımdır. Ncut algoritması ise görüntüleri farklı bölütlere ayıran bir optimizasyon yaklaşımıdır. Dolayısıyla, LE yerel yaklaşımı yüksek boyutlu verilerin doğal kümelenmesi olarak düşünülebilir.

2.4 Schroedinger Özharitaları

Schroedinger Özharitaları (Schroedinger Eigenmaps-SE) algoritması, yüksek boyutlu verileri düşük boyutlara indirgeyen doğrusal olmayan bir boyut indirgeme ve/veya kümeleme amacıyla kullanılan çizge tabanlı bir yöntemdir [31, 44]. Temelde, LE algoritmasıyla benzerlik gösteren SE, çizgeye bir $\mathbf{P}$ potansiyel matrisi ekleyerek LE algoritmasını genelleştirir. Hiperspektral görüntü analizi için kullanılan iki tür potansiyel matrisi bulunmaktadır: bariyer ve küme potansiyeli. Bariyer potansiyeli, $\mathbf{P}$ 'nin negatif olmayan bir köşegen matrisi olarak tanımlanmasıyla oluşturulmaktadır. Bariyer potansiyeli, $\mathbf{x}_1, \dots, \mathbf{x}_k$ noktaları için $\mathbf{y}_1, \dots, \mathbf{y}_k$ 'deki ilgili noktaları orijine çeker. Küme potansiyeli ise, $\mathbf{P}$ 'nin denklem (2.21)'de verilen köşegen olmayan $\mathbf{P}^{i,j}$ matrislerin toplamı olarak tanımlanarak oluşturulur. $\mathbf{x}_1, \dots, \mathbf{x}_k$ noktaları için tanımlanan küme potansiyeli $\mathbf{y}_1, \dots, \mathbf{y}_k$ 'deki ilgili noktaları birbirine doğru çeker, başka bir deyişle aynı kümeye toplar.

$$\mathbf{P}_{k,l}^{(i,j)} = \begin{cases} 1, & \text{eğer } (k, l) \in (i, i), (j, j) \\ -1, & \text{eğer } (k, l) \in (i, j), (j, i) \\ 0, & \text{aksi takdirde.} \end{cases} \quad (2.21)$$

SE algoritması denklem (2.18)'deki genelleştirilmiş özvektör sistemi yerine denklem

(2.22)'deki sistemin çözmeye çalışır. Laplacian matrisinin ve potansiyel matrisinin bölütlemeye katkıları α parametresiyle ayarlanmaktadır. α 'nın değeri arttırıldıkça bölütleme sonuçlarında potansiyel matrisinin etkisi de artmaktadır.

$$(\mathbf{D} - \mathbf{W} + \alpha \mathbf{P})\mathbf{y} = \lambda \mathbf{D}\mathbf{y} \quad (2.22)$$

Burada, özvektör sisteminin potansiyel matrisi eklenmiş halinin çözümü olan özvektörler elde edildikten sonra Ncut algoritmasının çözümü için anlatılan 4 yöntemden herhangi biri kullanılarak görüntüler için bölütler oluşturulabilir.

2.5 Benzeşim Matrisi

Şimdiye kadar bahsettiğimiz spektral bölütleme yöntemlerinde de gözüktüğü üzere algoritmaların temel taşı benzeşim matrisi, $\mathbf{W}$, oluşturmaktadır. Spektral bölütleme önemli olan faktör benzeşim matrisi $\mathbf{W}$ 'nin probleme uygun olarak tasarlanmasıdır. Daha önce bahsettiğimiz gibi, çizge oluştururken aynı sınıfta yer alan boğumlar arasındaki ilişkiyi arttırmak ve farklı sınıflarda olan boğumlar arasındaki ilişkiyi azaltmak amaçlanmaktadır. Çizgedeki tüm boğumların ilişkilerini içeren benzeşim matrisi olduğundan, probleme uygun seçilmesi kritik önem taşımaktadır.

Bu kısımda, KYM (kırmızı-yeşil-mavi) ve HSG görüntülerin bölütlenmesi ve sınıflandırılması amacıyla literatürde önerilen benzeşim matrisleri ele alınmıştır. Görüntülerin spektral bölütlenmesinde her boğum pikselleri veya süper pikselleri ifade etmektedir. Pikseller arasındaki uzamsal, renk, parlaklık gibi benzerlikler kullanılarak çizgedeki kenar ağırlıkları hesaplanıp benzeşim matrisi $\mathbf{W}$ oluşturulur. Aşağıda, görüntü bölütlemesi için önerilen farklı yöntemler verilmiştir.

2.5.1 Shi-Malik (SM) Benzeşim Matrisi

Shi-Malik yöntemi [38], çizge yapısını ve kenar ağırlık tanımlamasını hem spektral hem de uzamsal bilgileri içeren bir biçimde nasıl ele alacağını açıklamaktadır. Görüntülerdeki tüm pikseller arasındaki kenar ağırlıklarını hesaplamak karmaşık ve zordur. Yakın piksellerin aynı sınıftan olma ihtimalleri daha yüksek olduğundan, SM yöntemi çizge oluştururken sadece uzamsal olarak birbirine yakın olan piksellerin kenar ağırlıklarını

hesaplarken uzak olanların kenar ağırlıklarına sıfır atamaktadır. Böylece ağır işlem yükünden kurtulmuş olunur. Ayrıca, yakın piksellerin arasındaki uzamsal uzaklık ile ters orantılı olarak çizgedeki kenar ağırlığı azalacaktır. Bu yöntemin görüntüler için tanımladığı $\mathbf{W}$ benzeşim matrisi denklem (2.23)'te verilmiştir.

$$\mathbf{W}_{i,j} = \begin{cases} e^{-\frac{\|\mathbf{x}_i^s - \mathbf{x}_j^s\|^2}{\beta_{spektral}^2}} e^{-\frac{\|\mathbf{x}_i^u - \mathbf{x}_j^u\|^2}{\gamma_{uzamsal}^2}}, & \text{eğer } \|\mathbf{x}_i^u - \mathbf{x}_j^u\| < \epsilon \\ 0, & \text{aksi takdirde.} \end{cases} \quad (2.23)$$

Burada, $\mathbf{x}_j^s$ pikselin spektral (renk, parlaklık vb.) bilgisini göstermekte ve $\mathbf{x}_j^u$ ise pikselin uzamsal konumunu göstermektedir. $\beta_{spektral}$ ve $\gamma_{uzamsal}$ piksellerin spektral ve uzamsal bilgilerle elde edilen kenar ağırlıklarının uzaklığa bağlı olarak değişimini etkileyen kontrol parametreleridir. Denklem (2.23)'te de görüldüğü üzere sadece uzamsal olarak ϵ -komşuluğundaki pikseller için kenar ağırlıkları belirlenmiş ve diğer kenarlara sıfır atanmıştır.

2.5.2 Gilles-Bowles (GB) Benzeşim Matrisi

Gilles-Bowles (GB) yöntemi [26], SM ile benzerlik göstermektedir. Uzamsal benzerlik için SM yönteminde olduğu gibi Euclidean uzaklığı kullanılırken, spektral benzerlik için spektral açı haritalayıcı (spektral angle mapper-SAM) kullanılmıştır. Bu yöntemin, özellikle çok sayıda bant bilgisi içeren HSG'ler için etkili bir yöntem olduğu gösterilmiştir [26]. GB yöntemiyle oluşturulan $\mathbf{W}$ benzeşim matrisi denklem (2.24)'te verilmiştir.

$$\mathbf{W}_{i,j} = \begin{cases} e^{-\arccos\left(\frac{\langle \mathbf{x}_i^s, \mathbf{x}_j^s \rangle}{\|\mathbf{x}_i^s\| \cdot \|\mathbf{x}_j^s\|}\right)} e^{-\frac{\|\mathbf{x}_i^u - \mathbf{x}_j^u\|^2}{\gamma_{uzamsal}^2}}, & \text{eğer } \|\mathbf{x}_i^u - \mathbf{x}_j^u\| < \epsilon \\ 0, & \text{aksi takdirde.} \end{cases} \quad (2.24)$$

Burada, $\langle \mathbf{x}_i^s, \mathbf{x}_j^s \rangle$ iki pikselin spektral bilgileri arasındaki iç çarpımı ifade etmektedir ve $\|\mathbf{x}_i^s\|$ ise i . pikselin spektral bilgilerle oluşturan normudur. SM'de olduğu gibi, uzamsal olarak ϵ -komşuluğundaki pikseller için kenar ağırlıkları belirlenmiş ve diğer kenarlara sıfır atanmıştır.

2.5.3 Hou-Zhang-Ye-Zheng (HZYZ) Benzeşim Matrisi

Hou-Zhang-Ye-Zheng (HZYZ) yöntemi [45], SM ve GM yöntemlerine benzemekle birlikte farklı bir yaklaşım göstermektedir. HZYZ spektral ve uzamsal bilgileri kaynaştıran LE algoritma tabanlı bir yöntemdir. SM ve GM yöntemleri spektral ve uzamsal bilgilerin benzerliğini direkt kullanarak kenar ağırlıklarını belirlerken, HYZY yöntemi ise spektral ve uzamsal bilgilerin benzerliğini kullanarak ikili (0-1) kenar ağırlıklarını belirler. Bu yöntem, denklem (2.25)'te verilen ifadeye göre iki piksel arasındaki uzaklık, spektral ve uzamsal bilgiler kullanılarak hesaplanır. Uzaklık hesaplamada SM ve GB yöntemlerine benzerlik göstermektedir.

$$d(\mathbf{x}_i, \mathbf{x}_j) = (1 - e^{-\frac{\|\mathbf{x}_i^s - \mathbf{x}_j^s\|^2}{2\beta_{spektral}^2}})(1 - e^{-\frac{\|\mathbf{x}_i^u - \mathbf{x}_j^u\|^2}{2\gamma_{uzamsal}^2}}) \quad (2.25)$$

Bu yöntemle kenar ağırlıkları belirlenirken d uzaklığını direkt kullanmak yerine, bu uzaklığın belirlenmiş bir değerden küçük olan $\mathbf{x}_i$ ve $\mathbf{x}_j$ komşu piksellerin kenar ağırlığına denklem (2.26) gösterildiği gibi 1 değeri atanmaktadır. Böylece, benzerlik matrisinin girdileri yalnızca 0 ve 1 değerlerinden oluşmaktadır. Bu yöntem de HSG'lerin kümelenmesi için kullanılmaktadır.

$$W_{i,j} = \begin{cases} 1, & \text{eğer } d(\mathbf{x}_i, \mathbf{x}_j) < \epsilon \\ 0, & \text{aksi takdirde.} \end{cases} \quad (2.26)$$

2.5.4 Nokta tabanlı karşılıklı bilgi (Pointwise mutual information-PMI) Benzeşim Matrisi

Karşılıklı bilgi (mutual information), iki rastgele değişken arasındaki bilgi örtüşmesinin bir ölçümüdür. Nokta tabanlı karşılıklı bilgi (Pointwise mutual information-PMI) ise iki örnek arasındaki karşılıklı bağımlılığı veya rastgele değişkenlerin gerçekleştirmelerini ölçer. Başka bir deyişle, PMI iki olay için bir korelasyon ölçüsüyken, karşılıklı bilgi olası tüm olaylar için PMI ölçümüdür. PMI kelime çiftlerinin yan yana bulunma olasılığını bulmak için hesaplamalı dil biliminde kullanılan bir yöntemdir [46, 47]. Aynı zamanda görüntü

sınıflandırmasını arttırmak için de kullanılmaktadır [48]. Son zamanlarda, spektral bölütlemenin benzeşim matrisi PMI ile oluşturularak KYM görüntülerde kenar bulma ve bölütleme amacıyla önerilen oldukça başarılı bir yöntem haline gelmiştir [49]. PMI yöntemi, görüntüde aynı nesneye ait piksellerin, farklı nesnelere ait piksellerden daha yüksek istatistiksel bağımlılık sergilemesi prensibini temel alır. PMI benzeşim matrisini olasılık yoğunluk kestirimine göre hesaplar. $\mathbf{x}_i$ ve $\mathbf{x}_j$ görüntüdeki iki piksele ait özneliği (renk, parlaklık, spektral bilgiler vb.) olsun ve bu iki özneliğin belli bir d Euclidean uzaklığındaki bileşik olasılığı $p(\mathbf{x}_i, \mathbf{x}_j; d)$ olsun. Bu bileşik olasılığı farklı Euclidean uzaklıklarında hesaplayarak denklem (2.27)'deki $P(\mathbf{x}_i, \mathbf{x}_j)$ olasılık yoğunluk fonksiyonu tanımlanabilir. Bu olasılık yoğunluk fonksiyonunu hesaplamak için görüntünün içinden farklı d uzaklıklarda çok sayıda parça rastgele olarak örneklenir ve birlikte görülme olasılıkları hesaplanır.

$$P(\mathbf{x}_i, \mathbf{x}_j) = \frac{1}{Z} \sum_{d=d_0}^{\infty} w(d) p(\mathbf{x}_i, \mathbf{x}_j; d) \quad (2.27)$$

Denklem (2.27)'deki $w(d)$ iki piksel arasındaki uzaklık arttıkça azalan Gauss tabanlı bir ağırlıktır ve Z ise normalizasyon sabitidir. Bu olasılık yoğunluk fonksiyonunun marjinaleri bulunarak $P(\mathbf{x}_i)$ ve $P(\mathbf{x}_j)$ marjinal olasılıkları hesaplanabilir.

Pikseller arasındaki benzerlik ölçüsü olarak bu olasılık yoğunluk fonksiyonu kullanılması mantıklıdır. Ancak, bazı nesnelerin zıt renklerden oluşması, örneğin siyah ve beyaz renklerden oluşan bir nesne, bu nesnelerin pikselleri arasındaki bileşik olasılığın düşük çıkmasına neden olmaktadır. Böyle durumu önlemek amacıyla, $P(\mathbf{x}_i, \mathbf{x}_j)$ dağılımı yerine denklem (2.28)'deki PMI kullanmak pikseller arasındaki benzerlik dağılımını iyileştirmektedir [49].

$$PMI_{\rho}(\mathbf{x}_i, \mathbf{x}_j) = \log \frac{P(\mathbf{x}_i, \mathbf{x}_j)^{\rho}}{P(\mathbf{x}_i)P(\mathbf{x}_j)} \quad (2.28)$$

Yukardaki denkleme göre, $\rho = 1$ olduğunda PMI_{ρ} değeri tam olarak $\mathbf{x}_i$ ve $\mathbf{x}_j$ arasındaki karşılıklı bilgidir. $\rho = 1$ durumunda logaritma içindeki oran $\frac{P(\mathbf{x}_i, \mathbf{x}_j)}{P(\mathbf{x}_i)}$ şeklinde yazılabilir. Bu oran, görüntüdeki $\mathbf{x}_i$ 'nin gözlemlenme olasılığına kıyasla $\mathbf{x}_j$ gözlemi verildiğinde $\mathbf{x}_i$

gözlemlenme ihtimalini vermektedir. $\rho = 2$ olduğunda ise logaritmanın içindeki oran $\frac{P(\mathbf{x}_i|\mathbf{x}_j)}{P(\mathbf{x}_j|\mathbf{x}_i)}$ olmaktadır, yani $\mathbf{x}_i$ 'nin gözlemlenmesi $\mathbf{x}_j$ 'nin yakında olmasını gerektirmekte ve $\mathbf{x}_j$ 'nin gözlemlenmesi $\mathbf{x}_i$ 'nin yakında olmasını gerektirmektedir. ρ 'nun hangi değeri için bölütleme sonuçlarının iyi olacağı bilinmediğinden, veri kümesi üzerinde performansı artırmak amacıyla serbest bir değişken olarak bırakılabilir.

Spektral bölütleme yöntemlerinin kullandığı $\mathbf{W}$ benzeşim matrisi için direkt PMI_ρ 'yu kullanmak yerine üstel bir fonksiyona yerleştirmenin daha iyi sonuçlar verdiği gözlemlenmiştir [49]. Bu sebeple, $\mathbf{W}$ benzeşim matrisi denklem (2.29)'da verildiği gibi PMI_ρ 'nun üstel fonksiyonu olacak şekilde hesaplanır.

$$\mathbf{W}_{i,j} = e^{PMI_\rho(\mathbf{x}_i, \mathbf{x}_j)} \quad (2.29)$$

3. HİPERSPEKTRAL GÖRÜNTÜLERİN BÖLÜTLENMESİ

Son zamanlarda, yüksek spektral çözünürlükteki UA teknolojileri önemli gelişmeler göstermektedir. Görüntüleme alanında önemli bir yere sahip hiperspektral görüntüleyiciler UA teknolojilerin başında gelmektedir. Yüzlerce spektral banttıan oluřan HSG'ler, piksel başına 1-3 metreye kadar uzamsal çözünürlüğe de sahip olabilirler. Bu özelliklerinden dolayı HSG'ler yeryüzü sınıflandırmasında başarılı sonuçlar vermektedir. Aynı zamanda, çok sayıda spektral bant içerdiklerinden, benzer özellikler taşıyan ancak farklı türlele ait nesnelerin ayırt edilmesine olanak sağlamaktadırlar. Bunun yanı sıra; bölütleme, sınıflandırma ve hedef tespiti uygulamalarında performansı iyileştirmek amacıyla HSG'lerin sağladığı bilgileri tamamlayıcı nitelikte olan farklı veri kaynaklarına başvurmak gerekebilir. Bu amaçla, literatürde farklı kaynaklardan toplanan verilerin kaynaştırılması üzerine çalışmalar mevcuttur [33, 34, 35].

HSG'ler uzamsal ve spektral gibi önemli bilgiler içermekteyken, yükseklik bilgisini içermemektedir. Yükseklik bilgisi eksikliğinden dolayı HSG'lerin bölütlenmesi iki alanda başarısız olmaktadır. İlk olarak, benzer spektral bilgilere sahip nesneleri ayırt etmek zorlaşmaktadır. Ancak, benzer spektral özellikteki nesneler farklı yüksekliklere sahiplerse, örneğin çatı ve asfalt gibi, bunları ayırt etmek yükseklik bilgisi kullanarak mümkün hale gelmektedir. Başarısız olduğu diğer bir nokta ise gölgelik alanları nesnelerden yeterli doğrulukta ayırt edememesidir. Bu durum, özellikle hedef bulma uygulamalarında hayati önem taşımaktadır. HSG'lerin bu temel eksikliklerini gidermek amacıyla yükseklik bilgisini algılayan veya 3 boyutlu görüntü oluşturan başka UA teknolojilerinden faydalanmak son derece önemlidir. Yükseklik bilgisini, son zamanlarda sıklıkla kullanılan LiDAR veya sentetik açıklık radarı (SAR) gibi UA teknolojileriyle elde etmek mümkündür. Özellikle, LiDAR'dan elde edilen yükseklik bilgisi, HSG'leri tamamlayıcı niteliktedir. HSG'lere ek olarak LiDAR verileri de kullanıldığında yukarıda bahsedilen problemlerden kurtulmuş olunur. Dolayısıyla, HSG verileriyle LiDAR verileri bir araya getirildiğinde yeryüzündeki nesnelerin daha kapsamlı bir şekilde yorumlanması sağlanabilir.

Bu tez çalışmasında, HSG'lerden elde edilen uzamsal ve spektral bilgilerle LiDAR'dan elde edilen yükseklik bilgisi kaynaştırılarak, HSG'lerin denetlemesiz bölütlenmesi gerçekleştirilmiştir. Giriş bölümünde de bahsedildiği gibi, denetlemesiz bölütleme herhangi

bir önsel bilgiye gereksinim duymadığından birçok uygulama alanında kullanılmaktadır. HSG'lerin denetlemesiz bölütlenmesi için ikinci bölümde anlatılan çizge tabanlı spektral bölütleme yöntemleri kullanılmıştır. Spektral bölütleme yöntemlerinde önemli bir nokta olan benzeşim matrisinin (W) probleme uygun seçilmesi gerektiğinden ikinci bölümde bahsedilmiştir. Bu kısımda, HSG'lerin uzamsal-spektral bilgileri ile LiDAR'ın yükseklik bilgisi kaynaştırılarak spektral bölütleme için benzeşim matrisleri önerilmiştir. Oluşturulan bu benzeşim matrisleri kullanılarak spektral bölütleme yöntemleriyle HSG'lerin denetlemesiz bölütlenmesi gerçekleştirilmiştir. Bu tezde, HSG ve LiDAR verilerini kaynaştırmak için 3 yöntem önerilmiştir:

1. **SM Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (SMTNcut):** SM yönteminde olduğu gibi, Euclidean uzaklıkları kullanılarak benzeşim matrisi oluşturulmuştur. SM benzeşim matrisi ek olarak LiDAR verilerinden elde edilen yükseklik bilgileri de kullanılarak HSG'lerin yüksek doğrulukta bölütlenmesi için yeni bir benzeşim matrisi önerilmiştir. HSG ve LiDAR verileriyle oluşturulan bu benzeşim matrisi kullanılarak, ikinci bölümde anlatılan çok katmanlı Ncut ile bölütleme yapılmıştır [50, 51].
2. **SE Tabanlı HSG'lerin Denetlemesiz Bölütlenmesi (SET):** SE algoritmasının kullandığı LiDAR'dan elde edilen yükseklik bilgisi ve uzamsal bilgiler ile yeni bir küme matrisi önerilmiştir. HSG'lerden elde edilen spektral bilgilerle de benzeşim matrisi oluşturulmuş ve SE algoritması spektral Pb + UCM yöntemiyle çözümlenerek bölütleme sağlanmıştır [52].
3. **PMI Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (PMITNcut):** PMI benzeşim matrisi ile uzamsal-spektral ve yükseklik bilgileri birleştirilerek HSG'ler için yeni bir benzeşim matrisi önerilmiş ve ikinci bölümde anlatılan Ncut yönteminin başarılı bir çözümü olan spektral Pb + UCM yöntemiyle bölütleme sağlanmıştır [53].

Bu bölümde, yukarıda bahsedilen 3 yöntem ayrıntılı bir şekilde tanıtılmış ve algoritmaları verilmiştir.

3.1 SM Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (SMTNcut)

Görüntülerden çizge oluşturulmak istendiğinde, boğumlar ($\mathbf{V}$) pikselleri veya süper pikselleri ifade etmektedir. Pikseller arasındaki kenar ağırlıkları (w) ise görüntülere ait uzamsal benzerlik, renk benzerliği, parlaklık benzerliği gibi özellikler kullanılarak hesaplanmaktadır. HSG'lerde ise uzamsal bilgilerin yanı sıra yüzlerce banttıan oluşan spektral bilgiler yer almaktadır. HSG'lerden çizge oluşturmak için bu bilgiler kullanılmaktadır. Bölütleme sonuçlarını iyileştirmek amacıyla LiDAR verileri de göz önüne alınacağından çizgedeki kenar ağırlıkları hesaplanırken yükseklik bilgileri uygun bir şekilde uzamsal ve spektral bilgilerle birleştirilmelidir. Bu tez kapsamında önerdiğimiz ilk yöntemde, Ncut spektral bölütleme algoritması kullanılarak LiDAR'dan ve HSG'lerden elde edilen bilgiler birleştirilerek görüntülerin bölütleri elde edilmektedir. Öncelikle, bir spektral bölütleme yöntemi olan Ncut algoritması için benzeşim matrisinin oluşturulması gerekmektedir. Farklı kaynaklardan elde ettiğimiz uzamsal-spektral ve yükseklik bilgilerinin kendi içlerinde Euclidean uzaklığı kullanılarak, pikseller arasındaki benzerlikler hesaplanmakta ve aşağıda verilen denklemdeki gibi kenar ağırlıkları belirlenmektedir.

$$\mathbf{W}_{i,j} = e^{-\frac{d_{spektral}(i,j)}{\beta_{spektral}^2}} e^{-\frac{d_{lidar}(i,j)}{\delta_{lidar}^2}} \begin{cases} e^{-\frac{d_{uzamsal}(i,j)}{\gamma_{uzamsal}^2}}, & \text{eğer } d_{uzamsal}(i,j) \leq r \\ 0, & \text{aksi takdirde.} \end{cases} \quad (3.1)$$

Burada, $d_{spektral}(i,j)$ i . ve j . piksellerin tüm bantlardaki spektral bilgilerinin arasındaki Euclidean uzaklığını ifade eder ve (3.2)'deki gibi hesaplanır. Denklemdeki $\mathbf{x}_i^s$ ve $\mathbf{x}_j^s$, iki piksele ait farklı dalga boylarındaki spektral bilgiyi içeren vektörlerdir. Bu iki pikselin spektral bilgileri arasındaki fark arttıkça Euclidean uzaklığı da artacaktır. Bunlar arasındaki kenar ağırlığı ise Euclidean uzaklığının bir üstel fonksiyonu olarak tanımlandığından, uzaklık arttıkça kenar ağırlığı azalacaktır. Böylece, spektral bilgiler ile yakın olan pikseller arasındaki bağı kuvvetlendirmiş olurken, uzaktakiler arasındaki bağı da zayıflatmış olmaktadır.

$$d_{spektral}(i,j) = \|\mathbf{x}_i^s - \mathbf{x}_j^s\|_2^2 \quad (3.2)$$

Denklem (3.1)'de yer alan $d_{lidar}(i, j)$ piksellerin yükseklik bilgilerinin arasındaki Euclidean uzaklığıdır ve (3.3)'te gösterildiği gibi spektral bilgilere benzer şekilde hesaplanır. $\mathbf{x}_i^y$ ve $\mathbf{x}_j^y$ iki piksele ait yükseklik bilgisini içeren vektörlerdir. Spektral bilgiler kullanılarak oluşturulan kenar ağırlıkları, $d_{lidar}(i, j)$ uzaklığının üstel fonksiyonuyla çarpıldığında yükseklikleri yakın olan piksellerin arasındaki bağı bir derece daha güçlendirirken, yükseklikleri farklı olanlar arasındaki bağı ise iyice zayıflatmış olmaktadır.

$$d_{lidar}(i, j) = \|\mathbf{x}_i^y - \mathbf{x}_j^y\|_2^2 \quad (3.3)$$

Görüntülerden elde edilen diğer bir bilgi ise uzamsal bilgidir. Uzamsal bilgi görüntüdeki piksellerin birbirine göre konumlarını ifade etmektedir. Komşu piksellerin aynı nesne üzerinde olma olasılığı fazladır ve aralarındaki mesafe artıkcça bu ihtimal de ters orantılı olarak azalmaktadır. Bundan ötürü, kenar ağırlıkları hesaplanırken uzamsal uzaklıklarının da kullanılması oldukça önemlidir. Denklem (3.4)'te pikseller arasındaki Euclidean uzaklığının $\mathbf{x}_i^u$ ve $\mathbf{x}_j^u$ uzamsal bilgiler kullanılarak hesaplanması verilmiştir. Spektral ve yükseklik bilgilerine benzer olarak, piksellerin konumları arasındaki fark artıkcça kenar bilgileri azalacaktır. Böylece yakın olan piksellerin diğer özellikleri de benzerse aynı bölütte yer alması sağlanmaktadır.

Görüntülerde her piksel ikilileri arasındaki kenar ağırlıklarını hesaplamak çok işlem gerektiren bir yöntemdir. Pikseller uzaklaştıkcça kenar ağırlıkları sıfıra yakınsayacağından, belli bir uzamsal uzaklıktan sonraki piksel ikilisi arasındaki kenar ağırlıklarına sıfır atamak ağır işlem yükünden kurtulmaya ve benzeşim matrisini fazla yer kaplamadan kaydetmeye yardımcı olacaktır. Bu amaçla, denklem (3.1)'de verilen benzeşim matrisinin girdileri, pikseller arasındaki uzamsal Euclidean uzaklığı ($d_{uzamsal}$) önceden belirlenen r değerinden küçük pikseller için hesaplanmakta ve bu değerden büyük olanlara direkt sıfır atanmaktadır. r artıkcça daha çok piksel arasındaki kenar hesaplandığından bölütleme sonuçları da iyileşmektedir, ancak bu artış birlikteliğinde işlem yükünü arttırmaktadır. Bu değer deneysel olarak bölütleme doğruluğunu arttıracak şekilde ayarlanmalıdır. Benzeşim matrisi, ($\mathbf{W}$), tüm piksel ikilisi arasındaki ilişkiyi içermektedir. Denklem (3.1)'de görüldüğü üzere, benzeşim matrisi maksimum değerini aynı pikseller arasındaki kenar ağırlığını içeren ana köşegeninde almaktadır, yani $\mathbf{W}_{i,i} = 1$ 'dir. Bu ana köşegenin

r komşuluğunda pikseller arasındaki benzerlik azaldıkça benzeşim matrisini oluşturan kenar ağırlıkları da sıfıra yakınsamaktadır. r komşuluğu dışındaki tüm girdiler ise sıfırdır. Ayrıca, benzeşim matrisi simetrik olduğu için, $\mathbf{W}_{i,j} = \mathbf{W}_{j,i}$, sadece yarısını oluşturacak şekilde işlem yapmak karmaşıklığı önleyecek ve oluşturma zamanını kısaltacaktır.


$$d_{uzamsal}(i, j) = \|\mathbf{x}_i^u - \mathbf{x}_j^u\|_2^2 \quad (3.4)$$

Denklem (3.1)'de verilen $\beta_{spektral}$, $\gamma_{uzamsal}$ ve δ_{lidar} değişkenleri sırasıyla spektral, uzamsal ve yükseklik bilgilerinin kenar ağırlıklarındaki katkılarını ayarlayan kontrol parametreleridir. Uzamsal, spektral ve yükseklik bilgileri birbirinden farklı ölçülerde olduğundan $\beta_{spektral}$, $\gamma_{uzamsal}$ ve δ_{lidar} parametrelerin bölütleme doğruluğu için uygun seçilmesi gerekmektedir. Bu parametrelerinin arttırılması pikseller arasındaki benzerlik geçişlerini yumuşatmaktadır, azaltılması ise benzerliklerin pikselden piksele hızlı değişmesine sebep olmaktadır. Dolayısıyla $\beta_{spektral}$, $\gamma_{uzamsal}$ ve δ_{lidar} parametrelerinin bölütleme doğruluğu için HSG ve LiDAR verilerine göre uygun seçilmesi gerekmektedir.

Şekil 3.1'de HSG'den alınan uzamsal-spektral bilgilerle LiDAR'dan elde edilen yükseklik bilgisinin birleştirilerek Ncut algoritması tabanlı yöntemin akış şeması verilmiştir. Yukarıda bahsettiğimiz gibi Euclidean uzaklıkları kullanılarak tüm pikseller arasındaki karşılıklı kenar ağırlıklarını içeren benzeşim matrisi oluşturulduktan sonra genelleştirilmiş özvektör sisteminin k tane küçük özdeğer ve bunlara karşılık gelen özvektörleri bulmak için çözümü yapılır. Burada elde edilen özvektörlerin girdileri sürekli reel sayılardan oluşmaktadır. Bu özvektörlerden bölütler elde edilmesi için ayrıklaştırılması gerekmektedir. Önerdiğimiz bu yöntemde, 2. bölümde bahsedilen çok katmanlı Ncut algoritması kullanılarak özvektörler ayrıklaştırılmıştır. Elde edilen ayrık özvektörler ($\mathbf{y}'$) birleştirilerek görüntünün bölütleri oluşturulmuştur.

3.2 SE Tabanlı HSG'lerin Denetlemesiz Bölütlenmesi (SET)

Bu yöntem, Ncut spektral bölütlemeyi bir potansiyel matrisi ekleyerek genelleştiren SE algoritma tabanlı bir yöntemdir. SE algoritması denklem (2.22)'de verildiği gibi benzeşim matrisini ($\mathbf{W}$) ve potansiyel matrisini ($\mathbf{P}$ 'yi) girdi olarak almaktadır. HSG'lerin bu algoritmayla bölütlenmesi için çizge oluşturulurken, bu matrislerin veri kümesinden elde edilen



Şekil 3.1. SMTNcut spektral bölütleme yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi

uzamsal, spektral ve yükseklik bilgileriyle uygun bir biçimde oluşturulması gerekir. Benzeşim matrisi oluşturulurken sadece HSG'lere ait spektral bilgiler arasındaki Euclidean uzaklıklar kullanılmıştır. Bu yöntem için belirlenen W aşağıdaki gibi tanımlanmaktadır.

Birinci yöntemde de bahsedildiği gibi, denklem (3.5)'te yer alan $\mathbf{x}_i^s$, bir pikselde yer alan tüm spektral bantları ifade etmektedir. ϵ komşuluğundaki piksellerin kenar ağırlığı spektral bilgiler kullanılarak belirlenirken, bu komşuluk dışında kalan piksellerin kenar ağırlıklarına sıfır atanmaktadır.

$$\mathbf{W}_{i,j} = \begin{cases} e^{-\frac{\|\mathbf{x}_i^s - \mathbf{x}_j^s\|_2^2}{\beta_{spektral}^2}}, & \text{eğer } (\mathbf{x}_i, \mathbf{x}_j) < \epsilon \\ 0, & \text{aksi takdirde.} \end{cases} \quad (3.5)$$

SE algoritmasının potansiyel matrisi, uzamsal bileşenler arasındaki yakınlığı ve LiDAR verileri arasındaki yakınlığı birleştirilerek elde edilmiştir. Uzamsal çözünürlük ve yükseklik çözünürlüğü uzunluk birimlerinden oluştukları için bunların, ışık yansıması kullanılarak elde edilen spektral bilgilerden ayırıp kendi aralarında potansiyel matrisiyle birleştirilmesi mantıklıdır. Ayrıca, bu yöntem spektral bilgilerin komşuluğunun uzamsal bilgilerden bağımsız bir şekilde belirlenmesine olanak sağlamaktadır. Uzamsal ve yükseklik bilgisi kullanılarak önerdiğimiz potansiyel matrisi denklem (3.6)'da verilmiştir. Denklemdaki $\mathbb{N}_\epsilon^u(\mathbf{x}_i)$, $\mathbf{x}_i$ 'nin uzamsal bileşenlerinin ϵ komşuluğundaki uzamsal bileşenler kümesidir. $\mathbf{x}_i^u$ ve $\mathbf{x}_j^y$ sırasıyla piksellerin uzamsal ve yükseklik bileşenlerini göstermektedir. $\mathbf{P}^{(i,j)}$ matrisi ise denklem (2.21)'da tanımlanan diyagonal olmayan bir matristir [32].

$$\mathbf{P} = \sum_{i=1}^k \sum_{\mathbf{x}_j \in \mathbb{N}_\epsilon^u(\mathbf{x}_i)} \mathbf{P}^{(i,j)} e^{-\frac{\|\mathbf{x}_i^y - \mathbf{x}_j^y\|_2^2}{\delta_{lidar}^2}} e^{-\frac{\|\mathbf{x}_i^u - \mathbf{x}_j^u\|_2^2}{\gamma_{uzamsal}^2}} \quad (3.6)$$


Şekil 3.2'de SE yöntemi ile LiDAR destekli HSG'lerin bölütleme akış şeması verilmiştir. $\mathbf{W}$ ve $\mathbf{P}$ matrisleri oluşturulduktan sonra, denklem (2.22)'deki özvektör sistemi çözülerek özdeğerler ve özvektörler elde edilir. Bu sistemde yer alan α değeri bölütlemeye spektral bilgilerinin ve uzamsal-yükseklik bilgilerinin katkılarını ayarlamak amacıyla deneysel olarak ayarlanacak serbest bir parametredir. α küçültüldüğünde bölütleme sonuçlarında spektral bilgilerinin etkisi diğerlerine göre daha fazla olacağından görüntü bölütleri spektral benzerliğine göre oluşacaktır. Diğer yandan, α büyütüldüğünde bölütleme sonuçları uzamsal ve yükseklik bilgilerine göre şekillenecektir. Bölütleme sonrası

HSG'lerin üzerine uygulanacak işlemlere yönelik, α parametresi değiştirilerek bölütleme sonuçları istenilen hale getirilmiş olunur. SMTNcut yönteminde, görüntü kaç bölüte ayrılacaksa ona göre özvektör sistemik adet özvektör için çözülmekte ve sonuç olarak aynı sayıda bölüt oluşturulmaktaydı. Ancak, görüntülerde bölüt sayısının önceden bilinmesi gibi bir durum söz konusu değildir. Özvektör sayısını değiştirerek bölütleme doğruluğu artırma bir yöntem olarak kullanılabilir.

Bu tez kapsamında gerçek veriler üzerinde de gösterileceği gibi, özvektör sisteminin çözümü sonucu elde edilen özvektörler görüntüdeki nesnelerin sınır bilgilerini içermektedir. Bu sebeple, k değerini belirlemek yerine, nitekim bu zor bir işlemdir, özvektör sistemi belirli sayıda özvektör için çözüldükten sonra, bu özvektörler denklem (2.19)'da verilen kenar bulma algoritmasıyla birleştirilip görüntünün kenar bilgilerinin oluşturulması sağlanabilir. Kenar bulma ile bölütleme birbiriyle örtüşen problemlerdir. Biri elde edilince diğeri elde etmek mümkündür. Bundan dolayı, Şekil 3.2'deki akış şemasında da gözüktüğü üzere sPb algoritmasının sonucu olan görüntünün kenar bilgisi UCM algoritmasından geçirilerek HSG'lerin bölütleri oluşturulmaktadır.

3.3 PMI Benzeşim Matrisi Tabanlı Ncut Yöntemiyle HSG'lerin Denetlemesiz Bölütlenmesi (PMITNcut):

Diğer iki yöntemde HSG verileri ile LiDAR verileri birleştirilip spektral bölütlemenin kullanıldığı benzeşim matrisi oluşturulurken uzamsal, spektral ve yükseklik bilgileri arasındaki Euclidean uzaklık temel alındı. Bu yöntemle ise HSG ve LiDAR verilerindeki aynı nesneye ait piksellerin, farklı nesnelere ait piksellerden daha yüksek istatistiksel bağımlılık sergilemesi prensibi temel alınarak benzeşim matrisi oluşturulmaktadır. PMI ile görüntüden alınan örnek ikililerinin özniteliklerinin tüm görüntüde birlikte bulunma olasılıkları hesaplanmaktadır. Bu yöntemle, HSG'lerden alınan uzamsal, spektral bilgiler ve LiDAR'dan elde edilen yükseklik bilgisi için ayrı ayrı PMI'lar hesaplanmaktadır. Daha sonra, bu PMI değerleri birleştirilerek benzeşim matrisi oluşturulmaktadır. Bu farklı kaynaklardan elde edilen bilgilerin birbirinden bağımsız olduğu açıktır. Çünkü nesnelerin spektral özellikleri, yükseklikleri ve görüntüdeki uzamsal konumları arasında herhangi bir ilgileşim (correlation) bulunmamaktadır. Bu gerçek ışığında, uzamsal, spektral ve yükseklik bilgilerinin PMI değerleri aşağıdaki denklemde verildiği gibi birleştirilerek ben-



Şekil 3.2. SET spektral bölütleme yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi


zeşim matrisinin oluşturulması önerilmektedir.

$$\mathbf{W}_{i,j} = e^{\sum_{k=1}^3 PMI_{\rho}(\mathbf{x}_i^k, \mathbf{x}_j^k)} \quad (3.7)$$

Denklem (3.7)'deki $\mathbf{x}_i^1$, $\mathbf{x}_i^2$ ve $\mathbf{x}_i^3$ sırasıyla uzamsal, spektral ve yükseklik bilgilerini ifade etmektedir. ρ parametresi ise önceki bölümde de bahsettiğimiz gibi veri kümesi üzerinde bölütleme doğruluğunu artıracak şekilde deneysel olarak belirlenecek serbest bir parametredir.


HSG'ler yüzlerce spektral bant içerir, bu yüzden spektral bilgi için PMI oluşturulması muazzam miktarda hesaplama gerektirebilir. Spektral bilgiler farklı nesneler için sadece belirli dalga boylarında farklılık göstermektedir. Bu bantlar için PMI değeri bölütlemeye herhangi bir fayda sağlamamaktadır. Bu nedenle, bölütlemenin efektif yapılması için HSG'lerden elde edilen spektral bilgilerin önemli kısımlarını koruyarak boyutlarının indirgenmesi gerekmektedir. Boyut indirgeme, verilerin içeriğini geliştiren bir işlemdir. Bu çalışmada, spektral bilgilere ilişkin herhangi bir ön bilgiye ihtiyaç duymayan temel bileşen analizi (principle component analysis-PCA) yöntemi kullanılmıştır. PCA çok boyutlu veri kümelerindeki bilgileri sıkıştırmada etkili bir yöntemdir [54]. Bu tezde kullanılan HSG'lere ait spektral bilgileri PCA ile elde edilen ilk 20 temel birleşenine ait özdeğerler Şekil 3.3'te verilmiştir. İlk 7 en büyük özdeğerin toplamı, tüm özdeğerlerin toplamının %99,35'ini oluşturmaktadır. Dolayısıyla; spektral veri kümesi, ilk 7 temel bileşen kullanılarak gösterilebilir. Böylece, işlem karmaşasından kaçınılmış olunacak ve PMI daha verimli elde edilerek bölütleme doğruluğu arttırılacaktır.

Diğer yandan, LiDAR belirli bir sahnedeki her piksele ait yükseklik bilgilerini sağlamaktadır. Ancak, 4. bölümünde sunulan veri kümesi düşük yoğunluklu kentsel bölgelerden oluşmakta ve çok sayıda ağaç grubu içermektedir. Bu ağaçların dalları arasındaki boşluklar nedeniyle, LiDAR verileri bazı bölgelerde pikselden piksele hızlı değişimler göstermektedir. Bu değişim, PMI sonucunu ve buna bağlı olarak HSG'lerin bölütleme doğruluğunu negatif yönde etkilemektedir. Bu eksikliği önlemek amacıyla LiDAR verilerinin pikseller arası geçişlerini yumuşatmak gerektiğinden standart sapması 1 olan ve 5x5'lik pencereden oluşan simetrik bir Gauss alçak geçirgen filtresi kullanılmıştır.



Şekil 3.3. Kullanılan veri kümesinin PCA ile elde edilen en büyük 20 özdeğeri

Şekil 3.4'te 3. yöntemin akış şeması gösterilmektedir. Benzeşim matrisi oluşturulurken direkt olarak PMI değeri de kullanılabilir. Ancak, PMI'nin üstel fonksiyonu PMI'dan daha iyi sonuçlar verdiği için denklem (3.7)'de verilen form kullanılmaktadır. Şekil 3.4'te de verildiği gibi, benzeşim matrisi PMI ile oluşturulduktan sonraki işlemler yöntem 2 ile aynıdır. Yani, PMI tabanlı benzeşim matrisi kullanılarak genelleştirilmiş özvektör sistemi çözülerek belirli sayıda özdeğer (bu yöntem için 100 adet özdeğer) ve bunlara karşılık gelen özvektörler hesaplanmaktadır. Bu özvektörlerin görüntüdeki nesnelerin kenar bilgilerini içerdiğini önceki bölümde söylenmişti. HSG'lerin yanı sıra LiDAR verilerinin de kullanılması bu özvektörlerdeki kenar bilgisini iyice arttırmaktadır. Bundan dolayı, elde edilen özvektörler (2.19)'de verilen sPb ile birleştirilerek görüntünün kenar bilgisi çıkartılmaktadır. Son olarak, Yönlendirilmiş Havza Dönüşümü (Oriented Watershed Transform-OWT) ve UCM uygulanarak görüntünün bölütleri elde edilir.



Şekil 3.4. PMITNcut yöntemi kullanılarak LiDAR destekli HSG'lerin bölütlenmesi

4. GERÇEK VERİLER ÜZERİNDE DENEYSEL SONUÇLAR

Çalışmanın bu kısmında, tez süresince kullanılan gerçek hiperspektral ve LiDAR veri kümeleri tanıtılmıştır. Bir önceki bölümde önerilen LiDAR destekli HSG'lerin bölütleme yöntemleri gerçek veriler üzerinde uygulanmış ve önerilen 3 yöntemin sonuçları ile mevcut çizge tabanlı yöntemlerin sonuçları karşılaştırılmıştır.

4.1 Gerçek Veri Kümesi

Bu tezde bölütleme sonuçları için MUUFL Gulfport veri kümesi [55] kullanılmıştır. MUUFL Gulfport veri kümesi Kasım 2010'da Mississippi Long Beach'te bulunan Güney Mississippi Gulf Park Kampüsü üzerinde toplanmıştır. Aynı anda tek bir uçaktan Optech ALTM Gemini LiDAR ve CASI-1500 hiperspektral görüntüleyici kullanılarak toplanmış veriler düşük yoğunluklu kentsel ve kıyı bölgelerinden oluşmaktadır. Hiperspektral veriler 72 bantta VNIR spektral aralığında oluşturulmuştur. LiDAR sensörü, 1064 nm'lik dalga boyunda çalıştırılarak yükseklik bilgisi elde edilmiştir. Hiperspektral görüntüleyicinin ve LiDAR sensörünün teknik özellikleri sırasıyla Çizelge 4.1'de ve Çizelge 4.2'de verilmektedir.

Çizelge 4.1. CASI-1500 hiperspektral görüntüleyicinin teknik özellikleri


Sensör Özelliği	Birimi	Değeri
Dalga Boyu Aralığı	nm	375 – 1050
Bant Sayısı	adet	72
Spektral Çözünürlük	nm	10
Uzamsal Çözünürlük	m	1
Toplandığı Yükseklik	km	1.0668

Şekil 4.1'de KYM görüntüsünde de görüleceği üzere, orijinal MUUFL Gulfport veri kümesi 325x337 pikselden oluşmaktadır. Gürültü sebebiyle hiperspektral verinin ilk 4 bandı ve son 4 bandı kullanılmamaktadır. Dolayısıyla, önerilen yöntemlerde 64 banttan oluşan spektral bilgiler üzerinde çalışılmaktadır. Yakın tarihte, veri kümesinin bölütleme doğruluk haritası da oluşturulmuştur [56]. Orijinal verinin sağ alt tarafı geçersiz alandan oluştuğundan bölütleme doğruluk haritası 325x220 piksellik kısım için oluşturulmuştur.


Çizelge 4.2. Optech ALTM Gemini LiDAR sensörünün teknik özellikleri

Sensör Özelliği	Birimi	Değeri
Dalga Boyu	nm	1064
Darbe Tekrarlama Frekansı (PRF)	kHz	70
Tarama Frekansı	Hz	43
Tarama Açısı	derece	30
Toplandığı Yükseklik	km	1.0668

Şekil 4.2’de veri kümesinin bölütleme haritası gösterilmektedir. Şekilde de görüldüğü gibi görüntüde toplam 11 tane etiketlenmiş sınıf bulunmaktadır. Bu sınıflar şunlardan oluşmaktadır: ağaçlar, çim, karışık zemin yüzeyi, çamur/kum, asfalt, su, binalar, bina gölgeleri, kaldırım, bordür taşları ve farklı spektral özelliklere sahip kumaş hedefler.



Şekil 4.1. MUUFL Gulfport veri kümesinin KYM görüntüsü



Şekil 4.2. MUUFL Gulfport veri kümesinin bölüt doğrulama haritası

4.2 Denetlemesiz Bölütleme Sonuçlarının Nesnel Olarak Karşılaştırılması

Denetlemesiz bölütleme sonuçlarının performansını değerlendirmek ve farklı yöntemlerin bölütleme doğruluğunu (BD) karşılaştırmak için nesnel ve istatistiksel bir kıstasa gereksinim duyulmaktadır. Bu amaçla, [57]'de önerilen spektral ayrıştırma gücü (power of spectral discrimination-PWSD) uygun gözükmemektedir. Bu yöntemin değiştirilmiş sürümü, HSG'lerin denetlemesiz bölütleme performansını değerlendirmek için [29]'da kullanılmıştır. PWSD, görüntüdeki belirli bir piksel için iki referans bölüt temsilci imzasına bağlı olarak bir ayrıştırma ölçütü sağlamaktadır. PWSD şöyle hesaplanmaktadır:

$$\Omega(\mathbf{c}_i, \mathbf{c}_j, \mathbf{x}) = \max \left\{ \frac{\text{sam}(\mathbf{c}_i, \mathbf{x})}{\text{sam}(\mathbf{c}_j, \mathbf{x})}, \frac{\text{sam}(\mathbf{c}_j, \mathbf{x})}{\text{sam}(\mathbf{c}_i, \mathbf{x})} \right\} \quad (4.1)$$

Burada, $\mathbf{c}_i$ ve $\mathbf{c}_j$ sırasıyla i ve j bölütlerindeki piksellerin spektral bilgilerinin ortalaması alınarak her bir bölüt için elde edilen temsilci imzalardır. $\mathbf{x}$ ise bir pikselin hiperspektral verisini ifade eder. Denklem (4.1)'de verilen spektral açı ölçüsü (spectral angle measure-sam), iki hiperspektral verinin ($\mathbf{x}$ ve $\mathbf{y}$) benzerlik ölçümünü gösterir ve aşağı-

daki gibi tanımlanır. Denklemden yer alan n spektral verilerin boyutunu göstermektedir.

$$sam(\mathbf{x}, \mathbf{y}) = 1 - \arccos \left(\frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \right) \quad (4.2)$$

Bir bölütteki her $\mathbf{x}_i$ pikseli için PWSD, pikselin ait olduğu bölütün ($\mathbf{c}_i$) temsilci imzası ve elde edilen farklı bölütlerin temsilci imzaları kullanılarak hesaplanır ($\mathbf{c}_j, i \neq j$). Daha sonra; m bölüte ayrılmış bir sahnedeki $\mathbf{x}$ pikseli için BD, denklem (4.3)'te verildiği gibi PWSD değerlerinin ortalaması alınarak hesaplanır.


$$BD(\mathbf{x}) = ortalama \{ \Omega(\mathbf{c}_i, \mathbf{c}_j, \mathbf{x}) | j = 1, \dots, m (i \neq j) \} \quad (4.3)$$

Tanımı gereği PWSD değeri ve dolayısıyla BD daima 1'den büyüktür. Bir bölütleme tekniği için ortalama BD, tüm piksellerin BD değerinin ortalaması alınarak elde edilebilir. Bölütleme tekniğinin görüntüdeki nesnelerin ayırt etme kabiliyeti, ortalama BD'nin artan değeri ile orantılı olarak arttığı sonucuna varılabilir.

4.3 SMTNcut Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları

Bu yöntemin bölütleme sonuçlarının ayrıntılı olarak incelenmesi için öncelikle Şekil 4.1'de KYM görüntüsü verilen veri kümesinin 121x121 pikselden oluşan bölümünün HSG ve LiDAR verileri üzerinde çalışılmıştır. Kullanılan bu alt kümenin KYM görüntüsü, farklı 14 hiperspektral bandından elde edilen görüntüler ve LiDAR'dan elde edilen yükseklik haritası Şekil 4.3'te gösterilmektedir. Daha önce bahsedildiği gibi, şekildeki hiperspektral bantlara bakıldığında görüntüdeki maddelerin ışığı farklı yansıttığı gözükmemektedir. Tek bant ele alındığında; bazı maddeler, özellikle çimen ve ağaçlar, ışığı benzer yansıttığından tek bant verileriyle bunları ayırmak oldukça zorlaşmaktadır.


HSG'lerdeki farklı dalga boyları malzemeleri ayırmada avantaj sağlamakla birlikte yeterli iyileştirmeyi yapamamaktadır. LiDAR verilerinden elde edilen yükseklik bilgileri yardımıyla, spektral olarak birbirlerine benzeyen ancak farklı yükseklikte bulunan madde-



Şekil 4.3. Sırasıyla: Kullanılan verinin 121x121 piksellik KYM görüntüsü (sol üst), 425nm bandı, 465nm bandı, 515nm bandı, 565nm bandı, 615nm bandı, 665nm bandı, 715nm bandı, 765nm bandı, 815nm bandı, 865nm bandı, 915nm bandı, 965nm bandı, 1015nm bandı, 1050nm bandı ve LiDAR ile oluşturulan yükseklik haritası(sağ alt)

leri ayırmak kolaylaşmaktadır. Ayrıca, LiDAR verilerinin kullanımı cisimleri ve cisimlere ait gölgeleri birbirinden ayırmada önemli katkı sağlamaktadır.

Benzeşim matrisini oluşturmak için görüntülerde yer alan her bir piksel boğum olarak




Şekil 4.4. Sırasıyla: Veri kümesinin 121x121 piksellik bölümü bilgileri kullanılarak oluşturulan benzeşim matrisi ($\beta_{\text{spektral}} = 0.3$, $\gamma_{\text{uzamsal}} = 5$, $\delta_{\text{lidar}} = 2$ ve $r = 5$), belli bir bölgesi yakınlaştırılmış benzeşim matrisi

seçilmiş ve denklem (3.1)'de olduğu gibi hesaplamıştır. Hesaplama yapılırken $\beta_{\text{spektral}} = 0.3$, $\gamma_{\text{uzamsal}} = 5$, $\delta_{\text{lidar}} = 2$ ve $r = 5$ olarak seçilmiştir. Deneysel olarak seçilen bu parametre değerlerine göre elde edilen benzeşim matrisi Şekil 4.4'te verilmiştir. Şekilde de gözüktüğü gibi benzeşim matrisi seyrek (sparse) bir matristir. Yani köşegen ve köşegen çevresindeki bantta yer alan girdiler dışında kalan tüm değerler sıfırdır. Aynı zamanda benzeşim matrisi simetrik bir matristir. Kullanılan görüntü 121x121 boyutlarında olduğundan, yani çizge toplamda 14641 piksel (boğum) içerdiğinden, oluşturulan benzeşim matrisi 14641x14641 boyutlarındadır. Tanımı gereği benzeşim matrisi maksimum 1 değerini ve minimum 0 değeri almaktadır. Şekilde yakınlaştırılmış bölümüne bakıldığında sadece komşu 5 piksel arasındaki kenar ağırlıklarının hesaplandığı gözükmemektedir ve bu ağırlıklar pikseller arasındaki benzerlikler (uzamsal, spektral ve yükseklik) azaldıkça, orantılı olarak azalmaktadır.


Benzeşim matrisi oluşturulduktan sonra, Şekil 3.1'de gözüktüğü gibi özvektör sisteminin çözümü yapılır. Belirlenen sahne için özvektör sistemi en büyük 30 tane özdeğer ve bunlara karşılık gelen özvektörler bulunacak şekilde çözümlenmiştir. Sistemin çözümü sonucunda elde edilen en büyük 30 özdeğer ve görüntünün boyutlarına dönüştürülmüş ilk 8 özvektör Şekil 4.5'te gösterilmektedir. Şekilde gözüktüğü gibi her bir özvektör görüntünün belirli alanlarını diğer alanlardan ayırmaktadır. Ancak, bir önceki bölümde

bahsedildiği gibi Ncut çözümü ayırık olması gerekirken genelleştirilmiş özvektör sisteminin çözümü ile elde edilen özvektörler sürekli dirler. Dolayısıyla, Şekil 4.5'te de gözüktüğü gibi, özvektörlerde bazı bölgeler arasındaki geçişler daha yumuşak olduğundan ve özvektörlerin yüksek değerler aldığı kısımların çakışması sebebiyle tam olarak görüntüdeki bölütleri ifade etmemektedir. Bu özvektörlerden bölütler elde edilmesi için ayrıklaştırılması gerekmektedir.


Önerdiğimiz bu yöntemde, çok katmanlı Ncut algoritması kullanılarak özvektörler ayrıklaştırılmıştır. Oluşturulan bu ayırık vektörlerin görüntü boyutlarına dönüştürülmüş halleri Şekil 4.6'da gösterilmektedir. Şekilde de gözüktüğü gibi, her bir ayırık özvektör görüntünün farklı bir bölümünü ayırmaktadır ve vektörlerin ayırdığı bölgeler çakışmaktadır. Son olarak, verilen sahnedeki görüntü bölütlerini oluşturmak için bu ayırık vektörler birleştirilmelidir. Bu birleştirme işlemi basit bir çarpma ve toplama işleminden ibarettir. Ayırık özvektörlerin elemanları sadece 1 ve 0 değerlerinden oluşmaktadır. Bölütleri birbirinden ayırmak için her bir özvektör farklı doğal sayıyla çarpılıp ardından toplanırsa bölütler elde edilmektedir. Örneğin; ilk vektör 1 ile çarpılsın, ikinci vektör 2 ile çarpılsın ve bu sırayla devam edilerek tüm vektörler artan sıradaki doğal sayıyla çarpılıp toplandığında görüntü bölütleri oluşturulmaktadır.



Şekil 4.5. Veri kümesinin 121x121 piksellik bölümü kullanılarak özvektör sistemiyle oluşturulan en büyük 30 tane özdeğer (sol üst) ve ilk 8 en büyük özdeğere karşılık gelen görüntünün boyutlarına dönüştürülmüş özvektörler (y)



Şekil 4.6. Sürekli özvektörlerin ayrıklaştırılması sonucu oluşturulan ve görüntünün boyutlarına dönüştürülmüş ilk 8 ayırık özvektör (y')



Şekil 4.7. (a) Kullanılan verinin 121x121 piksellik KYM görüntüsü, (b) Verinin bölütleme doğruluk haritası, (c) SMTNcut yöntemiyle HSG'lerin bölütleme sonucu

Şekil 4.7'de ilgili görüntü kısmının bu yöntemle elde edilmiş bölütleme sonucu verilmektedir. LiDAR verilerinin kullanılmasıyla benzer özellikler taşıyan ağaç ve çim gibi nesneler başarılı bir şekilde ayrı ayrı bölütlenmiştir. Aynı zamanda, bölütleme doğruluk haritasında verilmeyen, ancak Şekil 4.7 (a)'da yer alan kırmızı araba da bu yöntem sonucu ayrı bir bölüte yerleştirilmiştir. Binalar ile gölgelerini ayırmada başarı göstermektedir. Ancak, bu yöntemin temel birkaç eksikliği mevcuttur. İlk olarak, kullanılan özvektör

sayısının önceden belirlenmesi gerekmektedir, yukarıda bahsedildiği gibi görüntünün 121x121 piksel alana sahip sahnesi için 30 özvektör kullanılmıştır. Görüntünün doğru bir şekilde bölütlenmesi için kullanılan özvektör sayısının uygun seçilmesi gerekmektedir. Az sayıda özvektör kullanıldığında görüntü olduğundan daha az bölüte ayrılacaktır. Çok sayıda özvektör kullanıldığında ise görüntü olduğundan daha fazla bölüte ayrılacaktır. İkinci eksiklik ise bu yöntemle görüntüdeki tekdüze büyük alanlar yanlış ayrılmaktadır. Örneğin, Şekil 4.7 (c)'de verilen bölütleme sonucunda da görüldüğü gibi, asfalt yol bir bütün olarak ayrılamamıştır. Ayrıca, büyük alanların birden çok bölüte ayrılmasını sağlayan özvektör sayısı da etkilemektedir.

Bölütleme doğruluğu için benzeşim matrisi oluşturulurken kullanılan $\beta_{spektral}$, $\gamma_{uzamsal}$, δ_{lidar} değerlerinin ve komşu kaç piksel arasında (r) kenar ağırlıklarının hesaplanacağı kritik öneme sahiptir. Çizelge 4.3'te farklı r parametresi için bu yöntemin ortalama BD değeri verilmektedir. Ortalama BD hesaplanırken diğer tüm değişkenler sabit tutularak sadece r parametresi değiştirilmiştir. Sonuçlara bakıldığında bu değer arttıkça, buna bağlı olarak ortalama BD de artmaktadır. Çünkü r değerinin artması, çizgede daha çok komşu piksel aralarındaki kenar ağırlıklarının hesaplanması anlamına gelmektedir. Kenar sayısı arttıkça görüntü hakkında daha çok bilgi kullanılarak çizge oluşturulmaktadır. Ancak, hesaplanan kenar ağırlığı sayısı arttıkça, birlikteliğinde işlem yükü de artmaktadır. r değeri arttıkça ortalama BD'deki artış miktarı azalmaktadır. Bu sebeple, işlem yükünü fazla arttırmayacak bir değerde sabit bırakılması mantıklıdır. Ayrıca, $\beta_{spektral}$, $\gamma_{uzamsal}$ ve δ_{lidar} parametrelerinin arttırılması pikseller arasındaki benzerlik geçişlerini yumuşattığından, bölütleme sonucunu iyileştirmektedir. Fakat çok arttırılmaları, farklı uzamsal ve spektral özelliklere sahip piksellerin benzerliğini de arttıracığından bölütlemeyi negatif yönde etkilemektedir.

4.4 SET Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları

Bu yöntemin bölütleme sonuçları için Ncut yönteminde olduğu gibi ayrıntılı incelemek amacıyla veri kümesinin Şekil 4.3'te verilen 121x121 pikselden oluşan bölümünün HSG ve LiDAR verileri üzerinde çalışılmıştır. Denklem (3.5)'te verilen benzeşim matrisini oluşturmak için $\beta_{spektral} = 1$ seçilmiştir. $\epsilon = 10$ komşuluğundaki pikseller arası ağırlıklar hesaplanmıştır. Denklem (3.6)'da gösterilen potansiyel matrisi oluşturulurken ise basit-


Çizelge 4.3. Farklı r değerleri için SMTNcut yöntemin ortalama BD'si ($\beta_{\text{spektral}} = 0.3$, $\gamma_{\text{uzamsal}} = 5$, $\delta_{\text{lidar}} = 2$ ve kullanılan özdeğer sayısı=30)

Deneme No	r (piksel)	ortalama BD
1	2	1.2620
2	3	1.2755
3	4	1.3658
4	5	1.3658
5	6	1.3873
6	7	1.3996
7	10	1.4051

lik olması açısından $\gamma_{\text{uzamsal}} = 1$, $\delta_{\text{lidar}} = 1$ seçilmiş ve $\epsilon = 6$ komşuluğundaki uzamsal bilgiler ve bunlara karşılık gelen yükseklik bilgileri kullanılmıştır. Spektral Pb kenar bulma algoritmasındaki yönlü türevler hesaplanırken, θ 'nın $[0, \pi]$ aralığında düzgün dağılmış 8 açı değeri kullanılmıştır. Bulunan kenarlardan bölütler oluşturulurken, elde edilen tüm sonuçlar için, UCM algoritmasının kullandığı eşik değeri 0,2 olarak belirlenmiştir. Son olarak, Laplacian matrisi ile potansiyel matrisin katkılarını görece ağırlıklandırarak bölütleme sonuçlarındaki değişimi gözlemlemek amacıyla denklem (2.22)'deki α 'nın farklı değerleri için ortalama BD hesaplanmıştır.

SE algoritmasının benzeşim matrisi olan **W** ve potansiyel matrisi olan **P** hiperspektral ve LiDAR verileriyle oluşturulduktan sonra Şekil 3.2'de gözüktüğü gibi belirlenen bir α değeri ile özdeğer sistemi en küçük özdeğer ve bunlara karşılık gelen özvektörler için çözümlenir. SMTNcut yöntemiyle bu basamaktan sonra elde edilen özvektörler ayrıklaştırılarak bölütler oluşturuldu. Ancak, SMTNcut yönteminde oluşturulan ayrık özvektör sayısı bölüt sayısı ile aynı olması gerekmektedir. Gerçek UA uygulamalarında görüntüdeki bölüt sayısı önceden bilinmediğinden özvektör sayısı belirlemek bölütleme doğruluğu açısından büyük önem kazanmaktadır. Bu yöntemle özvektör sistemi daha fazla özdeğer ve özvektör ($N=50$) için çözümlenerek bu bağımlılık ortadan kaldırılmaktadır. 3. bölümde bahsettiğimiz gibi elde edilen bu özvektörler görüntüdeki nesnelerin kenar bilgilerini içermektedir. Bu sebeple özdeğer sistemi sonucu elde edilen özvektörler denklem (2.19)'daki spektral Pb yöntemiyle birleştirilip görüntünün kenar bilgileri oluşturulabilir.


Şekil 4.8’de, özvektör sisteminin çözümü sonucu elde edilen ilk beş en küçük özdeğere karşılık gelen özvektörler ve bu özvektörler kullanılarak elde edilen spektral Pb sonucu gösterilmektedir. Şekildeki özvektörlere bakıldığında, her birinin görüntüdeki farklı bölgelerin kenar bilgisi taşıdığı gözükmemektedir. Çok sayıda özdeğer ve bunlara ait özvektör kullanılarak sPb ile görüntüdeki tüm nesnelerin kenar bilgisini oluşturmak mümkündür. LiDAR’dan elde edilen yüksekli bilgisi de kullanıldığından nesneler ile gölgeleri arasındaki kenar bilgileri de oluşturulmaktadır.



Şekil 4.8. Veri kümesinin 121x121 piksellik bölümü kullanılarak özvektör sistemiyle oluşturulan en büyük 5 tane özdeğer karşılık gelen özvektörler ve bu 5 vektör ile elde edilen sPb sonucu (sağ alt)

Spektral Pb sonucu kullanılarak UCM algoritmasıyla verilen sahnenin bölütleri oluşturulmaktadır. SET yönteminin bölütleme algoritmasının farklı α değerleri için elde edilen bölütleme sonuçları Şekil 4.9’da gösterilmektedir. Sonuçlara bakıldığında, $\alpha = 0$ iken, yani sadece spektral bilgiler kullanıldığında, görüntünün gereğinden fazla bölütlere ayrıldığı gözlemlenmektedir. Özellikle, ağaç toplulukları, gölgeleri ve çimenler olması gerekenden daha fazla bölütlere ayrılmıştır. $\alpha = 4$ iken, spektral bilgilerin yanı sıra uzamsal


ve özellikle yükseklik bilgileriyle elde edilen potansiyel matrisi devreye girdiğinde daha önce elde edilen fazla bölütlerin bertaraf edildiği gözükmemektedir. Ağaç toplulukları tek bir bölüt olarak ayrılmış, ağaç gölgeleri de ağaçlardan farklı bir bütün olarak gruplanmıştır. Benzer şekilde, çimenlerdeki fazla bölütler ortadan kalkmış, tek bölüt halinde ayrılmıştır. α değeri arttırıldığında, spektral bilginin bölütlemeye etkisi azalırken yükseklik bilgisinin etkisini arttırmaktadır. Beklenildiği gibi, yüksekliği baskın olan cisimlerin bölütlendiği Şekil 4.9 (d)'de $\alpha = 50$ için gözükmemektedir.



Şekil 4.9. (a) $\alpha = 0$ iken bölütleme sonucu, (b) $\alpha = 4$ iken bölütleme sonucu, (c) Verinin 121x121 piksellik KYM görüntüsü, (d) $\alpha = 10$ iken bölütleme sonucu, (e) $\alpha = 50$ iken bölütleme sonucu, (f) Verinin bölütleme doğruluk haritası

Şekil 4.10'da α parametresinin değişimine bağlı olarak ortalama BD değişimi gösterilmektedir. Grafikte gözüktüğü gibi α ayarlanarak verilen sahnenin BD'si en iyi seviyeye çıkartılabilir. α 'nın değeri belli bir noktadan sonra arttırılması sahnenin BD'sinin azalmasına sebep olmaktadır. Bu yanlış bölütler oluşturulduğu anlamına gelmemektedir. Bölümün başında bahsedildiği gibi BD, bölütleme yönteminin görüntüdeki nesnelerin spektral olarak ayırıp ayırmadığının bir ölçüsüdür. Ancak, α arttırılmasıyla spektral bilgilerin bölütleme üzerindeki etkisi azaldığından, beklenildiği gibi BD'nin azaldığı gö-

zükmetedir. α 'nın artırılması uzamsal ve yükseklik bilgilerinin bölütleme üzerindeki etkisini arttırmasına sebep olurken, elde edilen bölütleme haritası da buna göre şekillenmektedir. Dolayısıyla, Şekil 4.9 (d)'de de gözüktüğü üzere $\alpha = 50$ iken, yükseklik bilgisine göre görüntü bölütleri oluşmaktadır.



Şekil 4.10. α 'nın değişimine bağlı olarak ortalama BD'nin değişimi


4.5 PMITNcut Yöntemiyle HSG'lerin Denetlemesiz Bölütleme Sonuçları

PMITNcut yönteminin HSG'lerin denetlemesiz bölütleme sonuçları incelemek amacıyla diğer iki yöntemde olduğu gibi ilk olarak veri kümesinin Şekil 4.3'te verilen 121x121 pikselden oluşan bölümünün HSG ve LiDAR verileri üzerinde çalışılmıştır. Bu sahne verileriyle spektral bölütlemenin kullandığı benzeşim matrisini, $\mathbf{W}$, oluşturmadan önce ilgili veri kümesinin Şekil 3.4'teki akış şemasında gözüktüğü gibi bazı ön işlemlerden geçmesi gerekmektedir. Öncelikle işlem karmaşasını önlemek amacıyla ve PMI'nın verimli hesaplanması için PCA ile spektral bilgilerin daha düşük boyutlara indirgenmesi gerekmektedir. Şekil 3.3'te PCA ile elde edilen temel bileşenlere ait özdeğerler gözükmektedir. Bunların ilk 7 temel bileşenine ait özdeğerlerin toplamı, tüm özdeğerlerin toplamının yüzde 99,35'ini oluşturduğu bölüm 3.3'te bahsedilmişti. Dolayısıyla bu 7 temel

bileşen kullanarak önemli veri kaybına uğramadan spektral bileşenlerin içeriği zenginleştirilebilir. Şekil 4.11’de verinin 121x121 piksellik sahnesinin spektral bilgileri için PCA ile oluşturulan ilk 7 temel bileşeni gösterilmektedir. Görüldüğü üzere temel bileşenlere ait özdeğerler azaldıkça spektral bilgilerden elde edilecek bilgiler de gürültü haline dönüşmektedir. PMI oluşturulurken daha küçük bileşenlerin kullanılması, hem işlem yükü oluşturacağından hem de nesneler hakkında önemli bilgiler getirmeyeceğinden, gereksizdir.

Diğer ön işlem ise LiDAR verileri ile PMI oluşturmada önce yükseklikler arasındaki geçişleri yumuşatmak için filtreden geçirmektir. Veri kümesi düşük yoğunluklu kentsel bölgelerden oluştuğundan yükseklik bilgisi pikseller arası hızlı değişimler gösterebilmektedir. Şekil 4.12 (a)’da verinin orijinal yükseklik haritası gözükmemektedir. Şekilde gözüktüğü gibi, özellikle ağaç topluluklarının olduğu bölgelerde yükseklik bilgisi pikseller arasında hızlı değişimler göstermektedir. LiDAR verileri ile elde edilen PMI etkinliğini arttırmak adına yükseklik bilgileri, standart sapması 1 olan ve 5x5’lik pencereden oluşan simetrik bir Gauss alçak geçirgen filtresinden geçirilerek hızlı değişimler yumuşatılmaktadır. Filtrelenmiş yükseklik haritası Şekil 4.12 (b)’de verilmektedir. Filtrelenmiş yükseklik haritasına bakıldığında ağaç topluluklarının olduğu bölgeler başta olmak üzere, veriye zarar vermeden pikseller arasındaki yükseklik geçişleri yumuşatılmaktadır.


Ön işleminden geçen veriler, spektral bölütleme yönteminin kullandığı benzeşim matrisini oluşturmaya hazır hale gelmektedir. Denklem (2.27)’de verilen piksellerin birlikte görülme olasılıklarını hesaplamak için görüntüden 5000 örnek piksel alınmıştır. Bu piksel örnekleri görüntünün farklı bölgelerinden alınması için rastgele seçilmektedir. Rastgele belirlenen örnek piksellerin etrafından $d = 2$ ’den $d = 4$ uzaklığına kadar $\mathbf{x}_i$ ve $\mathbf{x}_j$ öznitelik çifti alınarak birlikte bulunma olasılıkları hesaplanmıştır. Uzaklık arttıkça pikseller arasındaki bağları ters orantılı olarak azaltmak için ağırlık fonksiyonu olan $w(d)$ standart sapması 0.1 olan Gauss fonksiyonu seçilmiştir. Elde edilen bu örnek piksellere çekirdek yoğunluk kestirimi (kernel density estimation-kde) kullanarak denklem 2.27’deki olasılık yoğunluk fonksiyonu oluşturulmuştur [49]. Daha sonra, bu olasılık fonksiyonu kullanarak PMI oluşturulmuştur. PMI hesaplanırken ρ parametresi bölütleme performansını arttırmak amacıyla farklı değerler için test edilmiş ve 1.8 olarak belirlenmiştir. PMI; uzamsal,



Şekil 4.11. Verinin 121x121 piksellik sahnesinin PCA ile oluşturulan ilk 7 temel bileşeni

spektral ve yükseklik bilgileri için ayrı ayrı hesaplandıktan sonra (3.7)'deki gibi birleştirilerek benzeşim matrisi oluşturulmuştur. Bu aşamadan sonra ikinci yöntem olan SET yönteminde olduğu gibi spektral bölütleme kullanılarak bölütler oluşturulmuştur. SET yönteminden farklı olarak spektral bölütleme 100 özdeğer ve bunlara karşılık gelen özvektörler için çözümlenmiştir. Bu özvektörler ve özdeğerler kullanılarak sPb algoritmasıyla görüntünün kenar bilgisi çıkartıldıktan sonra eşik değeri 0.25 olarak belirlenen OWT-UCM algoritmasıyla bölütler elde edilmiştir.

Şekil 4.13'te verilerinin 121x121 piksellik bölümü kullanılarak elde edilen PMITNcut bölütleme yönteminin sonuçları verilmektedir. Şekil 4.13 (c) görüntünün sPb ile elde edilen kenar bilgisini göstermektedir. Bu kenar bilgisi özellikle belli yüksekliğe sahip olan bina ve ağaç topluluklarında oldukça baskındır. Bunun temel nedeni HSG'lere ek olarak LiDAR verilerinin de kullanılmasıdır. Bu kenar bilgisi kullanılarak oluşturulan bölütler Şekil 4.13 (d)'de verilmektedir. Bölütleme sonucu verinin KYM görüntüsü ve bölütleme doğruluk haritasıyla karşılaştırıldığında başarılı olduğu açıkça gözükmemektedir. PMITNcut algoritmasının, bölütleme doğruluk haritasında pembe renkle gösterilen bina gölgesini tam anlamıyla ayrıldığı gözükmemektedir. Doğruluk haritasında etiketsiz olarak tanımlanan ancak KYM görüntüsünde ağaç gölgelerinden oluşan anlaşılan bölgelerin



Şekil 4.12. Verinin 121x121 piksellik sahnesinin: (a) orijinal yükseklik haritası, (b) Gauss filtresinden geçirilmiş yükseklik haritası

ağaçlardan ayrı bölütlendiği gözükmemektedir. SET yönteminde olduğu gibi görüntüdeki tekdüze büyük alanlar bütün olarak yüksek başarıyla bölütlenmektedir.

Yukarıda anlatıldığı gibi, bu yöntemle görüntüden rastgele seçilen piksellerle bölütleme yapıldığından algoritmanın her seferinde farklı sonuçlar vereceği aşikardır. Bu sebeple her denemede ilgili bölütleme sonucunun ortalama BD'si farklı olmaktadır. Bu yöntem için ortalama BD hesaplanırken algoritmanın çok sayıda çalışma sonucunun ortalaması alınarak genel bir ortalama BD oluşturulmaktadır. Çizelge 4.4'te sadece 10 farklı deneme sonucunun ortalama BD değeri ile 100 deneme sonucunda elde edilen değerlerin ortalaması verilmektedir. PMITNcut yönteminin farklı denemelerinde hesaplanan ortalama BD en fazla 5.0439 değerini alarak yüksek bir performans göstermektedir. Diğer yandan, ortalama BD'nin en düşük değeri 3.8300 olarak gözükmemektedir. Bunun temel nedeni sahnedeki rasgele örneklenen parçaların konumlarıdır. Uygun pikseller seçildiğinde ve bu piksellerin komşularından elde edilen uzamsal, spektral ve yükseklik bilgileriyle başarılı bölütleme sonuçları elde edilebilmektedir. Şekil 4.9 (c) ve Şekil 4.13 (d) bölütleme sonuçları karşılaştırıldığında, PMITNcut yöntemi ile SET yöntemin benzer sonuçlar verdiği gözükmemektedir. Ancak, ortalama BD'lere bakıldığında PMI yönteminin


yüksek başarı oranı göze çarpmaktadır. Ortalama BD'nin yüksek olması şu anlama gelmektedir: PMITNcut yöntemi pikselleri spektral olarak ayırmada üstün performans göstermektedir. Başarıyı arttıran etkenlerden biri LiDAR verileridir. LiDAR verileriyle görüntüdeki nesneleri yorumlama kabiliyetinin arttığı açıkça gözükmemektedir.

Çizelge 4.4. Farklı denemeler için PMITNcut yönteminin ortalama BD değerleri ile genel ortalama BD ve standart sapma değeri

Deneme No	ortalama BD
1	4.2114
2	5.0439
3	4.5819
4	3.8300
5	4.2446
6	4.5175
7	4.7306
8	4.4329
9	4.5145
10	4.6976
Genel ortalama	4.4805 $\pm$ 0.1104

4.6 Mevcut ve Önerilen Yöntemlerin Karşılaştırılması


Bu bölümde, LiDAR destekli HSG'lerin bölütlenmesi için önerilen 3 yöntemin sonuçları ve LiDAR bilgileri kullanmadan bölütleme yapan mevcut yöntemlerin sonuçları kıyaslanmaktadır. Bu kıyaslama yapılırken Şekil 4.14'te KYM görüntüsü, yükseklik haritası ve bölütleme doğruluk haritası gösterilen veri kümesi üzerinde sonuçlar tartışılmaktadır. LiDAR verilerinin bölütlemeye sağladığı avantajı görmek açısından; SM, GB yöntemleriyle benzeşim matrisi oluşturmuş ve (3.7)'de verilen benzeşim matrisi yükseklik verisi çıkartılarak hesaplanmış ve ilgili veri kümesinin bölütleri oluşturulmuştur. Yükseklik bilgisi kullanılmadan elde edilen sonuçlar ile önerilen yöntemlerle elde edilen sonuçlar karşılaştırılmaktadır. Sadece HSG verileri kullanılarak bölütleme yapıldığında karşımıza çıkan iki temel problem olduğundan bahsedilmişti. Bunlar, benzer spektral özelliklere sahip nesnelerin ayrılabilmesi ve nesnelerle gölgelerinin tam anlamında bir-



Şekil 4.13. (a) Kullanılan verinin 121x121 piksellik KYM görüntüsü, (b) Verinin bölütleme doğruluk haritası, (c) sPb ile oluşturulan görüntünün kenar bilgisi, (d) PMITNcut yöntemiyle HSG'lerin bölütleme sonucu


birinden ayıramaması problemleri idi. Önerilen yöntemlerle LiDAR kullanıldığından bu problemlerin ne derece bertaraf edildiği sonuçlar üzerinden gösterilmektedir.

Şekil 4.15'te Ncut yönteminin ilgili veri kısmı için bölütleme sonuçları verilmektedir. Bu bölüt haritası oluşturulması için $r = 10$ seçilmiş ve 40 özvektör kullanılmıştır. Bölüt oluşturma ile kenar bilgisi örtüşen problemler olduğundan, SMTNcut bölütleme sonucunun daha iyi anlaşılması adına verinin doğruluk haritası üzerine bölütleme sonunda elde edilen kenar bilgisi çizdirilmiştir. Binaların olduğu bölgelere bakıldığında başarılı bölüt-



Şekil 4.14. (a) Veri kümesinin 150x220 piksellik bölümünün KYM görüntüsü, (b) Gauss filtresinden geçirilmiş yükseklik haritası, (c) Bölütleme doğruluk haritası

ler oluşturulmuş ve bina gölgeleri ayrılmıştır. Dikkat edilirse, binalar üzerinde bulunan bazı yükseltmeler (havalandırma veya merdiven çıkışları olabilir) LiDAR verileri yardımıyla ayrılmıştır. Ancak, bu yöntemin temel problemi olan tekdüze alanları düzgün ayırması bu sahne için de gözükmemektedir. Kullanılan özvektör sayısı değiştirilerek kısmen bu problemin önüne geçilebilir. Diğer yandan, aynı görüntü kullanılarak SET ve PMITNcut yöntemlerin sonuçları sırasıyla Şekil 4.16 (a)'da ve Şekil 4.16 (b)'de verilmektedir. Bu bölütleme sonuçları elde edilirken, SET yöntemi için UCM eşik değeri 0.15 olarak belirlenmiş ve PMITNcut yöntemi için UCM eşik değeri 0.05 olarak belirlenmiştir. Bu yöntemlerin kullandığı diğer parametreler yukarıda belirlenen değerleriyle kullanılmıştır. SET ve PMITNcut yöntemlerin sonuçlarına bakıldığında, SMTNcut yöntemine nazaran sahnedeki nesnelerin daha düzgün ayrıldıkları anlaşılmaktadır. SET ve PMITNcut




Şekil 4.15. SMTNcut yöntemin bölütleme sonucu (solda, $r=10$), bölütleme sonucu kullanılarak elde edilen kenar bilgisi (sağda)

yöntemlerinin, SMTNcut'taki gibi tekdüze büyük alanları yanlış ayırma oranlarının daha düşük olduğu gözükmemektedir.

Bu algoritmalarda önemli olan UCM eşik değerinin uygun seçilmesidir. Bu eşik değeriyle görüntü bölüt sayısı ve doğruluğu artırılabilir. Tüm algoritmaların sonuçlarına bakıldığında, binalar ve gölgelerinin muazzam şekilde ayrıldığı gözükmemektedir. Ancak, SMTNcut'ın binalar üzerindeki çıkıntıları ayırdığı gözükürken, SET ve PMITNcut yöntemlerinde gözükmemektedir. Bunun nedeni LiDAR verilerinin algoritmadaki diğer bilgilere göre ağırlıklandırılmasıyla ilgilidir.

Şekil 4.16 (a)'ya ve Şekil 4.16 (b)'ye daha ayrıntılı bakacak olursak, kırmızı halka içine alınan kısımlarda SET yönteminin gereksiz bölütler oluşturduğu gözükürken PMITNcut yönteminde bu sorunlar büyük oranda çözümlenmiştir. Mavi halka ile gösterilen su bölgesinin SET yöntemiyle daha başarılı bir şekilde ayrıldığı gözükmemektedir. Aynı şekilde, sarı halkalarla gösterilen bazı bölgelerde, SET'in PMITNcut'tan daha doğru sonuçlar ürettiği göze çarpmaktadır.


Şekil 4.15'teki ve Şekil 4.16'daki bölütleme sonuçları kullanılarak hesaplanan ortalama BD değerleri Çizelge 4.5'te verilmektedir. Çizelgeye bakıldığında, diğer iki yöntemle kıyasla PMITNcut yöntemiyle son derece yüksek BD elde edilmiştir. Bu değer yüksek olması, görüntüdeki nesnelerin spektral açıdan PMITNcut yöntemiyle daha doğru ayrıl-



Şekil 4.16. (a) SET yöntemin bölütleme sonucu (UCM eşik değeri 0.15) , (b) PMITNcut yöntemin bölütleme sonucu (UCM eşik değeri 0.05) (c) Bölütleme doğruluk haritası

diği anlamına gelir. SMTNcut ve SET yöntemlerinin bu değeri düşük çıkmasının temel sebebi bazı bölgeleri fazla veya eksik bölütlemesinden kaynaklanmaktadır.

Şekil 4.17’de önerilen SMTNcut ve SET yöntemlerinin bölütleme sonuçları ile önerilen PMITNcut yönteminin LiDAR’lı ve LiDAR’sız bölütleme sonuçları ve mevcut SM, GB yöntemleriyle oluşturulan bölütleme sonuçları verilmektedir. Sonuçlar incelendiğinde, önerilen yöntemlerde yükseklik bilgisi kullanıldığında bölütleme sonuçlarında gelişme gözükmemektedir. Görüntüdeki nesnelerin LiDAR verileri yardımıyla daha anlamlı bölütlere ayrıldığı açıktır. Sadece uzamsal ve spektral bilgiler kullanan SM ve GB yöntemleri ile önerilen PMITNcut yönteminin LiDAR kullanılmayan sürümü, benzer spektral özelliklere sahip nesnelerin ayrılamaması (çimenler ve ağaçlar gibi) ve bazı noktalarda gölgelerin ayrılamaması (binalar ve gölgeleri gibi) problemleri yükseklik bilgisi yardımıyla



Şekil 4.17. (a) Önerilen PMITNcut yöntemin LiDAR'sız bölütleme sonucu, (b) Önerilen PMITNcut yöntemin LiDAR'lı bölütleme sonucu , (c) GB yöntemiyle oluşturulan bölütleme sonucu (LiDAR'sız), (d) Önerilen SET yönteminin bölütleme sonucu (e) SM yöntemiyle oluşturulan bölütleme sonucu (LiDAR'sız), (f) Önerilen SMTNcut yönteminin bölütleme sonucu

Çizelge 4.5. Yöntemlerin veri kümesinin 150x220 piksellik bölümü kullanılarak elde edilen ortalama BD'leri

Deneme No	Ortalama BD $\pm$ standart sapma
SM yöntemi	1.3879 $\pm$ 0
GB yöntemi	1.3693 $\pm$ 0
Önerilen SMTNcut yöntemi	1.4429 $\pm$ 0
Önerilen SET yöntemi	1.4536 $\pm$ 0
Önerilen PMITNcut yöntemi (LiDAR'sız)	4.2770 $\pm$ 0.3390
Önerilen PMITNcut yöntemi (LiDAR'lı)	4.6489 $\pm$ 0.4607

büyük oranda çözüme ulaştığı sonuçlardan anlaşılmaktadır. Ayrıca, Çizelge 4.5'teki ortalama BD'ler incelendiğinde, LiDAR kullanılması görüntülerin spektral ayrıştırma gücünü arttırmaktadır.

5. SONUÇLAR

Bu tezde, son zamanlarda görüntü işleme alanında önemli bir konu olan spektral bölütleme yöntemiyle hiperspektral veriler ve LiDAR verileri birleştirilip HSG'lerin denetlemesiz bölütlemesi sağlanmıştır. Spektral bölütlemeye en önemli nokta benzeşim matrisinin probleme uygun seçilmesidir. Bu çalışmada, HSG'lerden elde edilen uzamsal ve spektral bilgilerle LiDAR'dan elde edilen yükseklik bilgisi birleştirmek amacıyla 3 farklı benzeşim matrisi önerilmiştir. Önerilen bu benzeşim matrisleri farklı spektral yöntemler ve bu yöntemlerin farklı çözümleri ile görüntü bölütleri incelenmiş ve spektral ayırıştırma gücü yöntemiyle bölütleme doğrulukları karşılaştırılmıştır. Önerilen bu 3 yöntemin kullandığı parametrelere farklı değerler atanarak bölütleme sonuçları incelenmiş ve HSG'lerin ortalama BD'sini arttırmak amacıyla ilgili parametrelerin nasıl seçilmesi gerektiği tartışılmıştır. Önerilen yöntemler hem hiperspektral hem de LiDAR verilerinden oluşan MUUFL Gulfport gerçek veri kümesine uygulanmış ve bölütleme sonuçları karşılaştırılmıştır.

SMTNcut yönteminin özvektör sayısının bölütleme doğruluğu üzerinde kritik öneme sahip olduğu gösterilmiştir. Özvektör sayısının uygun seçilmemesinin görüntüyü az veya fazla bölütlere ayırdığı veri kümesi üzerinden gösterilmiştir. Ancak, bu sayının görüntü hakkında bilgi sahibi olmadan uygun olarak belirlenmesinin zor olduğu anlaşılmıştır. Diğer yandan, benzeşim matrisi oluştururken r parametresinin (kaç adet komşu piksel arasındaki kenar ağırlığının hesaplanacağı) farklı değerleri için sonuçların ortalama BD'si hesaplanmıştır. Sonuçlara göre r arttırıldıkça doğal olarak bölütleme doğruluğunun da arttığı gözlemlenmiştir. Ancak, r 'nin arttırılması beraberinde işlem yükünü de arttırdığından algoritma hızını düşürmektedir. İşlem yükü ve ortalama BD göz önüne alınarak uygun bir değer atanması anlaşılmıştır ve bu tezdeki veriler için $r = 10$ olarak en iyi performans verdiği gözükmemektedir.

Spektral bölütleme sonucu elde edilen özvektörler görüntüdeki nesnelerin kenar bilgisi içerdiği bilinmektedir. HSG'lere ek olarak LiDAR verilerin de bölütlemeye kullanılması özellikle bir yüksekliğe sahip olan nesnelerde kenar bilgisini iyice belirginleştirdiği sonuçlar üzerinden görülmüştür. SMTNcut yöntemindeki özdeğer sayısı belirlemedeki zorluğu ortadan kaldırmak amacıyla SET ve PMITNcut yöntemlerde belli sayıda özvek-

tör, sPb algoritmasıyla birleştirilerek öncelikle kenar bilgisi oluşturulmuş ve OWT-UCM algoritmasıyla bölütler elde edilmiştir. Görüntünün kenar bilgisi oluşturulduktan sonra UCM'nin farklı eşik değeri için farklı sayılarda bölüt sayısı elde etmek mümkün hale gelmiştir. Ayrıca, SMTNcut yönteminde görüntüdeki tekdüze büyük alanlar yanlış bölütlenirken, sPb+UCM yöntemi kullanıldığında bu sorunun ortada kalktığı gözükmiştir.

SET yöntemiyle spektral veriler ile uzamsal-yükseklik verileri α parametresinin farklı değerleriyle ağırlıklandırılmış ve bölütleme sonuçlarına etkisi incelenmiştir. Sonuçlardan anlaşıldığı gibi α sıfıra yaklaştıkça bölütleme sonuçları spektral bilgilere göre şekillenirken, α arttırıldığında ise uzamsal-yükseklik bilgilerine göre şekillendiği gözlemlenmiştir. Veri kümesi üzerindeki denemeler sonucunda α 3-4 değerleri arasında en yüksek bölütleme doğruluğu ulaştığına anlaşılmıştır. Bu parametrenin daha fazla artırılması çizge-
deki spektral bilgilerin ağırlığını uzamsal-yükseklik bilgilerine göre azalttığından, bunun sonucundan bölütleme yönteminin spektral ayrıştırma gücünü de düşürdüğü gözlemlenmiştir. Bunun sebebi, bölütlemenin spektral bilgilerden ziyade uzamsal ve yükseklik bilgileri ışığında bölütlenmesidir.

PMITNcut yönteminde ise benzeşim matrisi, bilgilerin birlikte bulunma olasılıklarına göre hesaplandığından pikseller arasında daha güçlü bağlar oluşturduğu açıktır. Bu yöntemin bölütleme sonuçlarına katkısını ve başarısı arttırmak amacıyla hiperspektral ve LiDAR verileri bazı ön işlemlerden geçirilmiştir. Gerek bölütleme sonuçlarına gerekse ortalama BD'lere bakıldığında, PMITNcut yönteminin üstün performans sergilediği anlaşılmaktadır. Özellikle, görüntüdeki nesnelerin spektral olarak son derece başarılı bir şekilde ayrıştırdığı ortalama BD sonuçlarında gözükmektedir.

Son olarak, LiDAR verilerinin bölütlemeye sağladığı katkıyı görmek amacıyla yükseklik bilgisi kullanmayan SM [38] ve GB [26] yöntemleri ve önerilen PMITNcut yöntemi yükseklik bilgisi kullanılmadan üzerinde çalışılan veri kümesine uygulanmış ve bölütleme sonuçları oluşturulmuştur. Sonuçlar incelendiğinde, önerilen yöntemlerde LiDAR verilerinin kullanılması görüntüdeki nesnelerin daha iyi yorumlanmasını sağladığı açıktır. LiDAR verileri yardımıyla, yakın spektral özelliklere sahip ancak yükseklikleri farklı olan nesnelerin (ağaçlar ve çimenler) bölütleme başarısının arttırdığı gözlemlenmiştir. Görüntüdeki binalar ile gölgelerinin de başarılı bir şekilde ayrıştırıldığı sonuçlardan an-

lařılmaktadır. Önerilen üç yöntemde de LiDAR verileri kullanıldığında sonuçların ortalama BD'leri yükseldiđi gözükmemektedir. Yani, LiDAR kullanılması görüntüdeki nesnelerin spektral olarak ayrıştırmasını iyileştirilmiştir. Çünkü yükseklik bilgisi yardımıyla eksik, fazla veya yanlış bölütler en aza indirgenmiştir.



KAYNAKLAR

- [1] Schott, J. R., *Remote sensing: the image chain approach*, 2. Edition, Oxford University Press, New York, **2007**.
- [2] Pelton, J. N., Madry, S., Camacho-Lara, S., *Handbook of satellite applications*, Springer Publishing Company, Incorporated, **2012**.
- [3] Ustin, S. L., Rencz, A. N., *Manual of remote sensing, remote sensing for natural resource management and environmental monitoring*, 3. Edition, United States: Wiley, New York, **2004**.
- [4] Anderson, J. R., Hardy, E. E., *A land use and land cover classification system for use with remote sensor data: Usgs professional paper 964*, United States: Bibliogov, **2013**.
- [5] Gurton, K., Felton, M., Remote detection of buried land-mines and IEDs using LWIR polarimetric imaging, *Optics Express*, 20, 22344 - 22359, **2012**.
- [6] Prost, G. L., *Remote sensing for geologists: a guide to image interpretation*, Taylor and Francis Inc., London, **1994**.
- [7] Schultz, G. A., Engman, E. T., *Remote sensing in hydrology and water management*, Springer-Verlag Berlin and Heidelberg GmbH and Co. K, Berlin, **2000**.
- [8] Steven, M. D., Clark, J. A., *Applications of remote sensing in agriculture*, Elsevier, **2013**.
- [9] Chen, X. L., Zhao, H. M., Li, P. X., Yin, Z. Y., Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes, *Remote Sensing of Environment*, 104, 133 - 146, **2006**.
- [10] Maktav, D., Erbek, F. S., Jürgens, C., Remote sensing of urban areas, *International Journal of Remote Sensing*, 26, 655 - 659, **2005**.
- [11] Gerçek D., Çeşmeci D., Güllü M. K., Ertürk A., Ertürk S., Hiperspektral görüntüleme ve görüntü işlemenin bugünü, yakın geleceği ve mevcut araştırma eğilimleri, *XYZ Dergi*, 18 - 25, **2013**.
- [12] Manolakis, D., Marden, D., Shaw, G. A., Hyperspectral image processing for automatic target detection applications, *Lincoln Laboratory Journal*, 14, 79 - 116, **2003**.
- [13] Remote Sensing Branch, <https://lasersdbw.larc.nasa.gov/tutorials/lidar/> (Nisan, **2017**).
- [14] Ghamisi, P., Dalla Mura, M., Benediktsson, J. A., A survey on spectral-spatial classification techniques based on attribute profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 53, 5, 2335 - 2353, **2015**.

- [15] Licciardi, G., Marpu, P. R., Chanussot, J. , Benediktsson, J. A., Linear versus nonlinear pca for the classification of hyperspectral data based on the extended morphological profiles, *IEEE Geoscience and Remote Sensing Letters*, 9, 3, 447 - 451, **2012**.
- [16] Villa, A., Benediktsson, J. A., Chanussot, J., Jutten, C., Hyperspectral image classification with independent component discriminant analysis, *IEEE Transactions on Geoscience and Remote Sensing*, 49, 12, 4865 - 4876, **2011**.
- [17] Khodadadzadeh, M. Li, J., Plaza, A., Ghassemian, H., Bioucas-Dias, J. M., Li, X., Spectral-spatial classification of hyperspectral data using local and global probabilities for mixed pixel characterization, *IEEE Transactions on Geoscience and Remote Sensing*, 52, 10, 6298 - 6314, **2014**.
- [18] Soltani-Farani, A., Rabiee, H. R., Hosseini, S. A. Spatial-aware dictionary learning for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 53, 1, 527 - 541, **2015**.
- [19] Pabitra, M., Shankar B. U., Sankar, K. P., Segmentation of multispectral remote sensing images using active support vector machines, *Pattern Recognition Letters*, 25, 1067 - 1074, **2004**.
- [20] Tarabalka Y., Chanussot J., Benediktsson J. A., Segmentation and classification of hyperspectral images using minimum spanning forest grown from automatically selected markers, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 40, 5, 1267 - 1279, **2010**.
- [21] Tarabalka, Y., Chanussot, J., Benediktsson, J. A., Segmentation and classification of hyperspectral images using watershed transformation, *Pattern Recognition*, 43, 7, 2367 - 2379, **2010**.
- [22] Tarabalka, Y., Tilton, J. C., Benediktsson, J. A., Chanussot, J., A marker-based approach for the automated selection of a single segmentation from a hierarchical set of image segmentations, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5, 1, 262 - 272, **2012**.
- [23] Sarkar, A., Biswas, M. K., Kartikeyan, B., Kumar, V., Majumder, K. L., Pal, D. K., A MRF model-based segmentation approach to classification for multispectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 40, 5, 1102 - 1113, **2002**.
- [24] Mughees, A., Chen, A., Tao, L., Unsupervised hyperspectral image segmentation: merging spectral and spatial information in boundary adjustment, *55th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, Tsukuba, 1466 - 1471, **2016**.

- [25] Veganzones, M. A., Tochon, G., Dalla-Mura, M., Plaza, A. J., Chanussot, J., Hyperspectral image segmentation using a new spectral unmixing-based binary partition tree representation, *IEEE Transactions on Image Processing*, 23, 8, 3574 - 3589, **2014**.
- [26] Gillis, D. B., Bowles, J. H., Hyperspectral image segmentation using spatial-spectral graphs, *SPIE Defense, Security, and Sensing*, International Society for Optics and Photonics and Remote Sensing, **2012**.
- [27] Pesaresi, M., Benediktsson, J. A., A new approach for the morphological segmentation of high-resolution satellite imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 39, 309 - 320, **2001**.
- [28] Guo, B., Gunn, S. R., Damper, R. I., Band selection for hyperspectral image classification using mutual information, *IEEE Geoscience and Remote Sensing Letters*, 3, 4, 522 - 526, **2006**.
- [29] Ertürk, A., Ertürk, S., Unsupervised segmentation of hyperspectral images using modified phase correlation, *IEEE Geoscience and Remote Sensing Letters*, 3, 4, 527 - 531, **2006**.
- [30] Acito, N., Corsini, G., Diani, M., An unsupervised algorithm for hyperspectral image segmentation based on the gaussian mixture model, *Geoscience and Remote Sensing Symposium, IEEE International, IGARSS'03*, Toulouse-France, 6, 3745 - 3747, **2003**.
- [31] Benedetto, J., Czaja, W., Dobrosotskaya, J., Doster, T., Duke, K., Gillis, D., Semi-supervised learning of heterogeneous data in remote sensing imagery," *SPIE Independent Component Analyses, Compressive Sampling, Wavelets, Neural Net, Biosystems, and Nanoengineering X*, 8401, 840104 - 840104 - 12, **2012**.
- [32] Cahill, N. D., Czaja, W., Messinger, D. W., Schroedinger eigenmaps with non-diagonal potentials for spatial-spectral clustering of hyperspectral imagery, *SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XX*, 9088, 908804 - 908804 - 13, **2012**.
- [33] Dalponte, M., Bruzzone, L., Gianelle, D., Fusion of hyperspectral and LiDAR remote sensing data for classification of complex forest areas, *IEEE Transactions on Geoscience and Remote Sensing*, 46, 5, 1416 - 1427, **2008**.
- [34] Huang, R., Zhu, J., Using random forest to integrate lidar data and hyperspectral imagery for land cover classification, *IEEE International Geoscience and Remote Sensing Symposium, IGARSS'13*, Melbourne, 3978 - 3981, **2013**.
- [35] Liao, W., Pižurica, A., Bellens, R., Gautama, S., Philips, W., Generalized graph-based fusion of hyperspectral and LiDAR data using morphological features," *IEEE Geoscience and Remote Sensing Letters*, 12, 3, 552 - 556, **2015**.

- [36] Von Luxburg, U., A tutorial on spectral clustering, *Statistics and computing*, 17, 4, 395 - 416, **2007**.
- [37] Wu, Z., Leahy, R., An optimal graph theoretic approach to data clustering: theory and its application to image segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15, 11, 1101 - 1113, **1993**.
- [38] Shi, J., Malik, J., Normalized cuts and image segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22, 8, 888 - 905, **2000**.
- [39] Golub, G.H., Van Loan, C.F., *Matrix Computations*, John Hopkins Press, **1989**.
- [40] Yu, S. X., Shi, J., Multiclass spectral clustering, *In International Conference on Computer Vision*, **2003**.
- [41] Arbeláez, P., Maire, M., Fowlkes, C., Malik, J., Contour detection and hierarchical image segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33, 5, 898 - 916, **2011**.
- [42] Arbeláez, P., Boundary extraction in natural images using ultrametric contour maps, *Conference on Computer Vision and Pattern Recognition Workshop, CVPRW'06*, 182 - 182, **2006**.
- [43] Belkin, M. and Niyogi, P., Laplacian eigenmaps for dimensionality reduction and data representation, *Neural computation*, 15, 6, 1373 - 1396, **2003**.
- [44] Czaja, W., Ehler, M., Schroedinger eigenmaps for the analysis of biomedical data, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35, 1274 - 1280, **2013**.
- [45] Hou, B., Zhang, X., Ye, Q., Zheng, Y., A novel method for hyperspectral image classification based on Laplacian eigenmap pixels distribution-flow, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6, 3, 1602 - 1618 **2013**.
- [46] Church, K.W., Hanks, P., Word association norms, mutual information, and lexicography, *Computational linguistics*, 16, 1, 22 - 29, **1990**.
- [47] Chambers, N., Jurafsky, D., Unsupervised learning of narrative event chains. *In ACL*, 789 - 797, **2008**.
- [48] Bengio, S., Dean, J., Erhan, D., Ie, E., Le, Q., Rabinovich, A., Shlens, J., Singer, Y., Using web co-occurrence statistics for improving image categorization, *arXiv preprint arXiv:1312.5697*, **2013**.
- [49] Isola, P., Zoran, D., Krishnan, D., and Adelson, E. H., Crisp boundary detection using pointwise mutual information, *In European Conference on Computer Vision*, Springer International Publishing, 799 - 814, **2014**.

- [50] Torun, O., Yüksel, S. E., Hyperspectral image segmentation using normalized cuts, *24th Signal Processing and Communication Application Conference (SIU)*, Zonguldak, 1717 - 1720, **2016**.
- [51] Torun, O., Yüksel, S. E., Using k-way normalized cuts to integrate LiDAR and hyperspectral imagery for segmentation, *Hyperspectral Imaging and Sounding of the Environment*, Optical Society of America, HTu3D.2, **2016**.
- [52] Torun, O., Yüksel, S. E., LiDAR aided hyperspectral images segmentation using schroedinger eigenmaps, *25th Signal Processing and Communication Application Conference (SIU)*, Antalya, 1 - 4, **2017**.
- [53] Torun, O., Yüksel, S. E., Unsupervised segmentation of lidar fused hyperspectral imagery using pointwise mutual information, *unpublished*.
- [54] Ifarraguerri A., Chang, C. I., Unsupervised hyperspectral image analysis with projection pursuit, *IEEE Transactions on Geoscience and Remote Sensing*, 38, 6, 2529 - 2538, **2000**.
- [55] Gader, P., Zare, A., Close, R., Aitken, J., Tuell, G., *MUUFLL gulfport hyperspectral and LiDAR airborne data set*, Technical Report, REP-2013-570, University of Florida, Gainesville, FL, **2013**.
- [56] Du, X., Zare, A., *Scene label ground truth map for MUUFLL Gulfport data set*, Technical Report, 20170417, University of Florida, Gainesville, FL, **2017**.
- [57] Van der Meer, F., The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery, *International Journal of Applied Earth observation and Geoinformation*, 8, 1, 3 - 17, **2006**.

EKLER

EK 1: SÖZLÜK DİZİNİ

Belirsiz Çokterimli Tam	: Nondeterministic Polynomial Complete
Benzerlik Çizgesi	: Similarity Graph
Benzerlik Matrisi	: Affinity Matrix
Boğum	: Node
Bölütleme	: Segmentation
Bölütleme Doğruluğu	: Segmentation Accuracy
Çekirdek Yoğunluk Kestirimi	: Kernel Density Estimation
Çok Bantlı	: Multispectral
Doğruluk Haritası	: Ground Truth
Düzgelenmiş Kesit	: Normalized Cut
Eşik Değeri	: Threshold
Görünür ve Yakın Kızılötesi	: Visible and Near Infrared
Karşılıklı bilgi	: Mutual Information
Kenar	: Edge
k-ortalamalar	: k-means
Laplacian Özharitaları	: Laplacian Eigenmaps
Lazerle Tespit ve Menzil Tayini	: Light Detection and Ranging
Morötesi	: Ultraviolet
Nokta Tabanlı Karşılıklı Bilgi	: Pointwise Mutual Information
Orta-Dalga Kızılötesi	: Mid-Wave Infrared
Ön İşleme	: Preprocessing
Özdeğer	: Eigenvalue
Özvektör	: Eigenvector
Özyinelemeli	: Recursive
Schroedinger Özharitaları	: Schroedinger Eigenmaps
Sentetik Açıklık Radarı	: Synthetic Aperture Radar
Seyrek	: Sparse
Spektral Ayırıştırma Gücü	: Power of Spectral Discrimination

Spektral Bölütleme	: Spectral Clustering
Spektral Sınır Olsılığı	: Spectral Probability of Boundary
Tek Bağlı	: Single Linkage
Temel Bileşen Analizi	: Principle Component Analysis
Temsilci İmza	: Representative Signature
Tutarlı	: Coherent
Ultrametrik Kontur Haritası	: Ultrametric Contour Map
Uzaktan Algılama	: Remote Sensing
Uzamsal	: Spatial
Uzun-Dalga Kızılötesi	: Long-Wave Infrared
Yönlendirilmiş Havza Dönüşümü	: Oriented Watershed Transform
Yönlü Türev	: Directional Derivative

Düzgelenmiş Kesit Kullanarak Hiperspektral Görüntülerin Bölütlenmesi

Hyperspectral Image Segmentation Using Normalized Cuts

Orhan Torun^{1,2}, Seniha Esen Yüksel¹

¹Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye

²TÜBİTAK BİLGEM/İLTAREN, Ankara, Türkiye

orhan.torun@tubitak.gov.tr,

eyuksel@ee.hacettepe.edu.tr

Özetçe— Hiperspektral görüntülerde (HSG) birbirine fiziksel olarak yakın ve spektral olarak benzer olan alanların kümelenmesi, sınıflandırmadan hedef tesbitine birçok alanda kullanılmaktadır. Bu bildiride, düzgelenmiş kesit algoritması HSGler için geliştirilmiştir. Düzgelenmiş kesit algoritmasında kullanılan benzeşim matrisi, hem uzamsal hem de spektral bilgileri kullanacak şekilde oluşturulmuş, daha sonra da spektral kümeleme yöntemleriyle çözümlenmiştir. Benzeşim matrisinde kullanılan parametreler değiştirilerek, bu parametrelerin bölütlemeye olan etkileri incelenmiştir. Sonuçlar, önerilen yöntem ile görüntülerdeki farklı spektral özelliklere sahip olan materyallerin ayırt edilebildiğini ve aranan hedeflerin belirlenebildiğini göstermektedir.

Anahtar Kelimeler — hiperspektral görüntü; spektral-uzamsal bölütleme; çizge, düzgelenmiş kesit.

Abstract— The segmentation of hyperspectral images based on spatial and spectral information is being used in many fields from target detection to classification. In this paper, the normalized cuts algorithm is extended for the segmentation of hyperspectral images. The affinity matrix of the normalized cuts algorithm is modified such that it uses both the spatial and spectral information. The effect of the parameters on the segmentation results is investigated, and it is shown that with proper parameter selection, the proposed method can segment the spectrally similar materials, and also extract the targets that we are after.

Keywords — hyperspectral image; spectral-spatial segmentation; graph; normalized cuts.

I. GİRİŞ

Farklı nesneler değişik dalga boylarında ışığı farklı şekillerde yansıtır. Her nesnenin ışığı yansıma özelliği kendisine ait spektral imzasını oluşturur. Hiperspektral kameralar, çok sayıda dalga boyunda nesnelerin ışığı ne

kadar yansıtıklarını ölçerler [1]. Yüzlerce dalga boyuna bakıldığında, hiperspektral görüntülerden her bir pikselde hangi materyal olduğu anlaşılabilir. HSG sınıflandırma ve bölütleme, uzaktan algılama ile görüntüleme alanında araştırılan önemli bir konu haline gelmiştir. Savunma sanayi, maden haritalama, tarım denetimi, çevre izleme gibi alanlarda uygulama bulunmaktadır. Bu bildiride, uzamsal ve spektral bilgi kullanılarak HSGlerin bölütlenmesi gerçekleştirilmiştir. Görüntü bölütleme için düzgelenmiş kesit algoritması kullanılmıştır.

Bildirinin akışı şöyledir: II. bölümde çizge (graph) teorisi ve düzgelenmiş kesit algoritması özetlenmiştir. III. bölümde düzgelenmiş kesit algoritmasında kullanılan, hem uzamsal hem de spektral bilgi yardımıyla elde edilen benzeşim matrisi anlatılmıştır. IV. bölümde ise kullanılan hiperspektral veriler tanıtılmış ve sonuçlar verilmiştir.

II. TEORİ


A. Çizge Teorisi

Bir $G = (V, E)$ çizgesi, V boğumlarının E kenarları ile birleştirilmesi sonucunda oluşturulur. Şekil 1’de A ve B sınıflarından oluşan çizgede, boğumlar ve bu boğumları birbirine bağlayan kenarlar görülmektedir. Her bir boğumu birbirine bağlayan kenarlara bir ağırlık verildiğinde, bu çizgeye ağırlandırılmış çizge denilmektedir. Şekilde gözüktüğü gibi i ve j adındaki iki boğumu bağlayan kenar ağırlıkları $w(i,j)$ ile ifade edilmektedir. Bu ağırlıklar boğumların birbirine olan benzerlikleri kullanılarak hesaplanmaktadır. Birbirine benzeyen boğumların kenar ağırlıkları diğer ağırlıklardan daha fazla olur. Görüntülerde ise bu boğumlar pikselleri veya süper pikselleri ifade etmektedir. Pikseller arasındaki uzamsal benzerlik, renk benzerliği, parlaklık benzerliği ve

bu bildiride de bahsedilen spektral benzerlikler kullanılarak çizgedeki ağırlıklar hesaplanmaktadır. Buradaki temel amaç denklem (1)'de verilen ifadeyi minimize ederek çizgeyi iki farklı gruba ayırmaktır [2].

$$\min cut(A, B) = \sum_{i \in A, j \in B} w(i, j) \quad (1)$$

Denklem (1)'e göre, i boğumları A sınıfında ve j boğumları B sınıfında kalacak şekilde, pikseller boğumlar arasındaki ağırlıkların en küçük olduğu kenarlardan ayrılırlar. Böylece birbirine benzeyen pikseller gruplandırılmış ve diğerlerinden ayrılmış olur.



Şekil 1. Çizgeyi oluşturan boğumlar, kenarlar ve kenar ağırlıkları

Fakat, çizgedeki uç boğumların kesit (cut) değeri küçük olduğundan denklem (1)'in sonucunda uç boğumlar yanlış sınıflandırılabilmektedir. Bunu önlemek amacıyla düzgelenmiş kesit yöntemi geliştirilmiştir [3].

B. Düzgelenmiş Kesit Algoritması

Yukardaki bölümde bahsedildiği gibi uç boğumların kesit değeri küçük olmasını önlemek amacıyla (1)'deki denklemin düzgelenmesi gerekmektedir. Bu kesit değeri, A ve B'deki boğumlar ile çizgedeki tüm boğumları birleştiren kenar ağırlıkları toplamını ifade eden denklem (3) ile düzgelenirse, denklem (2)'de verilen düzgelenmiş kesit maliyeti elde edilmektedir [3].

$$Ncut(A, B) = \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)} \quad (2)$$

ve

$$assoc(A, V) = \sum_{i \in A, j \in V} w(i, j) \quad (3)$$

burada V çizgedeki tüm boğumları ifade etmektedir.

Düzgelenmiş kesit yöntemi, pikselleri aralarındaki bağların kuvvetine göre gruplarken, A ve B gibi gruplar arasındaki ayrımı azaltıp, grupların kendi içindeki ilişkiyi arttırmayı amaçlar [3]. Bunu gerçekleştirmek için düzgelenmiş kesit maliyetinin minimize edilmesi gerekir. Düzgelenmiş kesit maliyetini minimize eden çözüm, (4)'te yer alan denklemin özdeğer ve özvektörlerinin bulunması ile elde edilir.

$$(D - W)y = \lambda Dy \quad (4)$$

W matrisi, benzeşim matrisi olarak da adlandırılır ve her bir indisi i, j boğumlarını birleştiren $w(i, j)$ ile ifade ettiğimiz kenarın ağırlığıdır. Bu bildiride, temel amaç HSGlerin uzamsal ve spektral bilgileri kullanılarak bu benzeşim matrisinin oluşturulmasıdır. D köşegenleri benzeşim matrisinin satırlarının veya sütunlarının toplamıyla oluşturulmuş bir matristir ve denklem (5)'teki gibi hesaplanır. y ise boğumların boyutunda bir indikatör vektördür ve i boğumu A'da ise $y_i=1$, değilse $y_i=-1$ değerini alır. $D - W$ matrisi de Laplas matrisi olarak adlandırılır.

$$D(i, i) = \sum_j W(i, j) \quad (5)$$

Denklem (4)'ün özvektörleri kullanılarak çizge iki yöntemle bölünebilir. Birinci yöntemde, en küçük ikinci özdeğere karşılık gelen özvektör kullanılarak çizge önce iki gruba ayrılır ve ayrılan gruplar yeni çizge olarak düşünülüp, özyenilemeli (recursive) olarak bölümlenmeye devam edilir. İkinci yöntemde ise, çizge kaç bölüme ayrılmak isteniyorsa o kadar özvektör kullanılır. Bu bildiride, HSG bölütlenmesinde ikinci yöntem kullanılmıştır ve aşağıdaki basamaklar takip edilmiştir:

- HSGlerden $G=(V, E)$ çizgesi oluşturulur, W benzeşim matrisi ve D matrisi hesaplanır,
- Denklem (4)'ten en küçük özdeğerlere karşılık gelen bölüt sayısı kadar özvektör hesaplanır,
- Eşik değeri belirlenir ve bu değer kullanılarak her bir özvektörün girdileri iki kısma ayrılır,
- Hesaplanan özvektörler, görüntüyle aynı boyuta çevrilip birleştirildikten sonra kenar bulma algoritmasından geçirilerek görüntü bölütlere ayrılır.

III. HİPERSPEKTRAL GÖRÜNTÜLER İÇİN BENZEŞİM MATRİSİ HESAPLAMA

Önceki bölümde bahsedilen düzgelenmiş kesit yönteminde önemli olan faktör benzeşim matrisinin probleme uygun olarak dizayn edilmesidir. Bu bildiride, uzamsal ve spektral bilgiler kullanılarak denklem (6)'da verilen form kullanılacaktır.

$$W(i, j) = e^{-\frac{d_{\text{spektral}}(i, j)}{\sigma_{\text{spektral}}}} * \left\{ e^{-\frac{d_{\text{uzamsal}}(i, j)}{\sigma_{\text{uzamsal}}}} \text{ eğer } d_{\text{uzamsal}} < r \right. \\ \left. 0 \text{ aksi taktirde} \right\} \quad (6)$$

Burada d_{uzamsal} , denklem (7)'de verilen şekilde hesaplanır. Bu denklemde $K(i)$ ve $K(j)$ görüntüdeki piksellerin konumunu gösteren vektörlerdir. Buna göre iki piksel birbirine çok uzaksa, aralarındaki kenar ağırlığına sıfır değeri atanır. Birbirlerine yakın iseler, aralarındaki uzaklığa ters orantılı olarak kenarın ağırlığı azalacaktır.

$$d_{\text{uzamsal}}(i, j) = \|K(i) - K(j)\|^2 \quad (7)$$

d_{spektral} ise iki spektra arasındaki Öklid uzaklığını ifade eder ve (8)'deki gibi hesaplanır:

$$d_{\text{spektral}}(i, j) = \|F(i) - F(j)\|^2 \quad (8)$$

Burada $F(i)$ ve $F(j)$, i ile j piksellere ait farklı dalga boylarındaki spektral bilgiyi içeren vektörlerdir.

Bölüm IV'te algoritmanın performansı σ_{uzamsal} , σ_{spektral} ve r değişkenleri için farklı değerler kullanılarak değerlendirilmektedir.

IV. KULLANILAN VERİLER VE SONUÇLAR

A. Hiperspektral Veriler

Bu çalışmada MUUFL Gulfport veri koleksiyonu kullanılmıştır [4]. Veriler 3500 feet ve 6700 feet'ten uçularak Southern Mississippi kampüsü üzerinden toplanmıştır. Alçaktan uçularak toplanan verilerde bir piksel $0.6\text{m} \times 1.0\text{m}$ 'lik alana; yüksekten uçularak toplanan verilerde ise bir piksel $1.0\text{m} \times 1.0\text{m}$ 'lik bir alana karşılık gelmektedir. Kampüse farklı renklere ve farklı boyutlara sahip toplamda 57 tane hedef yerleştirilmiştir. Yerleşkenin uçakla çekilmiş KYM (Kırmızı-Yeşil-Mavi) fotoğrafı Şekil 2'de verilmiştir. Toplanan hiperspektral görüntülerin (HSG) özellikleri Tablo 1'de verilmiştir.




Şekil 2. Mississippi Üniversitesi Güney Yerleşkesi

Parametre	Değeri
Dalga boyu	375-1050 nm
Spektral bant sayısı	72
Bant genişliği	10 nm

Tablo 1. CASI-1500 Hiperspektral Görüntüleyici Parametreleri.


B. Benzetim Sonuçları

Benzetim için Şekil 2'de verilen görüntüden seçilen bir alanın hiperspektral verileri kullanarak benzeşim matrisi oluşturulmuş ve bu benzeşim matrisine bağlı olarak (4)'te verilen denklemin özvektörleri bulunarak görüntünün bölütlenmesi yapılmıştır. Kullanılan hiperspektral verinin 3 dalga boyu (725nm-555nm-475nm) birleştirilerek elde edilen RGB görüntüsü Şekil 3(a)'da ve tek dalga boyu (975nm ve 475nm) kullanılarak oluşturulan griölçek görüntüsü Şekil 3(b)'de ve Şekil 3(c)'de görülmektedir.




Şekil 3. (a) Hiperspektral verilerin farklı 3 dalga boyundaki görüntüleri birleştirilmesiyle oluşturulan RGB görüntüsü, (b)-(c) tek dalga boyuyla elde edilen griölçek görüntüsü

Benzeşim matrisini oluşturmak için görüntülerde yer alan her bir piksel boğum olarak seçilmiş ve denklem (6)'da olduğu gibi hesaplanmıştır. Hesaplama yapılırken $\sigma_{\text{uzamsal}}=10$, $\sigma_{\text{spektral}}=0.2$ ve $r=5$ olarak seçilmiştir. Bu seçime göre elde edilen benzeşim matrisi Şekil 4'te verilmiştir. Şekilde de gözüktüğü gibi benzeşim matrisi seyrek (sparse) bir matristir. Yani köşegen ve köşegen çevresindeki bantta yer alan girdiler dışında kalan tüm değerler sıfırdır. Aynı zamanda benzeşim matrisi simetrik bir matristir. Kullanılan görüntü 76×76 boyutlarında olduğundan, yani çizge toplamda 5776 boğumdan oluşmaktadır, oluşturulan benzeşim matrisi 5776×5776 boyutlarındadır.




Şekil 4. Uzamsal ve spektral bilgiler kullanılarak oluşturulan benzeşim matrisi

Oluşturulan benzeşim matrisini kullanarak denklem (4)'ün özvektörleri hesaplanmış ve elde edilen özvektörlerin dört tanesinin görüntünün boyutlarına dönüştürülmüş halleri Şekil 5'te verilmiştir. Şekilde gözüktüğü gibi her bir özvektör görüntünün belirli alanlarını diğer alanlardan ayırmaktadır. Ancak, bazı bölgeler arasındaki geçişler daha yumuşak olduğundan bölütleme zorlaşmaktadır. Geçiş sınırlarını keskinleştirmek için her özvektör belirlenen eşik değere göre ayrık hale getirilir.



Şekil 5. Görüntü boyutlarına dönüştürülmüş ilk 4 özvektör

Oluşturulan bu 4 özvektör hesaplanan eşik değeri ayırık bölgelere ayrılıp birleştirildikten sonra görüntü bölütleri bulunmaktadır. $r=5$ ve $r=10$ değerleri için, sadece bu 4 özvektör kullanılarak görüntünün bölütlenmiş hali Şekil 6'da verilmiştir.




Şekil 6. Dört özvektör kullanılarak görüntünün bölütlenmesi

Şekil 6(a) ile Şekil 6(b) karşılaştırıldığında, r değerinin artırılmasıyla bölütlemenin iyileştiği gözükmetedir. Ancak, r 'nin artması daha çok pikselin arasındaki kenar ağırlıklarının hesaplanmasını gerektirdiğinden, benzeşim matrisi oluşturma işlem yükü de buna bağlı olarak artmaktadır. Ayrıca, r 'nin artırılması ile Şekil 6'da gözüktüğü gibi birbirine yakın olan hedeflerin ayrılma problemi oluşmaktadır. Bunu önlemek için r 'nin seçiminde hedeflerin boyutlarının dikkate alınması ve/veya $\sigma_{uzamsal}$, $\sigma_{spektral}$ parametrelerinin uygun seçilmesi gerekmektedir. $\sigma_{uzamsal}$ ve $\sigma_{spektral}$ parametrelerinin artırılması pikseller arasındaki benzerlik geçişlerini yumuşattığından, bölütleme sonucunu iyileştirmektedir. Fakat; çok artırılmaları, farklı uzamsal ve spektral özelliklere sahip piksellerin benzerliğini de arttıracığından bölütlemeyi negatif yönden etkilemektedir. Tablo 2'de farklı r , $\sigma_{uzamsal}$ ve $\sigma_{spektral}$ parametreleri için Matlab'da oluşturulan benzeşim matrisi süreleri verilmiştir ve Şekil 8'de bu parametreler kullanılarak elde edilen bölütleme gözükmetedir. Parametrelerin uygun seçilmesiyle, Şekil 7(c)'deki bölütlemenin Şekil 7(a)-(b)'ye kıyasla daha iyi bir sonuç verdiği gözlemlenmektedir.

Deneme	r	$\sigma_{uzamsal}$	$\sigma_{spektral}$	Özvektör sayısı	BM oluşturma süresi(s)
(a)	3	5	0.10	10	4,064
(b)	5	10	0,10	10	12,845
(c)	10	10	0,15	10	54,397

Tablo 2. Farklı parametre değerleri için benzeşim matrisi oluşturma süresi



Şekil 7. Tablo 1'de verilen değerlere göre bölütleme sonuçları

V. SONUÇ

Şekil 3(b) ve 3(c)'de, tek bant kullanılarak oluşturulan görüntülerde, görüntünün alındığı banda bağlı olarak, bazı hedefler gözükmezken; bazıları aynı özelliklere sahipmiş gibi gözükmetedir. Bundan dolayı, sadece tek bir bant kullanarak görüntüler bölütlenmeye çalışılırsa kötü sonuçlar elde edilecekti; çünkü piksellerin sadece bir banttaki parlaklığına bakılarak bölütleme yapılacaktı. Bu bildiride, HSGlerdeki tüm bantları kullanılarak, farklı dalga boylarındaki görüntülerin spektral özellikleri göz önüne alındığı için daha iyi sonuçlar elde edilmiştir.

VI. TEŞEKKÜRLER

Bu çalışma TÜBİTAK tarafından 115E318 numaralı proje kapsamında desteklenmiştir.

KAYNAKÇA

- [1] D. Manolakis, D. Marden, and G. A. Shaw, "Hyperspectral Image Processing for Automatic Target Detection Applications", Lincoln Laboratory Journal, Vol. 14, Num. 1, 2003.
- [2] Z. Wu and R. Leahy, "An Optimal Graph Theoretic Approach to Data Clustering: Theory and Its Application to Image Segmentation", IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 15, no. 11, pp. 1,101-1,113, Nov. 1993.
- [3] J. Shi, J. Malik, "Normalized cuts and image segmentation", PAMI 22(8) (2000) 888-905.
- [4] P. Gader, A. Zare, R. Close, J. Aitken, G. Tuell, "MUUFL Gulfport Hyperspectral and LiDAR Airborne Data Set," University of Florida, Gainesville, FL, Tech. Rep. REP-2013-570, Oct. 2013.

Using k-way Normalized Cuts to Integrate LiDAR and Hyperspectral Imagery for Segmentation

Orhan TORUN, S. Esen YUKSEL

Department of Electrical and Electronics Engineering, Hacettepe University, Ankara, Turkey
orhan.torun@tubitak.gov.tr, eyuksel@ee.hacettepe.edu.tr

Abstract: The segmentation of hyperspectral images (HSIs) based on spatial and spectral information is being used in many fields from target detection to classification. In this paper, the light detection and ranging (LiDAR) data and hyperspectral imagery are integrated by using the normalized cuts algorithm for the segmentation of HSIs. The affinity matrix of the normalized cuts algorithm is modified such that it uses both the spatial-spectral information and the LiDAR data. The effect of the LiDAR data on the segmentation results is investigated, and it is shown that with proper parameter selection.

OCIS codes: 000.0000, 999.9999.

1. Introduction

Hyperspectral images (HSI) measure how much light is reflected from a material. Every material reflects light differently. These different reflections generate a spectral fingerprint for a material. When a large number of bands are considered, material can be detected by looking one pixel in HSIs. This important information has been at the many areas including the defence industry, mining, civil engineering and geology. In previous paper [1], the normalized cuts algorithm is extended for the segmentation of hyperspectral images. The affinity matrix of the normalized cuts algorithm is modified such that it uses both the spatial and spectral information.

LiDAR is a remote sensing technique that measures the elevation in a given scene. The elevation information obtained from LiDAR has been complementary to hyperspectral imagery. Using elevation map, it is possible to distinguish objects of similar material but of different elevation. Therefore, it makes great sense to combine hyperspectral data with the elevation information derived from LiDAR to increase the efficiency of HSIs segmentation.

In this paper, we aim to combine the two distinct data sources. Normalized cuts method is proposed to integrate both spatial-spectral information and elevation information.

2. Background

2.1. Graph Theory

A graph $G = (V, E)$ consists of a set of objects called vertices (V) and edges (E) that represent connections between vertices. A graph is weighted if each edge has an associated number $w_{i,j}$. In the figure 1, the graph consist of two classes that are A and B. Some node in the graph are connected each other and weighted with respect to similarity between them. if similarity of two nodes is high, weight on the edge is close to 1, otherwise it is close to 0. We aim to partition the graph into disjoint sets such as A and B. The degree of dissimilarity between two classes can be computed as total weight of edges which have been moved away. In graph theory, it is called cut.

$$cut(A, B) = \sum_{i \in A, j \in B} w_{i,j} \quad (1)$$

The optimal partitioning graph is the one that minimizes this cut value [2-3].

However, the minimum cut criteria support to cut small sets of isolated nodes in the graph. To avoid this problem, equation (1) must be adjusted.




Fig. 1. An example of weighted graph.

2.2. Normalized Cuts

As mentioned, to avoid cutting small sets of isolated nodes in graph, equation (1) is normalized. Instead of looking cut value, new measure compute the cost function as a fraction of the total edge connections between classes to all the nodes in the graph. Theoretically, it is called normalized cut (Ncut).

$$Ncut(A, B) = \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)} \quad (2)$$

and

$$assoc(A, V) = \sum_{i \in A, j \in V} w_{i,j} \quad (3)$$

Now, we aim to minimize the normalized cut value. The solution of this problem is discrete. If it is relaxed to take on real values, equation (2) can be minimized by solving general eigenvalue system that given in equation (4). $\mathbf{D}$ is an diagonal matrix with the total connection from one node to all other nodes on its diagonal, and $\mathbf{W}$ is similarity matrix whose entries compose of $w_{i,j}$.

$$(\mathbf{D} - \mathbf{W})\mathbf{y} = \lambda \mathbf{D}\mathbf{y} \quad (4)$$

In this paper, hyperspectral imagery and LiDAR data are combined to construct similarity matrix. Then, using constructed similarity matrix, we solve relaxed version of equation (4), and we seek discrete solution closest to the continuous optima in iterative manner as mentioned in [4].

3. Proposed Similarity Matrix for HSIs

Designing of the similarity matrix is critically important for image segmentation. Firstly, we construct a weighted graph, by taking each pixel as node, then connecting each pair of pixels by an edge. We use spatial-spectral information and LiDAR data to compute weight for each pair of pixels. However, all pixel pairs do not connect, just closest r pairs are connected for computational complexity. We can define edge weight that connect two nodes as follow:

$$w_{i,j} = e^{-\frac{d_{spectral}(i,j)}{\sigma_{spectral}}} * e^{-\frac{d_{LiDAR}(i,j)}{\sigma_{LiDAR}}} * \begin{cases} e^{-\frac{d_{spatial}(i,j)}{\sigma_{spatial}}} & \text{if } d_{spatial}(i,j) < r \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

In equation (5), $d_{spectral}(i,j)$, $d_{LiDAR}(i,j)$ and $d_{spatial}(i,j)$ is spectral, LiDAR and spatial Euclidean distance between node i and j , respectively. $\sigma_{spectral}$, σ_{LiDAR} and $\sigma_{spatial}$ control the scale of data similarity measure. In the simulation part, efficiency of HSIs segmentation will be discussed for different σ s value and r .

4. Data Set and Simulation Results

4.1. Data Set Description

MUUFLL Gulfport Hyperspectral and LiDAR Airborne data set used for simulation. Data were collected using a Gemini LiDAR and CASI-1500 flown in a single plane simultaneously [5].

4.2. Simulation Results

Firstly, we compute similarity matrix $\mathbf{W}$ as given equation (5). Parameters in this equation are chosen experimentally as follow: $\sigma_{spectral} = 0.3$, $\sigma_{LiDAR} = 2$ and $\sigma_{spatial} = 5$ and $r = 6$. Secondly, equation (4) are solved for 14 eigenvalues and corresponding eigenvectors. The number of eigenvectors are also chosen experimentally for better segmentation. This eigenvectors are solution of relaxed problem. We use method given in [4], discrete eigenvectors are obtained. Some of this discrete eigenvectors are given in the figure 2. This eigenvectors partition the image into disjoint sets as we have seen in the figure 2. Then, discrete eigenvectors are merged and segments of HSIs are obtained. In the figure 3, HSIs' segments that compose of 14 discrete eigenvector are shown. There are two segmented image in the figure 3. Center image is segmented by using spatial and spectral information. However, right image is segmented by using LiDAR data beside spatial and spectral information. By using LiDAR data, segmentation results have been improved. When LiDAR are used, some group of trees, some individual tree and one extra object are also segmented as seen in the figure 3.

We will discuss segmentation solution for different σ s, different r and different number of eigenvector, and simulation results these parameters will be given.



Fig. 2. Six discrete eigenvectors




Fig. 3. Left: false RGB, Center: segments of HSI without using LiDAR, Right: segments of HSI with using LiDAR

References

1. Orhan Torun, S. Esen Yuksel, "Hyperspectral Image Segmentation Using Normalized Cuts," SIU, 2016.
2. Z. Wu and R. Leahy, "An Optimal Graph Theoretic Approach to Data Clustering: Theory and Its Application to Image Segmentation", IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 15, no. 11, pp. 1,101-1,113, Nov. 1993.
3. J. Shi, J. Malik, "Normalized cuts and image segmentation", PAMI 22(8) (2000) 888-905.
4. S. X. Yu and J. Shi, "Multiclass spectral clustering", In International Conference on Computer Vision, 2003.
5. P. Gader, A. Zare, R. Close, J. Aitken, G. Tuell, "MUUFL Gulfport Hyperspectral and LiDAR Airborne Data Set", University of Florida, Gainesville, FL, Tech. Rep. REP-2013-570, Oct. 2013.

Schroedinger Özharitalar Kullanarak LiDAR Destekli Hiperspektral Görüntülerin Bölütlenmesi

LiDAR Aided Hyperspectral Images Segmentation Using Schroedinger Eigenmaps

Orhan Torun, Seniha Esen Yüksel

Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye
orhanturun@hacettepe.edu.tr,
eyuksel@ee.hacettepe.edu.tr

Özetçe —Uzamsal ve spektral bilgi tabanlı hiperspektral görüntülerin (HSG) bölütlenmesi, hedef bulma ve sınıflandırma gibi birçok alanda kullanılmaktadır. Bu bildiride, hem LiDAR verilerinden elde edilen yükseklik bilgisini hem de uzamsal-spektral bilgileri birleştirerek yeni bir Schroedinger Özharitalar (SÖ) algoritması önerilmiştir. SÖ algoritmasının potansiyel matrisi, uzamsal bileşenler arasındaki yakınlığı ve LiDAR verileri arasındaki yakınlığı birleştirilerek elde edilmiştir. Bu potansiyel matris ağırlıklandırılarak bölütleme sonuçları incelenmiştir. Ayrıca; önerilen yöntemin bölütleme sonuçları, Uzamsal-Spektral Schroedinger Özharitalar (USSÖ) algoritmasının sonuçlarıyla ve Düzgelenmiş Kesit algoritmasının sonuçlarıyla karşılaştırılmıştır.

Anahtar Kelimeler—hiperspektral görüntüler, LiDAR, schroedinger özharitalar, bölütleme.

Abstract—The segmentation of hyperspectral images (HSI) based on spatial and spectral information is being used in many fields from target detection to classification. In this paper, a new Schroedinger Eigenmaps (SE) algorithm is proposed to combine both elevation information obtained from LiDAR data and the spatial-spectral information. The potential matrix of SE algorithm is obtained by integrating the proximity between spatial components and the proximity between LiDAR data. The segmentation results are examined with weighting of this potential matrix. In addition, the segmentation results of the proposed method compares with the results of the Spatial-Spectral Schroedinger Eigenmaps (SSSE) algorithm and the results of the Normalized Cut algorithm.

Keywords—hyperspectral imagery, LiDAR, schroedinger eigenmaps, segmentation.

I. GİRİŞ

Hiperspektral görüntüleme sensörleri, insan gözünün algıladığı görünür ışıktan elde edilen RGB görüntülerinden farklı olarak çok sayıda bitişik bantta görüntü oluşturur. HSG'ler, görünür ışıktan elde edilen görüntülerden daha fazla bilgi içermektedir. Bu sebeple, HSG'lerin bölütlenmesi ve HSG'lerden hedef tespiti askeri ve sivil uygulamalarda yaygın olarak kullanılmaktadır [1]. Düzgelenmiş Kesit algoritması [2] kullanılarak uzamsal ve spektral bilgilerin birleştirilmesiyle HSG'lerin bölütlendiği çalışmalar literatürde bulunmaktadır [3], [4].

LiDAR, belirli bir alandaki yüksekliği ölçen uzaktan algılama tekniğidir. LiDAR'dan elde edilen yükseklik bilgisi, hiperspektral görüntüleri tamamlayıcı niteliktedir. Örneğin; yükseklik haritalarını kullanarak, benzer malmazeden oluşan farklı yükseklikteki nesneleri ayırmak mümkündür. Bu nedenle, HSG bölütlenmesinde LiDAR'dan türetilmiş yükseklik bilgisinin kullanılması göz önüne alınmalıdır. Uzamsal-spektral bilgiler ile yükseklik bilgisi, Düzgelenmiş Kesit algoritması yardımıyla birleştirildiğinde HSG bölütlenmesinde iyileşme sağlandığı bir önceki yayımlarımız olan [5]'te görülmektedir.

Bu çalışmada, [6]'da verilen SÖ algoritması kullanılarak HSG'lerden elde edilen spektral bilgiler ile çizge oluşturulmuş, HSG'lerin uzamsal bilgisi ile LiDAR'dan elde edilen yükseklik bilgisi potansiyel matrisiyle birleştirilip çözümlenmiştir. SÖ algoritmasının sonucunda elde edilen özvektörler, öncelikle [7]'deki spektral Pb kenar bulma yöntemi ile birleştirilerek görüntünün kenar bilgisi elde edilmiştir. Kenar bilgisi, *Ultrametric Contour Maps* (UCM) algoritmasından geçirilerek HSG'lerin bölütleri oluşturulmuştur. Uzamsal ve yükseklik bilgileri kullanılarak elde edilen potansiyel matrisinin farklı ağırlıklandırılmasıyla bölütleme sonuçları incelenmiştir. LiDAR verilerinin bölütleme üzerindeki etkisini incelemek için, sadece uzamsal ve spektral bilgileri kullanan USSÖ algoritmasıyla [8] özvektörler oluşturulmuş ve yukarıda bahsedildiği gibi, bu özvektörlerden bölütler elde edilerek sonuçlar karşılaştırılmıştır. Aynı zamanda, uzamsal-spektral ve yükseklik bilgilerini Düzgelenmiş Kesit algoritmasıyla birleştirilerek bölütleme yapan [5]'teki yöntemimizin sonuçlarıyla da karşılaştırma yapılmıştır.

Bu çalışmanın organizasyonu şu şekilde devam etmektedir: II. bölümde SÖ algoritması kısaca özetlenmiştir. III. bölümde spektral ve uzamsal bilgilere ek olarak yükseklik bilgisinin de SÖ algoritması ile birleştirilerek HSG'lerin bölütlenmesi için önerilen yeni yöntem anlatılmıştır. IV. bölümde ise kullanılan HSG verileri tanıtılmış ve bölütleme sonuçları tartışılmıştır.

II. SCHROEDINGER ÖZHARİTALAR ALGORİTMASI

SÖ algoritması, son zamanlarda HSG'lere özgü uzamsal ve spektral bilgileri birleştirerek boyut indirgeme ve kümeleme amacıyla kullanılan çizge tabanlı bir yöntemdir [3]. Temelde, Düzgelenmiş Kesit algoritmasıyla benzerdir [2]. SÖ, çizgeye bir potansiyel matrisi ekleyerek Düzgelenmiş Kesit algoritmasını geliştirir. Aynı zamanda, SÖ yüksek boyutlu verileri

düşük boyutlara düşüren doğrusal olmayan bir boyut indirgeme yöntemidir.

Bir $G = (V, E)$ çizgesi, V boğumlarının E kenarları ile birleştirilmesi sonucunda oluşturulur. HSG'lerde her bir boğum piksellerden oluşur. i ve j pikselleri arasındaki benzerliğe göre $w_{i,j}$ kenar ağırlıkları belirlenir. Bu kenar ağırlıklarını girdi olarak alan ve benzeşim matrisi olarak adlandırılan $\mathbf{W}$, spektral veriler için denklem (1)'de verilmiştir. Denklemde yer alan $\mathbf{x}_i^f$, bir pikselde yer alan tüm spektral bantları ifade etmektedir. ϵ komşuluğundaki piksellerin kenar ağırlığı denklemdeki gibi belirlenirken, bu komşuluk dışında kalan piksellerin kenar ağırlıklarına sıfır atanmaktadır.

$$\mathbf{W}_{i,j} = \begin{cases} -\frac{\|\mathbf{x}_i^f - \mathbf{x}_j^f\|_2^2}{\sigma_{spektral}^2}, & \text{eğer } (\mathbf{x}_i, \mathbf{x}_j) < \epsilon \\ 0, & \text{aksi takdirde.} \end{cases} \quad (1)$$

$\mathbf{D}$, köşegenleri her bir pikselin çizgedeki ϵ komşuluğunda yer alan tüm pikseller ile oluşturduğu kenar ağırlıklarının toplamıyla elde edilen bir diyagonal matristir ve denklem (2)'deki gibi hesaplanır.

$$\mathbf{D}_{i,i} = \sum_j \mathbf{W}_{i,j} \quad (2)$$

Denklem (3)'teki gibi hesaplanan $\mathbf{L}$ matrisi ise Laplas matrisi olarak adlandırılır.

$$\mathbf{L} = \mathbf{D} - \mathbf{W} \quad (3)$$

Tüm bu tanımlamalardan sonra, SÖ algoritmasının çözümü denklem (4)'te verilen sistemin ilk N tane küçük özdeğere (λ) karşılık gelen özvektörlerin ($\mathbf{y}$) bulunmasıyla elde edilir. Bu bildiride, bölütleme için $N = 20$ seçilmiştir.


$$(\mathbf{L} + \alpha \mathbf{P})\mathbf{y} = \lambda \mathbf{D}\mathbf{y} \quad (4)$$

Denklem (4)'te yer alan $\mathbf{P}$, diyagonal olmayan ve uzamsal bileşenler arasındaki yakınlığı kodlayan potansiyel matrisidir. $\mathbf{P}$ matrisi denklem (5)'teki gibi tanımlanmaktadır [8]. Laplas matrisinin ve potansiyel matrisinin bölütlemeye katkıları α parametresiyle ayarlanmaktadır. α 'nın değeri artırıldıkça bölütleme sonuçlarında potansiyel matrisinin etkisi de artmaktadır. HSG'lerin bölütlenmesinde, bu parametrenin uygun seçilmesi kritik önem taşımaktadır.

$$\mathbf{P} = \sum_{i=1}^k \sum_{\mathbf{x}_j \in \mathcal{N}_i^p(\mathbf{x}_i)} \mathbf{P}^{(i,j)} \cdot \gamma_{i,j} \cdot e^{-\frac{\|\mathbf{x}_i^p - \mathbf{x}_j^p\|_2^2}{\sigma_{uzamsal}^2}} \quad (5)$$

Denklem (5)'teki $\mathcal{N}_i^p(\mathbf{x}_i)$, $\mathbf{x}_i$ 'nin uzamsal bileşenlerinin ϵ komşuluğundaki uzamsal bileşenler kümesidir. $\mathbf{x}_i^p$ piksellerin uzamsal bileşenlerini göstermektedir ve $\mathbf{P}^{(i,j)}$ matrisi ise denklem (6)'da tanımlanan diyagonal olmayan matristir [8]. $\gamma_{i,j}$ ise, III. bölümde anlatıldığı gibi, piksellerin LiDAR verileri arasındaki yakınlığı kodlayacak şekilde seçilmiştir.

$$\mathbf{P}_{k,l}^{(i,j)} = \begin{cases} 1, & \text{eğer } (k,l) \in (i,i), (j,j) \\ -1, & \text{eğer } (k,l) \in (i,j), (j,i) \\ 0, & \text{aksi takdirde.} \end{cases} \quad (6)$$



Şekil 1: HSG Bölütleme Akış Şeması

III. BÖLÜTLEME YÖNTEMİ

Daha önce bahsedildiği gibi; LiDAR'dan elde edilen yükseklik bilgisi, hiperspektral görüntüleri tamamlayıcı niteliktedir. Bu çalışmada, bölütleme sonuçlarını iyileştirmek amacıyla SÖ algoritmasının potansiyel matrisinde yer alan $\gamma_{i,j}$ parametresi, denklem (7)'de gözüktüğü gibi, piksellerin yükseklik bileşenleri arasındaki yakınlık bilgisiyle oluşturulması önerilmiştir. Denklemdeki $\mathbf{x}_i^f$ pikseldeki yükseklik bileşenini göstermektedir.


$$\gamma_{i,j} = e^{-\frac{\|\mathbf{x}_i^f - \mathbf{x}_j^f\|_2^2}{\sigma_{lidar}^2}} \quad (7)$$

Denklem (4)'te verilen sistemin ilk N tane küçük özdeğere karşılık gelen özvektörler bulunduğundan sonra k -means kümeleme yöntemi uygulanarak bölütlere ayrılır [7]. Ancak, bu yöntem görüntüde tekdüze büyük alanlar olduğunda yanlış bölütlemelere sebep olmaktadır. Bundan kurtulmak için, Şekil 3'te verilen özvektörlerin kenar bilgisi taşıdığı gözüktüğünden, spektral Pb kenar bulma algoritmasıyla birleştirip sonra bölütlere ayrıştırılmıştır. Spektral Pb kenar bulma yöntemi (8)'de verilmiştir. Burada, denklem (4)'te elde edilen özvektörlerin ($\mathbf{y}_k$) yönlü türevleri alınıp özdeğerler (λ_k) ile normalleştirildikten sonra toplanarak kenarlar elde edilmektedir. Denklem (8)'de gösterildiği gibi, θ ile gösterilen farklı yönlerden alınan türevlerin en büyük değerleri alındığında kenar bulma sonuçları iyileşmektedir.

$$sPb = \max_{\theta} \sum_{k=1}^N \frac{1}{\sqrt{\lambda_k}} \nabla_{\theta} \mathbf{y}_k \quad (8)$$

Bu çalışmada, Şekil 1'de verilen akış şemasında gözüktüğü gibi, HSG ve LiDAR verilerinin birleştirilmesiyle görüntülerin bölütlenmesi sağlanmıştır. Bölütleme yaparken aşağıdaki basamaklar izlenmiştir:

- HSG'lerden $G = (V, E)$ çizgesi oluşturulur, $\mathbf{W}$ benzeşim matrisi ve $\mathbf{D}$ diyagonal matrisi hesaplanır,
- Yükseklik ve uzamsal bilgileri kullanılarak $\mathbf{P}$ potansiyel matrisi oluşturulur,
- Belirlenen α değerine göre denklem (4)'te verilen sistem en küçük N tane özdeğere karşı gelen özvektörler hesaplanır,
- Denklem 8'de verilen sPb hesaplanır,
- Belirlenen eşik değeriyle UCM algoritması çalıştırılır ve bölütler oluşturulur.



Şekil 2: Sırasıyla: Kullanılan Verinin RGB Görüntüsü, 475nm Bandı, 1075nm Bandı ve LiDAR

IV. KULLANILAN VERİLER VE SONUÇLAR

A. Kullanılan Veriler

Bu yayında bölütleme sonuçları için MUUFL Gölüport verisi kullanılmıştır [9]. Veriler Southern Mississippi kampüsü üzerinden toplanmıştır. Alçaktan uçularak toplanan verilerde bir piksel $0.6 \times 1.0 m^2$ 'lik alana; yüksekten uçularak toplanan verilerde ise bir piksel $1.0 \times 1.0 m^2$ 'lik bir alana karşılık gelmektedir. Kampüse farklı renklere ve farklı boyutlara sahip toplamda 64 tane hedef yerleştirilmiştir. HSG ve LiDAR sensör özellikleri Tablo I 'de verilmiştir.


TABLO I: HSG VE LiDAR SENSÖR PARAMETRELERİ

HSG		LiDAR	
Parametre	Değeri	Parametre	Değeri
Dalga boyu aralığı	375-1050nm	Dalga boyu	1064nm
Bant sayısı	72	Darbe Tekrarlama Frekansı	70KHz
Bant Genişliği	10nm	Tarama Frekansı	43Hz

B. Sonuçlar

Bölütleme sonuçları için yukarıda bahsedilen verinin 121×121 pikselden oluşan bölümünün HSG ve LiDAR verileri üzerinde çalışılmıştır. Denklem (1)'de verilen benzeşim matrisini oluşturmak için $\sigma_{spektral} = 1$ seçilmiştir. $\epsilon = 10$ komşuluğundaki pikseller arası ağırlıklar hesaplanmıştır. Denklem (5)'te gösterilen potansiyel matrisi oluşturulurken $\sigma_{uzamsal} = 1$, $\sigma_{lidar} = 1$ seçilmiş ve $\epsilon = 6$ komşuluğundaki uzamsal bilgiler ve bunlara karşılık gelen yükseklik bilgileri kullanılmıştır. Spektral Pb kenar bulma algoritmasındaki yönlü türevler hesaplanırken, θ 'nın $[0, \pi]$ aralığında düzgün dağılmış 8 açı değeri kullanılmıştır. Bulunan kenarlardan bölütler oluşturulurken, elde edilen tüm sonuçlar için, UCM algoritmasının kullandığı eşik değeri 0, 2 olarak belirlenmiştir. Son olarak, denklem (4)'teki α , Laplas matrisi ile potansiyel matrisin katkılarını görece ağırlıklandırarak bölütleme sonuçlarındaki değişimi gözlemek amacıyla sırasıyla 0, 2, 10 ve 50 seçilmiştir.

Şekil 2'de kullanılan verinin RGB görüntüsü, hiperspektral veriden alınan 475nm ile 1075nm bantlarındaki görüntüleri ve bu hiperspektral verilere karşılık gelen LiDAR verileri gösterilmiştir. Daha önce bahsedildiği gibi, Şekil 2'deki hiperspektral bantlara bakıldığında görüntüdeki maddelerin ışığı farklı yansıttığı gözükmemektedir. Tek bant ele alındığında; bazı maddeler, özellikle çimen ve ağaçlar, ışığı benzer yansıttığından tek bant verileriyle bunları ayırmak oldukça zorlaşmaktadır. HSG'lerdeki farklı dalga boyları malzemeleri ayırmada avantaj sağlamakla birlikte yeteri iyileştirmeleri yapamamaktadır. LiDAR verilerinden elde edilen yükseklik bilgileri yardımıyla, spektral olarak birbirlerine benzeyen ancak farklı yükseklikte bulunan maddeleri ayırmak kolaylaşmaktadır. Bu çalışmada



Şekil 3: (a) İlk Dört Özvektor, (b) Spektral Pb Kenarları


kullanılan veriler düşünüldüğünde, çimen ve ağaçları ayırmakta başarılı olduğu gözükmemektedir. Ayrıca, LiDAR yardımıyla cisimleri ve cisimlere ait gölgeleri birbirinden ayırmada önemli katkı sağlamaktadır.

Şekil 3'te, (4)'teki denklemin çözümü sonucu elde edilen ilk dört en küçük özdeğere karşılık gelen özvektörler ve bu özvektörler kullanılarak elde edilen spektral Pb sonucu verilmiştir. Şekildeki özvektörlere bakıldığında, III. bölümde de bahsedildiği gibi, her birinin kenar bilgisi taşıdığı gözükmemektedir. Literatürde, özvektörler elde edildikten sonra *k-means* gibi kümeleme algoritmaları kullanılarak bölütlenme yapılmaktadır. Ancak; özellikle HSG'lere ek olarak LiDAR verileri de kullanıldığında, Şekil 3'te de gözüktüğü gibi kenarların belirginleşmesiyle önerilen algoritma bölütleme sonuçlarına önemli katkı sağlamaktadır.

Bölüm III'de önerilen algoritma farklı α değerleri için uygulanmış, elde edilen bölütler Şekil 4'te gösterilmiştir. Sonuçlara bakıldığında, $\alpha = 0$ iken, yani sadece spektral bilgiler kullanıldığında, görüntünün gereğinden fazla bölütlere ayrıldığı görülmüştür. Özellikle, ağaç toplulukları, gölgeleri ve çimenler olması gerekenden daha fazla bölütlere ayrılmıştır. $\alpha = 2$ iken, HSG'lerin yanı sıra uzamsal ve özellikle yükseklik bilgileriyle elde edilen potansiyel matrisi devreye girdiğinde daha önce elde edilen fazla bölütlerin bertaraf edildiği gözükmemektedir. Ağaç toplulukları tek bir bölüt olarak ayrılmış, ağaç gölgeleri de ağaçlardan farklı bir bütün olarak gruplanmıştır. Benzer şekilde, çimenlerdeki fazla bölütler ortadan kalkmış, tek bölüt halinde ayrılmıştır. α değeri artırıldığında, spektral bilginin bölütlemeye etkisi azalırken yükseklik bilgisinin etkisini artırmaktadır. Beklenildiği gibi, yüksekliği baskın olan cisimlerin bölütlendiği Şekil 4'te $\alpha = 50$ için gözükmemektedir.


USSÖ algoritmasının farklı α değerleri için bölütleme sonuçları Şekil 6'da verilmiştir. $\alpha = 2$ olduğunda iyileşme gözükmeyle birlikte, bazı noktalarda ağaçlarla çimenlerin ve ağaçlarla gölgelerinin birbirlerine karıştırıldığı gözükmemektedir. Benzer şekilde, asfaltın da bazı bölümlerinin fazla bölütlere ayrıştırıldığı gözükmemektedir. $\alpha = 2$ için, Şekil 4 ve Şekil 6'da verilen sonuçlar karşılaştırıldığında, LiDAR'ın iyileştirme etkisi çarpıcı bir şekilde gözükmemektedir. Yine Şekil 6'da sonuçları verilen USSÖ algoritmasının α değeri artırıldığında anlamsız ve yanlış bölüt sayısı artmaktadır. Halbuki, Şekil 4'te gözüktüğü gibi önerilen algoritmada α artırıldığında yükseklik bilgisi yardımıyla anlamlı bölütler oluşturulmaya devam edilmektedir.

HSG ile LiDAR verilerini [5]'te bahsedilen Düzgelenmiş




Şekil 4: Önerilen Algoritmanın Farklı α Değerleri ile Elde Edilen Bölütler

Kesit algoritması yardımıyla birleştirerek bölütleme yapan yöntemin ve önerilen algoritmanın sonuçları Şekil 5'de verilmiştir. Şekile bakıldığında, 1 ile gösterilen kısımda yer alan hedefleri Düzgelenmiş Kesit ayırırken, önerilen yöntem yükseklik bilgisine daha çok önem verdiğinden ($\alpha = 2$), alçakta olan bu hedefleri bölütlediği gözükmemektedir. Diğer taraftan, ağaç topluluğu ile binaları ayırmada önerilen yöntemin son derece başarılı olduğu 2 ile gösterilen bölgede ve diğer bölgelerde gözükmemektedir. Aynı şekilde, Düzgelenmiş Kesit algoritması 4 numaralı bölgedeki ağaçların hiç birini bölütlemeyen, önerilen yöntem hem ağaçları hem de gölgelerini ayrı ayrı bölütlemiştir. Son olarak, 3. bölgede verilen ve çevresine göre alçakta kalan arabayı Düzgelenmiş Kesit algoritması ayırırken, önerilen algoritma ayıramamıştır. Şekildeki sonuçlara genel olarak bakıldığında ise, önerilen algoritmanın bölütlemadaki üstünlüğü fark edilmektedir.



Şekil 5: Sırasıyla: Kullanılan Verinin RGB Görüntüsü, Düzgelenmiş Kesit Bölütleme Sonucu, Önerilen Algoritmanın Bölütleme Sonucu ($\alpha = 2$)

Sonuç olarak, HSG ve LiDAR verilerinin birleştirilmesiyle elde edilen görüntü bölütlerinin doğruluğunun artmasında ve bu bölütlerdeki malzemelerin bir bütün olarak kümelenebilmesinde önemli katkı sağlandığı açık bir şekilde gözükmemektedir.



Şekil 6: USSÖ Algoritmasının Farklı α Değerleri ile Elde Edilen Bölütler

TEŞEKKÜR

Bu çalışma TÜBİTAK tarafından 115E318 numaralı proje kapsamında desteklenmiştir.

KAYNAKLAR

- [1] D. Manolakis, D. Marden, and G. A. Shaw, "Hyperspectral image processing for automatic target detection applications," Lincoln Laboratory Journal, vol. 14, no. 1, pp. 79–116, 2003.
- [2] J. Shi and J. Malik, "Normalized cuts and image segmentation," IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 22, no. 8, pp. 888–905, 2000.
- [3] D. B. Gillis and J. H. Bowles, "Hyperspectral image segmentation using spatial-spectral graphs," SPIE Defense, Security, and Sensing, International Society for Optics and Photonics, 2012.
- [4] O. Torun and S. E. Yüksel, "Hyperspectral image segmentation using normalized cuts," Signal Process. and Commun. Appl. Conference (SIU), 24th, Zonguldak, 2016, pp. 1717–1720.
- [5] O. Torun and S. E. Yüksel, "Using k-way normalized cuts to integrate LiDAR and hyperspectral imagery for segmentation," in Light, Energy and the Environment, OSA Technical Digest (online), 2016, paper HTu3D.2.
- [6] J. Benedetto, W. Czaja, J. Dobrosotskaya, T. Doster, K. Duke, and D. Gillis, "Semi-supervised learning of heterogeneous data in remote sensing imagery," SPIE Independent Component Analyses, Compressive Sampling, Wavelets, Neural Net, Biosystems, and Nanoengineering X, vol. 8401, pp. 840104–840104–12, 2012.
- [7] P. Arbeláez, M. Maire, C. Fowlkes, and J. Malik, "Contour detection and hierarchical image segmentation," IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 33, no. 5, pp. 898–916, May 2011.
- [8] N. D. Cahill, W. Czaja, and D. W. Messinger, "Schroedinger Eigenmaps with nondiagonal potentials for spatial-spectral clustering of hyperspectral imagery," SPIE Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XX, vol. 9088, pp. 908804–908804–13, 2014.
- [9] P. Gader, A. Zare, R. Close, J. Aitken, G. Tuell, "MUUFL gulfport hyperspectral and LiDAR airborne data set," University of Florida, Gainesville, FL, Tech. Rep. REP-2013-570, Oct. 2013.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı: Orhan TORUN

Doğum Yeri: Ardahan

Medeni Hali: Bekar

E-posta: orhantorun@hacettepe.edu.tr

Adresi: Etiler Mahallesi Fabrika Caddesi No: 8 D: 1 Etimesgut / ANKARA

Eğitim

Lise: Fatih Sultan Mehmet Lisesi, İSTANBUL

Lisans: Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü, ANKARA

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

Yabancı Dil ve Düzeyi

İngilizce : İleri Düzey

İş Deneyimi

TÜBİTAK BİLGEM İLTAREN, Şubat 2015-, Araştırmacı, ANKARA

Deneyim Alanları

Uzaktan algılama, görüntü işleme, radar sinyal işleme

Tezden Üretilmiş Projeler ve Bütçesi

—

Tezden Üretilmiş Yayınlar

Torun, O., Yüksel, S. E., "Hyperspectral image segmentation using normalized cuts," *in 24th Signal Process. Commun. Applicat. Conf. (SIU). IEEE*, 2016, pp. 1717-1720.

Torun, O., Yüksel, S. E., "Using k-way normalized cuts to integrate lidar and hyperspectral imagery for segmentation," in *Hyperspectral Imaging and Sounding of the Environment. Optical Society of America*, 2016, pp. HTu3D-2.

Torun, O., Yüksel, S. E., "Lidar aided hyperspectral images segmentation using schroedinger eigenmaps," in *25th Signal Process. Commun. Applicat. Conf. (SIU). IEEE*, 2017, pp. 1-4.

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

HİSE 2016, Light, Energy and the Environment Congress, Leipzig, Almanya.

SIU 2017, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Antalya, Türkiye.



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 13/09/2017

Tez Başlığı / Konusu: Hiperspektral Görüntülerde Lidar Destekli Spektral Bölütleme

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 79 sayfalık kısmına ilişkin, 13/09/2017 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %6 'tür.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç ✓
- 2- Alıntılar hariç/dahil ✓
- 3- 5 kelimeden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

13.09.2017
Tarih ve İmza

Adı Soyadı:	ORHAN TORUN
Öğrenci No:	N14127043
Anabilim Dalı:	ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ
Programı:	ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ
Statüsü:	☒ Y.Lisans ☐ Doktora ☐ Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.

YRD. DOÇ. DR. SENİHA ESEN YÜKSEL
(Unvan, Ad Soyad, İmza)