

**T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA GÖRÜNTÜLERİNİN SÜPERPİKSEL
TABANLI SINIFLANDIRILMASI**

**SERTAÇ ARISOY
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE
2016**

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA GÖRÜNTÜLERİNİN
SÜPERPİKSEL TABANLI
SINIFLANDIRILMASI

SERTAÇ ARISOY
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
DOÇ. DR. KORAY KAYABOL

GEBZE
2016

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**SUPERPIXEL BASED CLASSIFICATION OF
REMOTE SENSING IMAGES**

SERTAÇ ARISOY

**A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE
DEPARTMENT OF ELECTRONIC ENGINEERING**

**THESIS SUPERVISOR
ASSOC. PROF. DR. KORAY KAYABOL**

**GEBZE
2016**



YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 01/06/2016 tarih ve 2016/35 sayılı kararıyla oluşturulan jüri tarafından 03/08/2016 tarihinde tez savunma sınavı yapılan Sertaç ARISOY'un tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Doç. Dr. Koray KAYABOL

ÜYE

: Yrd. Doç. Dr. Köksal HOCAOĞLU

ÜYE

: Prof. Dr. Bilge Günsel KALYONCU

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Bu tezde uzaktan algılamada yaygın olarak kullanılan Sentetik Açıklı Radar (SAR) ve hiperspektral görüntülerin sınıflandırılması için süperpiksel tabanlı yaklaşımlar kullanılmıştır. Mevcut süperpiksellerin yanında uzaktan algılama imgeleri için karışım tabanlı süperpiksel yöntemi (MISP) ve Gauss karışım modeli (GKM) süperpiksel yöntemini önermekteyiz. Tezin içeriği üç bölümden oluşmaktadır. İlk bölümde bilgisayarla görme alanındaki görüntüler için önerilen düzgelemiş kesim, turbo piksel, entropi oranı süperpikselleri (ERS), basit doğrusal yinelemeli kümeleme (SLIC), doğrusal spektral kümeleme (LSC) ve hızlı-kaydırma (QS) süperpiksel yöntemleri, SAR görüntüleri için önerilen MISP ve PLS süperpiksel yöntemleri ve hiperspektral imgeler için önerilen GKM süperpiksel yöntemi anlatılmaktadır. İkinci bölümde SAR imgeleri içerisindeki şehir, arazi, göl gibi farklı bölgelerin sınıflandırılmasında süperpiksellerin başarımı denenmiştir. Süperpikseller elde edildikten sonra k-ortalamlar, sıradüzensel ve GKM gibi kümeleme algoritmaları ile denetimsiz olarak sınıflandırılmaktadır. Bilgisayarla görme alanındaki süperpiksel yöntemleri ve bu tezde önerilen MISP yönteminin başarımları karşılaştırıldığında MISP yönteminin diğer yöntemlere göre daha iyi sonuçlar verdiği görülmektedir. Üçüncü bölümde süperpikseller hiperspektral imge içerisindeki farklı yeryüzü bölgelerinin sınıflandırılmasında kullanılmıştır. Geleneksel spektral sınıflandırmanın yanında tez kapsamında uzamsal olarak piksellerin komşuluk bilgisini içeren süperpikseller kullanılarak uzamsal-spektral sınıflandırma yöntemini kullanılmaktadır. Spektral tabanlı sınıflandırma yöntemlerine oranla uzamsal-spektral sınıflandırma yaklaşımıyla performans artışı sağlanmaktadır.

Anahtar Kelimeler: Süperpiksel, SAR imgelerin sınıflandırılması, Hiperspektral imgelerin sınıflandırılması.

SUMMARY

In this thesis, superpixel based approaches are used to classify SAR and hyperspectral images which are commonly used in remote sensing. Beside state-of-the-art superpixel methods, we propose mixture-based superpixel (MISP) and Gauss mixture model (GKM) superpixel methods specific to remote sensing images. The thesis is organized as three sections. In the first section, we present the superpixel methods in the computer vision literature such as normalized cuts, turbo pixel, entropy rate superpixels (ERS), simple linear iterative clustering (SLIC), linear spectral clustering (LSC) and quick-shift (QS), specific methods to SAR images such as MISP and PILS and specific to hyperspectral images as GKM superpixel method. In the next section the performance of superpixels are evaluated in terms of classifying different region such as urban, land, lake etc. in SAR image. After obtained the superpixels, they are unsupervised classified with commonly used k-means, hierarchical and GKM algorithms. When the test results of proposed in this thesis MISP method and the computer vision superpixel methods are compared, it is shown that MISP outperforms the other methods. In the third section the superpixel methods are used to classify the different areas in the hyperspectral image. Beside traditional based spectral classification methods, in this thesis we refer to spatial-spectral classification method using superpixels that include neighborhood information of the pixels in the spatial domain. In comparison with spectral based classification methods spatial-spectral classification approach increases the classification performance.

Key Words: Superpixel, SAR image classification, Hyperspectral image classification.

TEŞEKKÜR

Her zaman bilimsel çalışmaların yolunu açan ve bu yolda hiçbir zaman yardımını esirgemeyen danışmanım Doç. Dr. Koray KAYABOL'a,

114E535 No'lu "Hiperspektral İmgelerin Bağlamsal Sınıflandırılması ve Boyut İndirgenmesi için Olasılıksal Modeller" isimli projeyi desteklerinden dolayı TÜBİTAK'a,

TerraSAR-X uydusuna ait Rosenheim ve Mississippi görüntülerine çevrimiçi erişimi sağlayan AIRBUS Defence&Space'e,

Indian Pines, Salinas ve Pavia Üniversitesi hiperspektral görüntülerine çevrimiçi erişimi sağlayan Prof. Dr. Manuel Grana Romay'a,

Timothee Cour, Stella Yu, Jianbo Shi, Ming-Yu Liu, Andrea Vedaldi, Brian Fulkerson, Peter Kovesi, Zhengqin Li, Jiansheng Chen ve Alex Levinshtein'e kodlarını çevrimiçi paylaştıkları için,

ve öğrenim hayatım boyunca her zaman yanımda duran ve destekleyen aileme en içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xiii
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	1
2. SÜPERPİKSEL ALGORİTMALARI	3
2.1. Çizge Tabanlı Süperpiksel Algoritmaları	4
2.1.1. Düzgelenmiş Kesim	4
2.1.2. Entropi Oranı Süperpikselleri	6
2.2. Kümeleme Tabanlı Süperpiksel Algoritmaları	8
2.2.1. Basit Doğrusal Yinelemeli Kümeleme	8
2.2.2. Doğrusal Spektral Kümeleme	9
2.2.3. Hızlı-Kaydırma Yöntemi	11
2.2.4. Turbo Piksel Yöntemi	12
2.3. Uzaktan Algılama İmgeleri için Süperpiksel Algoritmaları	13
2.3.1. SAR İmgeleri için Önerilen Süperpiksel Algoritmaları	13
2.3.1.1. Piksel Yeğİnlik ve Konum Benzerliđi Süperpikselleri	14
2.3.1.2. Karışım Tabanlı Süperpiksel Yöntemi	15
2.3.2. Hiperspektral İmgeler için Önerilen Süperpiksel Yöntemi	23
2.3.2.1. Gauss Karışım Modeli Süperpikselleri	23
2.4. Süperpiksellerin Düzenlenmesi	25
2.5. Süperpiksel Başarım Metrikleri	26
2.5.1. Bölütleme Hatası	26
2.5.2. Sınır Duyarlılıđı	26
2.5.3. Derlitopluluk	27

3. SAR İMGELERİN SÜPERPİKSEL TABANLI SINIFLANDIRILMASI	29
3.1. SAR İmgesine Giriş	29
3.2. SAR İmgesi Veri Kümesi	32
3.2.1. Rosenheim İmgesi	32
3.2.2. Mississippi İmgesi	34
3.3. SAR İmgelerden Süperpiksellerin Çıkarılması	35
3.4. Süperpikseller için Öznitelik Çıkarımı	42
3.5. Süperpiksellerin Kümelenmesi	43
3.5.1. k-ortalamlar Yöntemi	43
3.5.2. Sıradüzensel Kümeleme Yöntemi	44
3.5.3. GKM Kümeleme Yöntemi	46
3.6. Deney Sonuçları ve Algoritmaların Başarım Karşılaştırmaları	47
3.7. Vargı	54
4. HİPERSPEKTRAL İMGELERİN SÜPERPİKSEL TABANLI SINIFLANDIRILMASI	56
4.1. Hiperspektral İmgesine Giriş	56
4.2. Hiperspektral İmge Veri Kümesi	57
4.2.1. Indian Pines İmgesi	57
4.2.2. Salinas İmgesi	57
4.2.3. Pavia Üniversitesi İmgesi	58
4.3. Hiperspektral İmgelerde Boyut İndirgenmesi	59
4.3.1. Temel Bileşen Analizi	59
4.4. Hiperspektral İmgelerden Süperpiksellerin Çıkarılması	61
4.5. Hiperspektral İmgelerin Spektral Alanda Sınıflandırılması	67
4.5.1. Olasılıksal Temel Bileşen Analizi	68
4.5.2. Hiperspektral İmgelerin Spektral Alanda OTBA Tabanlı Sınıflandırılması	69
4.6. Uzamsal-Spektral Sınıflandırma	71
4.7. Deney Sonuçları ve Algoritmaların Başarım Karşılaştırmaları	72
4.8. Vargı	74
KAYNAKLAR	76
ÖZGEÇMİŞ	79
EKLER	80

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler ve Açıklamalar

Kisaltmalar

μ	:	Ortalama Vektörü
σ^2	:	Varyans
Σ	:	Kovaryans Matrisi
m	:	Metre
AVIRIS	:	Airborne Visible/Infrared Imaging Spectrometer
BR	:	Boundary Recall
CM	:	Compactness
EM	:	Expectation Maximization
ERS	:	Entropy Rate Superpixels
ESS	:	Error Sum of Squares
GKM	:	Gauss Karışım Modeli
IBCSS	:	Incremental Between Cluster Sum of Squares
ICM	:	Iterated Conditional Modes
LSC	:	Linear Spectral Clustering
MISP	:	Mixture-based Superpixel
MLE	:	Maximum Likelihood Estimation
NC	:	Normalized Cuts
OTBA	:	Olasılıksal Temel Bileşen Analizi
PILS	:	Pixel Intensity and Location Similarity
QS	:	Quick Shift
RGB	:	Kırmızı, Yeşil, Mavi Renk Uzayı
RODIS	:	Reflective Optics System Imaging Spectrometer
SAR	:	Sentetik Açıklı Radar
SKM	:	Sonlu Karışım Modeli
SLIC	:	Simple Linear Iterative Clustering
TBA	:	Temel Bileşen Analizi
TD	:	Tam Doğruluk
TP	:	Turbo Pixel
UE	:	Under-segmentation Error

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: Çizge uzayı.	4
2.2: MISP yönteminde rastgele değişkenlerin birbirleriyle olan ilişkisi.	23
3.1: SAR görüntüleme geometrisi.	30
3.2: SAR görüntülerinin oluşturulması sırasında sinyal işleme süreci.	31
3.3: Rosenheim şehri imgesi.	32
3.4: Rosenheim şehri imgesinden elde edilen TSX1, TSX2 ve TSX3 SAR imgeleri ve yer-gerçekliği haritaları.	33
3.5: Mississippi bölgesi imgesi.	34
3.6: Mississippi imgesinden elde edilen TSX4 SAR imgesi ve yer-gerçekliği haritası.	34
3.7: TSX1 imgesi için PILS ve QS yöntemlerinde KBT süreci süperpiksel haritaları.	36
3.8: TSX1 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları.	37
3.9: TSX2 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları.	38
3.10: TSX3 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları.	39
3.11: TSX4 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları.	40
3.12: TSX1, TSX2, TSX3 ve TSX4 imgelerinde süperpiksel yöntemlerinin UE, BR ve CM başarımlarının karşılaştırılması.	41
3.13: Süperpiksel özneliklerinin çıkarılması.	42
3.14: Sıradüzensel kümeleme algoritmasında kullanılan ağaç yapısı.	45
3.15: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin k-ortalamar kümelmesi sonucu sınıflandırma haritaları.	51
3.16: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin sıradüzensel kümelmesi sonucu sınıflandırma haritaları.	52
3.17: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin GKM yöntemine göre kümelmesi sonucu sınıflandırma haritaları.	53

4.1:	Hiperspektral imge kübü.	56
4.2:	Indian Pines imgesinin 80, 150, 190 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası.	57
4.3:	Salinas imgesinin 30, 100, 190 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası.	58
4.4:	Pavia Üniversitesi imgesinin 10, 50, 70 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası.	58
4.5:	Indian Pines, Pavia Üniversitesi ve Salinas hiperspektral imgelerinin TBA yöntemiyle elde edilen sıralı ilk beş bileşen görüntüleri.	62
4.6:	Indian Pines imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları.	63
4.7:	Pavia Üniversitesi imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları.	64
4.8:	Salinas imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları.	65
4.9:	Indian Pines, Pavia Üniversitesi ve Salinas imgeleri için süperpiksel yöntemlerinin UE, BR ve CM ölçümlerinin karşılaştırılması.	66
4.10:	Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin OTBA tabanlı Bayes sınıflandırma sonucu haritaları.	70
4.11:	Hiperspektral imgelerde uzamsal-spektral sınıflandırma süreci.	72
4.12:	Çoğunluk oylaması yöntemi.	72
4.13:	Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin uzamsal-spektral sınıflandırma haritaları.	75

TABLolar DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
3.1: TSX1 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımı sonuçları.	48
3.2: TSX2 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımı sonuçları.	48
3.3: TSX3 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımı sonuçları.	49
3.4: TSX4 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımı sonuçları.	49
3.5: MISP, SLIC, TP, QS, PILS ve NC süperpiksel algoritmalarının çalışma zamanları.	54
4.1: GKM, NC, TP, SLIC ve QS süperpiksel algoritmalarının çalışma zamanları.	67
4.2: Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin OTBA tabanlı Bayes sınıflandırma sonuçları.	71
4.3: Indian Pines imgesinde uzamsal-spektral sınıflandırma sonuçları.	73
4.4: Pavia Üniversitesi imgesinde uzamsal-spektral sınıflandırma sonuçları.	73
4.5: Salinas imgesinde uzamsal-spektral sınıflandırma sonuçları.	74

1. GİRİŞ

Uzaktan algılama yeryüzündeki nesnelere herhangi bir fiziksel temas olmadan uzaya gönderilmiş hareketli platformlar tarafından aktif ya da pasif sensörler ile ölçüm sonucunda bilgi alma ve bunları analiz etme bilimi olarak tanımlanabilir. Pasif görüntüleme sensörleri güneş enerjisini kullanırken aktif görüntüleme sensörleri enerji üreterek sahneye elektromanyetik dalga gönderip yansıyan sinyali toplayarak görüntü elde ederler. SAR görüntüleri aktif görüntüleme sensörleri tarafından ölçülmektedir. SAR görüntüsü hareketli platform üzerinden gönderilen ve ters saçılan sinyallerin toplanması sonucunda oluşmaktadır. Yeryüzü hareketlerinin izlenmesinden hedef tespitine kadar geniş alanda kullanılmaktadır. Bu çalışmada SAR imgeleri içerisindeki şehir, arazi, göl gibi farklı bölgeler süperpiksel tabanlı sınıflandırılmaktadır. Uzaktan algılamada yaygın olarak kullanılan hiperspektral görüntülerin sınıflandırılmasında birçok farklı yöntem önerilmektedir. Bu tezde geleneksel piksel tabanlı yaklaşımların yanında süperpiksel tabanlı yaklaşımlar ile uzaktan algılama görüntüleri sınıflandırılmaktadır.

1.1. Tezin Amacı, Katkısı ve İçeriği

Uzaktan algılama görüntüleri geleneksel olarak piksel tabanlı sınıflandırılmaktadır. Piksel tabanlı sınıflandırma aşırı işlem yükü gerektirmekte ve işleme zamanı fazla olabilmektedir. Bu çalışmada süperpiksel tabanlı sınıflandırma yaklaşımları ile işlem yükünün ve işleme zamanının azaltılması, bunun yanında sınıflandırma başarımlarının artırılması amaçlanmaktadır. SAR ve hiperspektral görüntüler için önerilen süperpiksel yöntemleri ile literatürde var olan bilgisayarla görme alanındaki görüntüler için önerilmiş süperpiksel yöntemlerinin uzaktan algılama görüntüleri üzerinde karşılaştırılması yapılarak süperpiksel tabanlı sınıflandırmada en etkili süperpiksel yöntemi aranmaktadır. Bu amaçla ikinci bölümde literatürde var olan bilgisayarla görme alanında kullanılan düzgelemiş kesim (normalized cuts, NC) [1], turbo piksel (turbo pixel, TP) [2], entropi oranı süperpikselleri (entropy rate superpixels, ERS) [3], basit doğrusal yinelemeli kümeleme (simple linear iterative clustering, SLIC) [4], doğrusal spektral kümeleme (linear spectral clustering, LSC) [5] ve hızlı kaydırma (quick shift, QS) [6]

süperpiksel yöntemleri ve SAR görüntüleri için önerilen piksel yeğinlik ve konum benzerliği (pixel intensity and location similarity, PILS) [7] süperpikselleri anlatılmaktadır. SAR imgeleri için karışım tabanlı süperpiksel (mixture-based superpixel, MISP) yöntemini bu tezde önererek [8]-[10]'da literatüre dahil etmekteyiz. Hiperspektral görüntüler için Gauss Karışım Modeli (GKM) süperpiksel yöntemini önererek [11]'de literatüre dahil etmekteyiz.

Üçüncü bölümde SAR imgelerinin elde edilme süreci anlatılmakta ve sınıflandırmada kullanılan imgeler tanıtılmaktadır. SAR imgelerinin süperpiksel tabanlı sınıflandırılması amacıyla ilk olarak MISP, PILS, düzelenmiş kesim, turbo piksel, ERS, SLIC ve QS süperpiksel algoritmaları kullanılarak süperpikseller elde edilmekte ve algoritmaların birbirlerine göre başarımları karşılaştırılmaktadır. Süperpiksellerin sınıflandırılması adımımda imgedeki süperpikseller içerisinden piksel histogramları ile öznitelik vektörleri oluşturulmaktadır. Süperpikselleri temsil eden öznitelik vektörleri gözetimsiz olarak k-ortalamlar, sıradüzensel ve GKM kümeleme yöntemlerine göre kümelenmekte ve sınıflandırma başarımları karşılaştırılarak SAR imgelerinin süperpiksel tabanlı sınıflandırılmasında etkili yöntem aranmaktadır.

Dördüncü bölümde hiperspektral imgelerin sınıflandırılmasında ilk olarak GKM, düzelenmiş kesim, turbo piksel, ERS, SLIC, LSC ve QS yöntemleri kullanılarak süperpikseller çıkarılmakta ve süperpiksel başarımları karşılaştırılmaktadır. Spektral alanda piksel vektörleri Olasılıksal Temel Bileşen Analizi (OTBA) tabanlı Bayes sınıflandırıcı ile sınıflandırılmaktadır. Son adımda uzamsal alandaki süperpikseller ve spektral alandaki sınıflandırılmış pikseller çoğunluk oylaması ile işbirliği yaparak uzamsal-spektral sınıflandırma yapılmaktadır.

2. SÜPERPİKSEL ALGORİTMALARI

Süperpikseller imge içerisindeki piksellerin gruplandırılması sonucu oluşan atomik bölgeler olarak tanımlanabilir. İmge bölütlemesi [12], nesne yerelleştirilmesi [13], sahnenin 3B modellenmesi [14], derinlik kestirimi [15] gibi birçok bilgisayarla görme alanında kullanılmaktadır. İmgenin aşırı bölütlenmesi sonucunda elde edilmektedir. Süperpiksellerin başlıca kullanım amacı imge işleme sırasında işlem yükünü ve işleme zamanını azaltmasıdır. Örneğin imge içerisindeki piksellerin L adet etiketlenmesi sırasında n adet pikselin etiketlenmesi için L^n (tipik olarak 10^6) işlem yükü gerekirken, $m < n$ için m adet süperpiksel kullanılarak işlem yükü L^m 'ye (tipik olarak 10^2) düşürülmektedir [3]. Süperpikseller yerel bilgiler taşımaktadır ve imgenin sınırları hakkında önsel bilgi vermektedir. Süperpikseller oluşturulurken genel bir takım özellikleri sahip olması istenmektedir. Bu özellikler:

- Her süperpiksel imge içerisinde yalnızca bir nesne ile örtüşmeli,
- Süperpiksel sınır setleri nesne sınırlarını oluşturmalı,
- Süperpikseller imge içerisinde ön işleme amacıyla kullanıldığından hızlı bir şekilde karmaşık olmayan işlem yükü ile hesaplanmalıdır.

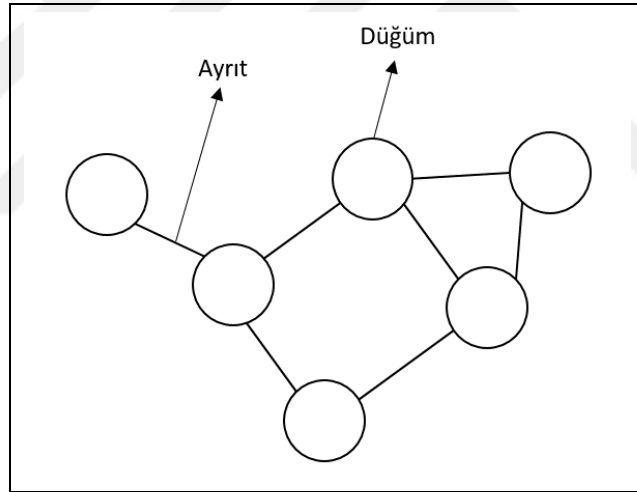
Süperpikseller bilgisayarla görme alanında kullanılan renkli ve gri seviyeli imgeler için önerilmiştir. Son zamanlarda uzaktan algılama alanında da süperpikseller yaygın olarak kullanılmaya başlanmıştır [7], [16], [17]. Literatürde birçok süperpiksel yöntemi bulunmaktadır. Bu yöntemler çizge (graph) tabanlı ve kümeleme (clustering) tabanlı olarak iki gruba ayrılabilir. Çizge tabanlı yöntemlerde pikseller çizge uzayına aktarılıp kümelenmektedir. Bu grupta NC [1] ve ERS [3] süperpiksel algoritmaları öne çıkmaktadır. Kümeleme tabanlı yöntemler ise süperpikseller eğim iniş (gradient descent) algoritması tabanlı olarak özyineli bir şekilde oluşturulmaktadır. TP [2], SLIC [4], LSC [5] ve QS [6] yöntemleri kümeleme tabanlı yöntemler olarak önerilmiştir.

Bu bölümde ilk olarak çizge ve kümeleme tabanlı süperpiksel yöntemleri açıklanmaktadır. Sonraki adımda uzaktan algılanan SAR görüntüleri için önerilen PILS [7] yöntemi ve bu tezde önerdiğimiz MISP [8]-[10] yöntemi ve hiperspektral görüntüler için önerdiğimiz GKM süperpikseller yöntemi açıklanmaktadır.

Süperpiksel yöntemlerinin başarımlarını ölçen bölütleme hatası (under-segmentation error, UE), sınır duyarlılığı (boundary recall, BR) ve derlitopluluk (compactness, CM) metrikleri tanıtılarak bölüm sonlandırılmaktadır.

2.1. Çizge Tabanlı Süperpiksel Algoritmaları

Çizge tabanlı yöntemlerde pikseller $G = (V, E)$ çizge uzayına aktarılmaktadır. Burada V düğüm noktalarını, E düğüm noktalarını birleştiren ayrıt kümesi olmak üzere Şekil 2.1'de çizge uzayı gösterilmektedir. İmge için düğüm noktaları pikselleri temsil etmektedir. İki düğümü birleştiren ayrıt ağırlığı W komşu düğümler arasında benzerlik oranı ile ilişkilidir. Süperpikseller çizge uzayının alt küçük uzaylara parçalanması ile oluşturulmaktadır. Bu bölümde yaygın olarak kullanılan NC [1] ve ERS [3] süperpiksel yöntemleri açıklanmaktadır.



Şekil 2.1: Çizge uzayı.

2.1.1. Düzgelenmiş Kesim

Düzgelenmiş kesim (Normalized cuts - NC) [1] yönteminde öznitelik uzayı ağırlıklı yönsüz çizge uzayı $G = (V, E)$ olarak temsil edilmektedir. Çizge uzayının düğümleri öznitelik uzayındaki noktaları temsil etmektedir. Her düğüm çifti arasında ayrıt ağırlıkları $w(i, j)$ i ve j düğümleri arasındaki benzerlik fonksiyonu kullanılarak tanımlanmaktadır.

Çizge uzayındaki düğüm setleri birbiriyle örtüşmeyecek şekilde V_1, V_2, \dots, V_m alt gruplara ayrıştırılması sonucunda oluşmaktadır. Gruplar kendi içerisinde yüksek benzerliğe, farklı gruplara karşı düşük benzerliğe sahip olacak şekilde eniyilenmektedir. Çizge uzayının ayrıştırılması sırasında kullanılan benzerlik ölçüsü kesim olarak adlandırılmakta ve

$$cut(V_1, V_2) = \sum_{u \in V_1, v \in V_2} w(u, v) \quad (2.1)$$

olarak tanımlanmaktadır. Çizge uzayı kesim değerinin enküçüklenmesiyle ayrıştırılmaktadır. Düğümler arasında sıra dışı bir düğüm olması durumunda kesim değeri küçük olmakta ve bu durumda gruplaşma yanlı olmaktadır. Bu durumdan kaçınmak için iki düğüm arasındaki benzerlik değerinden ziyade alt çizge uzayında birbirine bağlı toplam düğüm benzerlikleri ile düzelenmesi sonucu düzelenmiş kesim (normalized cuts - Ncut) ölçüsü

$$Ncut(V_1, V_2) = \frac{cut(V_1, V_2)}{assoc(V_1, V)} + \frac{cut(V_2, V)}{assoc(V_2, V)} \quad (2.2)$$

kullanılmaktadır. Burada $assoc(V_1, V)$ V_1 alt çizge uzayındaki düğümler ile V çizge uzayındaki diğer bağlantılı tüm düğümlere olan toplam benzerliğini göstermektedir. Gösterici fonksiyon x düğüm çizge alt uzayının içinde ise $x_i = 1$ diğer durumda $x_i = -1$ olarak tanımlanmaktadır. $d(i) = \sum_j w(i, j)$ olarak i . düğüme bağlı diğer tüm düğümlerin benzerlik toplamı şeklinde tanımlanmaktadır. Eşitlik (2.2)

$$(\mathbf{D} - \mathbf{W})\mathbf{y} = \lambda \mathbf{D}\mathbf{y} \quad (2.3)$$

şeklinde genelleştirilmiş özdeğer problemi ile çözülmekte ve gruplar oluşturulmaktadır. Burada \mathbf{D} köşegenlerinde $d(i)$ değerlerine sahip köşegen matristir. \mathbf{W} matrisi i . satır, j . sütunda i ve j düğümleri arasındaki benzerlik değerini tutmaktadır. \mathbf{y} gösterici fonksiyondan gelen eşitliktir ve $\mathbf{y}^T \mathbf{D} \mathbf{1} = 0$ eşitliğini sağlamaktadır. Eşitlik (2.3)'te ikinci en küçük özdeğerde kesimin kararlılığına bakılarak $Ncut$ değeri belli bir eşik değerinin altında olması sağlanmaktadır. Bu koşulları sağlayan gruplar süperpiksel olarak kabul edilmektedir.

Düzgelenmiş kesim ile elde edilen süperpikseller düzgün ve derli toplu olmaktadır. Yöntemin dezavantajı ise özdeğer tabanlı olmasıdır. Özdeğer tabanlı yöntemlerde özvektör sayısı arttıkça işlem karmaşıklığı artmaktadır. Süperpiksel sayısı özdeğer sayısı ile bağlantılı olduğundan imgeden yüksek sayıda süperpiksellerin çıkarılması karmaşıklık ve yüksek zaman gereksinimine neden olmaktadır.

2.1.2. Entropi Oranı Süperpikselleri

Entropi Oranı Süperpikselleri (Entropy Rate Superpixels, ERS) [3] yönteminde pikseller $G = (V, E)$ olarak çizge uzayına aktarılmaktadır. Burada $A \subseteq E$ olmak üzere K adet ayırıt altkümesi açgözlü eniyileme yöntemiyle $G = (V, A)$ olacak şekilde bulunmaktadır.

Ayrık zamanlı X rastgele değişkini ve p_x olasılık kütle fonksiyonu için entropi

$$H(X) = - \sum_{x \in X} p_X(x) \log p_X(x) \quad (2.4)$$

olarak tanımlanmaktadır. $X = \{X_t | t \in T\}$ stokastik süreç için entropi oranı $H(X) = \lim_{t \rightarrow \infty} H(X_t | X_{t-1}, X_{t-2}, \dots, X_1)$ olarak tanımlanmaktadır. Durağan 1. Sıra Markov süreç için basit formda bu oran $\lim_{t \rightarrow \infty} H(X_2 | X_1)$ olarak ifade edilmektedir. Burada rastgele yürüme için durağan dağılımın geçiş olasılığı

$$p_{i,j}(A) = \begin{cases} \frac{w_{i,j}}{w_i} & i \neq j \text{ ve } e_{i,j} \in A \\ 0 & i \neq j \text{ ve } e_{i,j} \notin A \\ 1 - \frac{\sum_{j: e_{i,j} \in A} w_{i,j}}{w_i} & i = j \end{cases} \quad (2.5)$$

şeklindedir. $G = (V, A)$ çizge uzayının rastgele yürüme için entropi oranı

$$H(A) = \sum_i \mu_i \sum_j p_{i,j}(A) \log(p_{i,j}(A)) \quad (2.6)$$

olarak yazılmaktadır. Burada μ durağan dağılımlı ve $(\frac{w_1}{w_T}, \frac{w_2}{w_T}, \frac{w_3}{w_T}, \dots, \frac{w_K}{w_T})^T$ şeklinde tanımlanmaktadır. w_T sabit değeri $w_T = \sum_{i=1}^K w_i$ olarak hesaplanmaktadır. N_A çizge uzayında bağlı bileşen sayısı ve Z_A bu uzayda küme üyelik dağılımının rastgele değişkeni olarak tanımlanmaktadır. Ayrıt setleri için çizge uzayı ayrıştırılması $S_A = \{S_1, S_2, \dots, S_{N_A}\}$ olarak gösterilsin. Bu durumda Z_A 'nın olasılık kütle fonksiyonu

$$p_{Z_A}(i) = \frac{|S_i|}{|V|} \quad (2.7)$$

$i = \{1, \dots, N_A\}$ olarak tanımlanmaktadır. Buradan denge terimi

$$B(A) = H(Z_A) - N_A = - \sum_i p_{Z_A}(i) \log(p_{Z_A}(i)) - N_A \quad (2.8)$$

şeklindedir. Entropi oranı ve denge terimi λ denge terimiyle birleştirilerek amaç fonksiyonu oluşturulmakta ve

$$\begin{array}{ll} \max & H(A) + \lambda B(A) \\ A & \\ s. t. & A \subseteq E \text{ ve } N_A \geq K \end{array} \quad (2.9)$$

şeklinde açgözlü (greedy) eniyileme algoritmasıyla çözümlenerek ayrıt setleri bulunmaktadır. Algoritma boş set ($A = \emptyset$) olarak başlamaktadır. En büyük kazanç göre ayrıtlar sete eklenmektedir. $N_A = K$ adet bağlı alt çizge uzaya ulaşıncaya algoritma sonlanmaktadır.

Entropi oranı derlitoplu ve türdeş süperpikseller üretilmesini sağlarken denge terimi süperpiksellerin aynı boyutta olmasını sağlamaktadır. Derlitoplu ve türdeş süperpikseller sadece bir nesne ile örtüşmekte ve imgedeki nesne sınırları ile bağlantılı olmaktadır.

2.2. Kümeleme Tabanlı Süperpiksel Algoritmaları

2.2.1. Basit Doğrusal Yinelemeli Kümeleme

Basit Doğrusal Yinelemeli Kümeleme (Simple Linear Iterative Clustering, SLIC) [4] süperpikselleri piksellerin renk benzerliği ve yakınlığına bağlı olarak kümelenmesi ile oluşmaktadır. Kümeleme uzayı beş boyutlu $\mathbf{p} = [l, a, b, x, y]^T$ piksel vektöründen oluşmaktadır. Burada l, a, b CIELAB uzayının üç renk bileşeni x ve y piksel koordinatlarıdır.

CIELAB uzayı CIE komitesi tarafından standartlaştırılmış renk uzayıdır. İnsan gözü tarafından görülen tüm renkleri içermektedir. l bileşeni renk aydınlığını ifade etmektedir. $l = 0$ siyahı, $l = 100$ beyazı temsil etmektedir. a bileşeni renk kanallarının kırmızı/eflatun ve yeşil arasındaki konumunu temsil etmektedir. Negatif a değeri yeşili, pozitif a değeri eflatun rengini göstermektedir. b bileşeni ise renk kanallarının sarı ve mavi arasındaki konumunu vermektedir. Negatif değerde olması mavi, pozitif değer olması sarı rengini temsil etmektedir [18].

İstenen K adet süperpiksele göre imge gruplara ayrılmaktadır. İmgenin toplam alanı N olmak üzere, her bir süperpikselin alanı $S = N/K$ olmaktadır. Herhangi bir k . süperpiksel merkezi $\mathbf{C}_k = [l_k, a_k, b_k, x_k, y_k]^T$ olarak gösterilmektedir. Beş boyutlu \mathbf{p}_i piksel vektörünün k . süperpiksel merkezine olan uzaklık ölçümü D_s

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (2.10)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2.11)$$

$$D_s = d_{lab} + \frac{m}{S} d_{xy} \quad (2.12)$$

olarak renk ve konum vektörleri arasındaki Öklid uzaklığından faydalanılarak hesaplanmaktadır. Burada m süperpiksellerin derlitopluluğunu düzenlenmektedir. Yüksek m değeri ile daha derlitoplu süperpikseller oluşturulmaktadır. m değeri aynı zamanda renk ve yakınlık benzerliğinin baskınlığını ayarlamaktadır. Pikseller en yakın süperpiksel merkezine atanmaktadır. Atanan yeni piksellerle süperpiksel merkezleri güncellenmektedir. Piksellerin yeni süperpiksel merkezlerine uzaklıkları

yeniden hesaplanıp atama işlemi tekrardan yapılmaktadır. Bu süreç k-ortalamlar yönteminde olduğu gibi özyineli olarak süperpiksel merkezleri yakınsayınca kadar devam etmektedir. Özyineleme boyunca süperpiksel merkezleri 2Sx2S alan içerisinde güncellenmektedir. Algoritmanın sonunda üretilmek istenen süperpiksel alanından çok küçük alana sahip süperpikseller büyük alanlı en yakın komşu süperpiksel ile birleştirilmektedir. SLIC algoritmasıyla süperpikseller hızlı bir şekilde derli toplu ve türdeş olarak üretilmektedir.

2.2.2. Doğrusal Spektral Kümeleme

Doğrusal Spektral Kümeleme (Linear Spectral Clustering, LSC) [5] süperpikselleri piksellerin on boyutlu öznitelik uzayına aktarılıp ağırlıklı k-ortalamlar yöntemine göre kümelenebilmesi ile oluşmaktadır. On boyutlu doğrusal öznitelik uzayı ağırlıklı k-ortalamlar ve düzgelenecek kesim yöntemlerinin amaç fonksiyonlarının ortak eniyi noktalarının denkliğiyle bulunmaktadır. Amaç fonksiyonları on boyutlu uzayda iki vektörün ağırlıklı iç çarpımı çizge uzayında iki düğümün benzerliği olarak tanımlanmasıyla eniyilenmektedir.

Ağırlıklı k-ortalamlar yönteminin amaç fonksiyonu

$$F_{k-m} = \sum_{k=1}^K \sum_{p \in \pi_k} w(\mathbf{p}) \|\phi(\mathbf{p}) - \mathbf{m}_k\|^2 \quad (2.13)$$

olarak tanımlanmaktadır. Burada π_k k. kümeyi, K küme sayısını, $\phi(\mathbf{p})$ pikselleri yüksek boyutlu uzaya aktaran temel fonksiyonu ve \mathbf{m}_k k. küme merkezini temsil etmektedir. K-yol düzgelenecek kesim yönteminin amaç fonksiyonu

$$F_{Ncuts} = \frac{1}{K} \sum_{k=1}^K \frac{\sum_{p \in \pi_k} \sum_{q \in \pi_k} W(\mathbf{p}, \mathbf{q})}{\sum_{p \in \pi_k} \sum_{q \in V} W(\mathbf{p}, \mathbf{q})} \quad (2.14)$$

olarak tanımlanmaktadır. Burada $W(\mathbf{p}, \mathbf{q})$ \mathbf{p} ve \mathbf{q} düğüm noktalarının benzerliğini temsil etmektedir. F_{k-m} ve F_{Ncuts} amaç fonksiyonları

$$\mathbf{p}, \mathbf{q} \in V, w(\mathbf{p})\phi(\mathbf{p}) \cdot w(\mathbf{q})\phi(\mathbf{q}) = W(\mathbf{p}, \mathbf{q}) \quad (2.15)$$

$$\mathbf{p} \in V, w(\mathbf{p}) = \sum_{\mathbf{q} \in V} W(\mathbf{p}, \mathbf{q}) \quad (2.16)$$

eşitlikleri varsayımı ile birbirlerine eşit olmaktadır. İlk eşitlik yüksek boyutlu öznitelik uzayında iki vektörün ağırlıklı iç çarpımı çizge uzayında iki düğümün benzerliğine eşit olduğunu göstermektedir. İkinci eşitlik ağırlıklı k-ortalama yönteminde her noktanın ağırlığı çizge uzayında ilgili noktaya karşılık gelen düğüme bağlı diğer tüm ayrıt ağırlıklarının toplamına eşit olduğunu göstermektedir.

Çizge uzayında ayrıt benzerliklerini ölçmek için Öklid uzaklığı kullanılmaktadır. Beş boyutlu $\mathbf{p} = [l_p, \alpha_p, \beta_p, x_p, y_p]^T$ ve $\mathbf{q} = [l_q, \alpha_q, \beta_q, x_q, y_q]^T$ piksel vektörleri şeklinde tanımlanmaktadır. Burada l, α, β piksel renk değerlerini, x ve y piksel koordinatlarıdır. \mathbf{p} ve \mathbf{q} vektörlerinin benzerliği

$$\begin{aligned} \widehat{W}(\mathbf{p}, \mathbf{q}) = & C_c^2 2.55^2 \left[2 - (\alpha_p - \alpha_q)^2 - (\beta_p - \beta_q)^2 \right] \\ & + C_c^2 \left[1 - (l_p - l_q)^2 \right] + C_s^2 \left[2 - (x_p - x_q)^2 - (y_p - y_q)^2 \right] \end{aligned} \quad (2.17)$$

olarak hesaplanmaktadır. Burada C_c ve C_s sırasıyla renk benzerliği ve yakınlık baskınlığını düzenlemektedir. Simetrik çekirdek fonksiyonu yakınsaması için $g(t)$ kosinüs fonksiyonu kullanılmakta ve benzerlik ölçütü değerleri 0 ile 1 arasında sınırlandırılmaktadır.

$$\begin{aligned} \widehat{W}(\mathbf{p}, \mathbf{q}) = & C_s^2 [g(x_p - x_q) + g(y_p - y_q)] \\ & + C_c^2 \left[g(l_p - l_q) + 2.55^2 (g(\alpha_p - \alpha_q) - g(\beta_p - \beta_q)) \right] \end{aligned} \quad (2.18)$$

$$g(t) = 1 - t^2 \approx \cos\left(\frac{\pi}{2}t\right) \quad t \in [-1, 1] \quad (2.19)$$

İki kosinüs çarpımının trigonometrik dönüşümü özelliği kullanılarak pikselleri on boyutlu uzaya aktaran \emptyset temel fonksiyonu bulunmaktadır.

$$\begin{aligned} \emptyset(\mathbf{p}) = \frac{1}{w(\mathbf{p})} & (C_c \cos \frac{\pi}{2} l_{\mathbf{p}}, C_c \sin \frac{\pi}{2} l_{\mathbf{p}}, 2.55 C_c \cos \frac{\pi}{2} \alpha_{\mathbf{p}}, \\ & 2.55 C_c \sin \frac{\pi}{2} \alpha_{\mathbf{p}}, 2.55 C_c \cos \frac{\pi}{2} \beta_{\mathbf{p}}, 2.55 C_c \sin \frac{\pi}{2} \beta_{\mathbf{p}}, \\ & C_s \cos \frac{\pi}{2} x_{\mathbf{p}}, C_s \sin \frac{\pi}{2} x_{\mathbf{p}}, C_s \cos \frac{\pi}{2} y_{\mathbf{p}}, C_s \sin \frac{\pi}{2} y_{\mathbf{p}}) \end{aligned} \quad (2.20)$$

$$w(\mathbf{p}) = \sum_{\mathbf{q} \in V} W(\mathbf{p}, \mathbf{q}) = w(\mathbf{p}) \emptyset(\mathbf{p}) \sum_{\mathbf{q} \in V} w(\mathbf{q}) \emptyset(\mathbf{q}) \quad (2.21)$$

Süperpikseller on boyutlu uzayda ağırlıklı k-ortalamlar yöntemiyle vektörlerin özyineli olarak gruplanmasıyla oluşmaktadır. SLIC yönteminde olduğu gibi LSC yönteminde de süperpiksel merkezleri $2S$ alan içerisinde güncellenmektedir. Her özyinelemede süperpiksel merkezleri ve ağırlıklı ortalamalar güncellenmektedir. Ağırlıklı ortalamalar yakınsayınca kadar algoritma devam etmektedir. Algoritma sonunda oluşturulmak istenen süperpiksel alanından çok küçük alana sahip süperpikseller büyük alanlı komşuları ile birleştirilmektedir.

2.2.3. Hızlı-Kaydırma Yöntemi

Kip arama tabanlı Hızlı Kaydırma (Quick Shift, QS) [6] süperpikselleri piksellerin Parzen yoğunluk kestirimine göre kümelenmesi ile oluşturulmaktadır. N veri noktası seti için Parzen yoğunluk kestirimi isotropik Gauss penceresi kullanılarak

$$P(x) = \frac{1}{2\pi\sigma^2 N} \sum_{i=1}^N e^{-\frac{\|x-x_i\|^2}{2\sigma^2}} \quad (2.22)$$

şeklinde hesaplanmaktadır. Gauss penceresi kaydırılarak merkez noktası değiştirilmekte ve kestirim değerleri yeniden hesaplanmaktadır. Merkez piksel yüksek yoğunluk kestirimine sahip en yakın nokta ile bağlanmaktadır. Her bağlantı belli bir d_x uzaklığına sahiptir. Bağlantı setleri ağaç yapısı oluşturmaktadır. Ağacın kökleri en yüksek kestirim yoğunluğuna sahip noktalarlardır.

Öznitelik uzayı olarak RGB renkli görüntü ve uzamsal piksel koordinatları dahil olmak üzere beş boyutlu (r, g, b, x, y) uzayı kullanılmaktadır. Renk değerleri ile uzamsal koordinatlar arasında ödünleşim mevcuttur.

Oluşturulan ağaç yapısı bağlantıları $d_x > \tau$ olmak üzere belli bir τ eşik değeri ile koparılmakta ve süperpikseller oluşturulmaktadır.

2.2.4. Turbo Piksel Yöntemi

Turbo Piksel (Turbo Pixel, TP) [2] yönteminde süperpikseller imge içerisinde tekdüze dağılımlı olarak konumlandırılmış daire tohumlarının aşamalı olarak geometrik akış problemi ile genişletilmesiyle oluşmaktadır. TP algoritmasında süperpiksel bölgesi olarak tanımlanan belirlenmiş bölge ile bu bölge dışında kalan belirlenmemiş bölgedeki tüm pikseller ile sınır oluşturma amaçlanmaktadır. Süperpiksel bölgeleri imge üzerinde tekdüze dağılımlı tanımlanmış daire tohumlarının sınır hız vektörlerine göre açılması ile oluşturulmaktadır. Her pikselin belirlenmiş ve belirlenmemiş bölge arasındaki en yakın sınır noktasına göre işaretli Öklid uzaklığı

$$\psi_t = -S \|\nabla\psi\| \quad (2.23)$$

formülü ile hesaplanmaktadır. Burada S sınır noktasının hareket hızını, $\nabla\psi$ uzaklığın zamansal değişimini göstermektedir. Bu bağıntıya göre belirlenmiş bölgedeki piksel uzaklıkları pozitif, belirlenmemiş bölge dışında ise negatif olmaktadır. Sınır noktaları ψ uzaklığının sıfır seviye seti ile temsil edilmektedir. Sıfır seviye seti sınırın her iki tarafından dört piksel olacak şekilde dar bant bölgesi olarak tanımlanmaktadır. İşaretli Öklid uzaklığının zamanda birinci dereceden ayrıştırılmasıyla

$$\psi^{n+1} = \psi^n - S_I S_B \|\nabla\psi^n\| \Delta t \quad (2.24)$$

eşitliği elde edilmektedir. Bu eşitlik sınır bölgelerindeki her noktanın dar banda ulaşmasına kadar özyineli olarak ilgili noktalara uygulanır. Burada S_I yerel imge yapısı ve sınır noktalarının geometrisi ile ilgili, S_B sınır noktalarının diğer süperpiksellere yakınlığı ile ilgili hızları kontrol eden terimlerdir. Her özyinelemede belirlenmemiş bölgelerde iskelet yapıları oluşturulmaktadır. İskelet noktaları

üzerinde yakınlık tabanlı S_B hızları sıfır kabul edilmektedir. Böylelikle süperpiksel sınırları birbirine çapraz olarak karışmamaktadır. İmge tabanlı S_I hızı

$$S_I(x, y) = [1 - \alpha K(x, y)]\phi(x, y) - \beta [N(x, y) \cdot \nabla \phi(x, y)] \quad (2.25)$$

eşitliği ile bulunmaktadır. Eşitliğin ilk terimi imge içerisindeki yüksek değişim noktalarında yani sınır noktalarında sınır oluşumunu yavaşlatmaktadır. Eşitlikte $\phi(x, y)$ yerel benzerlik terimi her piksel çifti için hesaplanmakta ve imge kenarlarında düşük değere sahip olmaktadır. $K(x, y)$ eğrilik fonksiyonu (x, y) sınır noktasında eğrilik değerini vermektedir. α denge terimi eğriliğin baskınlığını ayarlamaktadır. Eşitliğin ikinci terimi süperpiksel sınırlarının imge kenarlarında olmasını düzenlemektedir. Algoritma sınır oluşma işlemi sonlanıncaya kadar devam etmektedir. Süperpiksel sınırlarının bir piksel genişliğinde olması ile algoritma sona ermektedir. TP yöntemiyle üretilen süperpikseller tekdüze ve derlitoplu olmaktadır.

2.3. Uzaktan Algılama İmgeleri için Süperpiksel Algoritmaları

2.3.1. SAR imgeleri için Önerilen Süperpiksel Algoritmaları

Süperpikseller uzamsal komşuluk bilgileri taşıdığından uzaktan algılama imgelerinin sınıflandırılmasında tercih edilmektedir. Tek bant polarize SAR imgesinin sınıflandırılmasında iki temel yaklaşım kullanılmaktadır. Bu yaklaşımlardan biri istatistiksel tabanlı yöntemlerdir. Bu yöntemlerde Gamma, Nakagami, Weibull gibi uygun model seçimi ve parametrelerin kestirimi yapılmaktadır. Bu tezde istatistiksel tabanlı yöntem olarak [8]'de önerilen ve [9] ve [10]'da geliştirdiğimiz SAR imgelerindeki bölgelerin sınıflandırılmasında kullandığımız MISP süperpiksel yöntemini kullanılmaktadır. SAR imgelerin sınıflandırılmasında bir diğer yaklaşım ise imge analiz yöntemleridir. İmge analiz yöntemi olarak PILS [7] süperpiksel yöntemi kullanılmaktadır. İmge analiz tabanlı yöntemler benek gürültüsü, gürültüye karşı hassasiyet ve aşırı işleme gibi sebeplerden dolayı engel taşımaktadır.

2.3.1.1. Piksel Yeğlilik ve Konum Benzerliği Süperpikselleri

Piksel Yeğlilik ve Konum Benzerliği (Pixel Intensity and Location Similarity, PILS) [7] süperpikselleri piksellerin yeğlilik ve konum benzeşimi kullanılarak k-ortalamlar yöntemine göre kümelenmesi ile oluşmaktadır. Öznitelik uzayı olarak üç boyutlu $[I, x, y]^T$ vektörü kullanılmaktadır. Burada I piksel yeğliliği, x ve y piksel konumlarıdır. SAR imgeleri çarpımsal gürültü altında elde edildiği için üç boyutlu öznitelik vektörlerinin benzeşim ölçüsünde standart Öklid ölçütü uygun değildir. PILS yönteminde SAR imgelerine özgü yeni benzeşim ölçütü önerilmektedir. [19]'da SAR imgelerindeki benek gürültüsünü gidermek için önerilen genlik oran uzaklığı (amplitude ratio distance) PILS yönteminde piksel yeğliliklerinin benzeşimi olarak

$$S_I(i, j) = \|p(r_{i,j,k})\|^2 = \sum_{k=1}^M G(k) \left| p\left(\frac{I_{N_i}(k)}{I_{N_j}(k)}\right) \right|^2 \quad (2.26)$$

şeklinde kullanılmaktadır. Burada I_{N_i} ve I_{N_j} merkez pikselleri N_i ve N_j olan aynı boyutta piksel genlik vektörleri, $r_{i,j,k}$ k . I_{N_i} ve I_{N_j} piksel yeğliliklerinin oranını, G Gauss çekirdek fonksiyonunu ve M pencere büyüklüğünü göstermektedir. $r_{i,j,k}$ oranının olasılık yoğunluk fonksiyonu,

$$p(r_{i,j,k}) = \frac{2(2L-1)!}{\Gamma^2(L)} \frac{(r_{i,j,k})^{2L-1}}{[r_{i,j,k}^2 + 1]^{2L}} \quad (2.27)$$

şeklinde tanımlanmaktadır. Burada L SAR imgesinin bakış sayısını, $\Gamma(\cdot)$ gamma fonksiyonunu göstermektedir. Piksel konumlarının uzaklığı

$$d_{x,y}(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (2.28)$$

eşitliği ile hesaplanmaktadır. Burada x_i , y_i , x_j ve y_j N_i . ve N_j . piksel konumlarını göstermektedir. Bu benzerlik ölçütü Gauss çekirdek fonksiyonu ile farklı uzaya aktarılmakta ve konum benzeşimleri

$$S_{x,y}(i,j) = \exp(-d_{x,y}^2(i,j)/2) \quad (2.29)$$

şeklinde tanımlanmaktadır. Piksel yeğlilik ve konumları belli bir λ düzenleştirme terimi ile

$$S(i,j) = S_I(i,j) + \lambda S_{x,y}(i,j) \quad (2.30)$$

birleştirilmekte ve üç boyutlu öznitelik vektörlerinin kümelenmesi için kullanılan benzeşim ölçütü tanımlanmaktadır. Burada λ piksel konumlarının baskınlığını ayarlamaktadır. Süperpiksel boyutu S olmak üzere $2S$ alan içerisinde M pencere büyüklüğü 9 olarak seçilerek 3×3 pencereler arasında benzeşimler hesaplanmaktadır. Benzeşim değerlerine göre süperpiksel grupları belli bir özyineleme sayısı ile k-ortalamar yöntemine göre oluşturulmaktadır. Algoritma sonunda oluşturulmak istenen süperpiksel alanından çok küçük süperpikseller büyük alanlı komşu süperpikseller ile birleştirilmektedir.

2.3.1.2. Karışım Tabanlı Süperpiksel Yöntemi

Çoklu-bakış SAR imgesi için kuramsal yeğlilik ve genlik istatistiği sırasıyla Gamma ve Nakagami dağılımı olarak modellenmektedir [20]. SAR imgesinin istatistiksel modeli istatistiksel çarpımsal gürültü varsayımı altında elde edildiğinden imgedeki benek gürültülerine karşı etkilidir. Karışım Tabanlı Süperpiksel (Mixture-based Superpixel, MISP) [8]-[10] yöntemi SAR imgesinin istatistiksel bilgisinden faydalanarak süperpikselleri üretmektedir. Bu yöntemde Gestalt tabanlı algısal gruplama ilkelerinden [21] benzeşim ve yakınlık ilkeleri kullanılmaktadır. Benzeşim ölçütü olarak Nakagami dağılımı kullanılmaktadır. Aynı gruptaki iki piksel aynı Nakagami dağılımına sahip olduğu kabul edilmektedir. Yakınlık ölçütünde pikseller arasındaki uzamsal mesafe istatistiği iki değişkenli Gauss dağılımı olarak modellenmektedir. Benzeşim ve yakınlık istatistiği ölçütü Sonlu Karışım Modeli (SKM) ile birleştirilmektedir. SKM modelinde bu iki istatistiksel model kullanılarak pikseller süperpiksel merkezleri etrafında kümelenmektedir.

Yöntemin matematiksel modellenmesi olarak piksel genlikleri $a_n \in \mathbf{R}^+$ ve koordinatları $\mathbf{q}_n = [x_n, y_n]^T \in \mathbf{R}^2$ olmak üzere n . piksele ait öznitelik vektörü $\mathbf{f}_n = [a_n, x_n, y_n]^T$ olarak gösterilmektedir. Genlik ve koordinatlar istatistiksel olarak

bağımsız kabul edilmekte ve $p(a_n, \mathbf{q}_n | \theta) = p(a_n | \theta)p(\mathbf{q}_n | \theta)$ şeklinde yazılmaktadır. Burada θ parametre kümesini temsil etmektedir. Piksel genlikleri Nakagami dağılımı ile

$$p(a_n | \mu_k, v_k) = \frac{2}{\Gamma(v_k)} \left(\frac{v_k}{\mu_k}\right)^{v_k} a_n^{2v_k-1} e^{-v_k \frac{a_n^2}{\mu_k}} \quad (2.31)$$

olarak modellenmektedir. Burada μ_k ve v_k k . süperpiksele ait parametrelerdir. Piksellerin süperpiksel merkezleri etrafında normal dağılımlı olduğu kabul edilmektedir. Bu durumda piksel koordinat dağılımları

$$p(\mathbf{q}_n | \mathbf{m}_k, \mathbf{\Sigma}_k) = \frac{1}{2\pi |\mathbf{\Sigma}_k|^{\frac{1}{2}}} \exp\{(\mathbf{q}_n - \mathbf{m}_k)^T \mathbf{\Sigma}_k^{-1} (\mathbf{q}_n - \mathbf{m}_k)\} \quad (2.32)$$

olarak gösterilmektedir. Burada \mathbf{m}_k ve $\mathbf{\Sigma}_k$ sırasıyla k . süperpiksele ait ortalama vektörü ve kovaryans matrisini göstermektedir. Bu durumda k . süperpiksele ait parametre kümesi $\theta_k = \{\mu_k, v_k, \mathbf{m}_k, \mathbf{\Sigma}_k\}$ olarak tanımlanmaktadır.

Süperpiksellerin birbirleriyle örtüşmeyecek şekilde olması amaçlanmaktadır. İmge içerisinde K adet süperpiksel olduğu kabul edilirse her piksel için K boyutlu etiket vektörü $\mathbf{z}_n \in \{0, 1\}^K$ olarak tanımlanmaktadır. $z_{n,k}$ gösterge değeri

$$z_{n,k} = \begin{cases} 1 & n. \text{ piksel } K. \text{ süperpiksele ait ise} \\ 0 & \text{diğer} \end{cases} \quad (2.33)$$

şeklinde tanımlanmaktadır. İkili \mathbf{z}_n etiket vektörü $\sum_{k=1}^K z_{n,k} = 1$ özelliğine sahiptir. Burada vektör sadece bir süperpiksel için 1 değerini almaktadır. Bu durumda $\mathbf{z}_n \in \{[1, 0, \dots, 0], [0, 1, \dots, 0], \dots, [0, 0, \dots, 1]\}$ şeklinde yazılmaktadır. Ayrıca \mathbf{z}_n etiket vektörlerinin \mathbf{f}_n öznitelik vektörlerinden koşullu bağımsız olduğu kabul edilmektedir. Bu durumda $p(\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_n | \mathbf{z}_{1:N}) = p(\mathbf{f}_1 | \mathbf{z}_{1:N})p(\mathbf{f}_2 | \mathbf{z}_{1:N}) \dots p(\mathbf{f}_n | \mathbf{z}_{1:N})$ olmaktadır. \mathbf{z}_n önsel dağılımı multinominal dağılımlı olarak

$$p(\mathbf{z}_n | w_{1:K}) = \prod_{k=1}^K w_k^{z_{n,k}} \quad (2.34)$$

şeklinde tanımlanmaktadır. Burada $w_{1:K}$ multinominal dağılımın parametresidir. Multinominal dağılımın doğal eşlenik önsel dağılımı Dirichlet dağılımı olarak tanımlanmaktadır [22]. Bu durumda $p(w_{1:K})$ için önsel dağılım

$$p(w_{1:K}) = \frac{1}{\beta(\alpha)} \prod_{k=1}^K w_k^{\alpha_k} \quad (2.35)$$

olmaktadır. Burada α yoğunlaşma terimi β beta fonksiyonudur ve $\beta(\alpha) = \Gamma^K(\alpha)/\Gamma(\alpha K)$ şeklinde gamma fonksiyonu ile hesaplanmaktadır.

Bu tanımlamalardan sonra \mathbf{f}_n öznitelik vektörü ve \mathbf{z}_n etiketlerinin koşullu ortak yoğunluk olasılığı

$$\begin{aligned} p(\mathbf{f}_n, \mathbf{z}_n | \theta_{1:K}, w_{1:K}) &= \frac{p(\mathbf{f}_n, \mathbf{z}_n, \theta_{1:K}, w_{1:K})}{p(\theta_{1:K}, w_{1:K})} \\ &= \frac{p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K}, w_{1:K}) p(\mathbf{z}_n, \theta_{1:K}, w_{1:K})}{p(\theta_{1:K}, w_{1:K})} \\ &= \frac{p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K}) p(\mathbf{z}_n | \theta_{1:K}, w_{1:K}) p(\theta_{1:K}, w_{1:K})}{p(\theta_{1:K}, w_{1:K})} \\ &= p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K}) p(\mathbf{z}_n | w_{1:K}) \end{aligned} \quad (2.36)$$

şeklinde ayrışmaktadır. İlk terimin $p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K})$ olasılığı

$$p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K}) = \prod_{k=1}^K p(\mathbf{f}_n | \theta_k)^{z_{n,k}} \quad (2.37)$$

olarak tanımlanırsa sonlu karışım yoğunluğu modeli

$$p(\mathbf{f}_n | \theta_{1:K}, w_{1:K}) = \sum_{\mathbf{z}_n} \prod_{k=1}^K [p(\mathbf{f}_n | \theta_k) w_k]^{z_{n,k}} \quad (2.38)$$

şeklinde elde edilmektedir. Burada w_k sonlu karışım modelinin karışım oranını göstermektedir.

MISP yönteminde süperpiksel etiketleri $\mathbf{z}_{1:N}$, Nakagami ve Gauss dağılımlarının parametre kümesi $\theta_{1:K}$ ve karışım oranları $w_{1:K}$ olmak üzere üç adet hesaplanması gereken değişken kümesi mevcuttur. Ortak sonsal dağılım

$$\begin{aligned}
p(\mathbf{z}_{1:N}, \theta_{1:K}, w_{1:K} | \mathbf{f}_{1:N}) &= \frac{p(\mathbf{f}_{1:N} | \mathbf{z}_{1:N}, \theta_{1:K}, w_{1:K}) p(\mathbf{z}_{1:N}, \theta_{1:K}, w_{1:K})}{p(\mathbf{f}_{1:N})} \\
&= \frac{p(\mathbf{f}_{1:N} | \mathbf{z}_{1:N}, \theta_{1:K}) p(\mathbf{z}_{1:N} | \theta_{1:K}, w_{1:K}) p(\theta_{1:K}, w_{1:K})}{p(\mathbf{f}_{1:N})} \quad (2.39) \\
&\approx p(\mathbf{f}_{1:N} | \mathbf{z}_{1:N}, \theta_{1:K}) p(\mathbf{z}_{1:N} | w_{1:K})
\end{aligned}$$

olarak yazılmaktadır. Eşitliğin sağ tarafındaki ilk olabilirlik terimi

$$p(\mathbf{f}_{1:N} | \mathbf{z}_{1:N}, \theta_{1:K}) = \prod_{n=1}^N \prod_{k=1}^K [p(a_n | \theta_k) p(\mathbf{q}_n | \theta_k)]^{z_{n,k}} \quad (2.40)$$

olarak gösterilmektedir. Süperpiksel etiketlerinin ortak önsel dağılımı

$$p(\mathbf{z}_{1:N} | w_{1:K}) = \prod_{n=1}^N \prod_{k=1}^K w_k^{z_{n,k}} \quad (2.41)$$

olmaktadır. Eşitlik (2.39)'daki ortak sonsal dağılım işlenebilir olmadığı için blok yineli koşullu mod (Iterated Conditional Mode - ICM) [23] algoritması ile çözüm bulunmaktadır. Dağılımlara ait parametre kümesi en büyük olabilirlik kestirimi ile bulunmaktadır. Herhangi bir t anı için k . süperpiksel için Gauss dağılımının parametreleri \mathbf{m}_k ve Σ_k sırasıyla

$$\mathbf{m}_k^t = \frac{1}{N_k} \sum_{n \in S_k} \mathbf{q}_n \quad (2.42)$$

$$\Sigma_k^t = \frac{1}{N_k} \sum_{n \in S_k} (\mathbf{q}_n - \mathbf{m}_k^t)(\mathbf{q}_n - \mathbf{m}_k^t)^T \quad (2.43)$$

eşitlikleri ile hesaplanmaktadır. Burada \mathbf{q}_n piksel konumlarını, S_k k . süperpiksele ait piksel sayısını göstermektedir. Nakagami dağılımının parametrelerinden μ_k

$$\mu_k^t = \frac{1}{N_k} \sum_{n \in S_k} a_n^2 \quad (2.44)$$

şeklinde kestirilmektedir. Nakagami dağılımının diğer parametresi v_k 'nin kapalı formda çözümü olmadığından en büyük olasılık kestirimine (Maximum Likelihood Estimation - MLE) göre bulunmaktadır. Nakagami dağılımının türevinin sıfır olduğu yerde v_k bulunmaktadır. Matematiksel olarak Nakagami dağılımı

$$p(a_n | \mu_k, v_k) = \frac{2}{\Gamma(v_k)} \left(\frac{v_k}{\mu_k}\right)^{v_k} a_n^{2v_k-1} e^{-v_k \frac{a_n^2}{\mu_k}} \quad (2.45)$$

şeklindedir. Burada kestirmek istediğimiz v_k parametresi θ olarak gösterilsin. Bu durumda N adet piksel seti için eşitlik

$$p(a_{1:N} | \mu_k, v_k) = \sum_{n=1}^N \frac{2}{\Gamma(\theta)} \left(\frac{\theta}{\mu_k}\right)^{\theta} a_n^{2\theta-1} e^{-\theta \frac{a_n^2}{\mu_k}} \quad (2.46)$$

şeklindedir. Burada her iki tarafın logaritmasının türevini alırsak

$$L(\theta) = \sum_{n=1}^N \left[\log 2 - \log \Gamma(\theta) + \theta \log(\theta) - \theta \log \mu_k + (2\theta - 1) \log a_n - \frac{\theta a_n^2}{\mu_k} \right] \quad (2.47)$$

$$\frac{dL(\theta)}{d\theta} = \sum_{n=1}^N \left[-\frac{\Gamma'(\theta)}{\Gamma(\theta)} + \log(\theta) + \theta \frac{1}{\theta} - \log \mu_k + 2 \log a_n - \frac{a_n^2}{\mu_k} \right] = 0 \quad (2.48)$$

olmaktadır. Burada $-\frac{\Gamma'(\theta)}{\Gamma(\theta)} = \Psi(\theta)$ ve $\mu_k = \frac{1}{N} \sum_{n=1}^N a_n^2$ şeklinde tanımlanmaktadır. Bu durumda Eşitlik (2.48)

$$-\Psi(\theta) + \log \frac{\theta}{\mu_k} + 1 + \frac{2}{N} \sum_{n=1}^N \log a_n - \frac{1}{N} \sum_{n=1}^N \frac{a_n^2}{\mu_k} = 0 \quad (2.49)$$

$$-\Psi(v_k) + \log \frac{v_k}{\mu_k} + 1 + \frac{2}{N} \sum_{n=1}^N \log a_n - 1 = 0 \quad (2.50)$$

$$\log \frac{v_k}{\mu_k^{\frac{1}{t-1}}} - \Psi(v_k) + \frac{2}{N} \sum_{n=1}^N \log a_n = 0 \quad (2.51)$$

olarak Eşitlik (2.51) kullanılarak sıfır bulma yöntemiyle özyineli olarak bulunmaktadır. Burada Ψ digamma fonksiyonu olarak adlandırılmaktadır. Digamma fonksiyonu gamma fonksiyonunun logaritmik türevinden elde edilmektedir. Sonlu karışım modelinin karışım oranı parametresi için Dirichlet önsel dağılımı tanımlandığı için karışım oranları en büyük sonsal kestirim (Maximum a Posteriori - MAP) yöntemiyle bulunmaktadır. Karışım oranı w_k için önsel dağılım

$$p(w_{1:K}) = \frac{1}{\beta(\alpha)} \prod_{k=1}^K w_k^{\alpha-1} \quad (2.52)$$

şeklinde, olabilirlik dağılımı

$$p(\mathbf{z}_{1:N} | w_{1:K}) = \prod_{n=1}^N \prod_{k=1}^K w_k^{z_{n,k}} \quad (2.53)$$

olarak tanımlanmaktadır. Bu durumda w_k karışım oranının logaritmik en büyük sonsal kestirime göre çözümü

$$\max_{w_k} \log(p(\mathbf{z}_{1:N} | w_{1:K}) p(w_{1:K})) \quad (2.54)$$

$$\log \left[\prod_{n=1}^N \prod_{k=1}^K w_k^{z_{n,k}} \frac{1}{\beta(\alpha)} \prod_{k=1}^K w_k^{\alpha-1} \right] \quad (2.55)$$

$$\sum_{n=1}^N \sum_{k=1}^K z_{n,k} \log w_k - \log \beta(\alpha) + (\alpha - 1) \sum_{k=1}^K \log w_k \quad (2.56)$$

şeklindedir. Karışım oranlarını 0 ile 1 arasında sınırlandırmak için λ değişkeni tanımlanmaktadır.

$$\begin{aligned} & \sum_{n=1}^N \sum_{k=1}^K z_{n,k} \log w_k - \log \beta(\alpha) + (\alpha - 1) \sum_{k=1}^K \log w_k \\ & + \lambda \left(1 - \sum_{j=1}^K w_j \right) \end{aligned} \quad (2.57)$$

Bu durumda w_j 'nin en büyük sonsal kestirimi

$$\begin{aligned} & \frac{\partial}{\partial w_j} \left[\sum_{n=1}^N \sum_{k=1}^K z_{n,k} \log w_k - \log \beta(\alpha) + (\alpha - 1) \sum_{k=1}^K \log w_k \right. \\ & \left. + \lambda \left(1 - \sum_{j=1}^K w_j \right) \right] = 0 \end{aligned} \quad (2.58)$$

$$\sum_{n=1}^N z_{n,j} \frac{1}{w_j} + \frac{\alpha - 1}{w_j} - \lambda = 0 \quad (2.59)$$

$$w_j = \frac{\sum_{n=1}^N z_{n,j} + \alpha - 1}{\lambda} \quad (2.60)$$

şeklinde bulunmaktadır. Burada λ değeri en büyük olabilirlik kestirimi ile bulunmaktadır. Eşitlik (2.60)'da elde edilen w_j değeri Eşitlik (2.57)'de yerine konulursa λ için en büyük olabilirlik kestirimi

$$\begin{aligned}
& \frac{\partial}{\partial \lambda} \left[\sum_n \sum_k z_{n,k} \log \frac{\sum_{n=1}^N z_{n,j} + \alpha - 1}{\lambda} - \log \beta(\alpha) \right. \\
& \quad \left. + (\alpha - 1) \sum_{k=1}^K \log \frac{\sum_{n=1}^N z_{n,j} + \alpha - 1}{\lambda} + \lambda \left(1 - \sum_{j=1}^K \frac{\sum_{n=1}^N z_{n,j} + \alpha - 1}{\lambda} \right) \right] = 0
\end{aligned} \tag{2.61}$$

$$- \sum_n \sum_k z_{n,k} \frac{1}{\lambda} - \sum_k \frac{(\alpha - 1)}{\lambda} + 1 = 0 \tag{2.62}$$

$$\lambda = N + K(\alpha - 1) \tag{2.63}$$

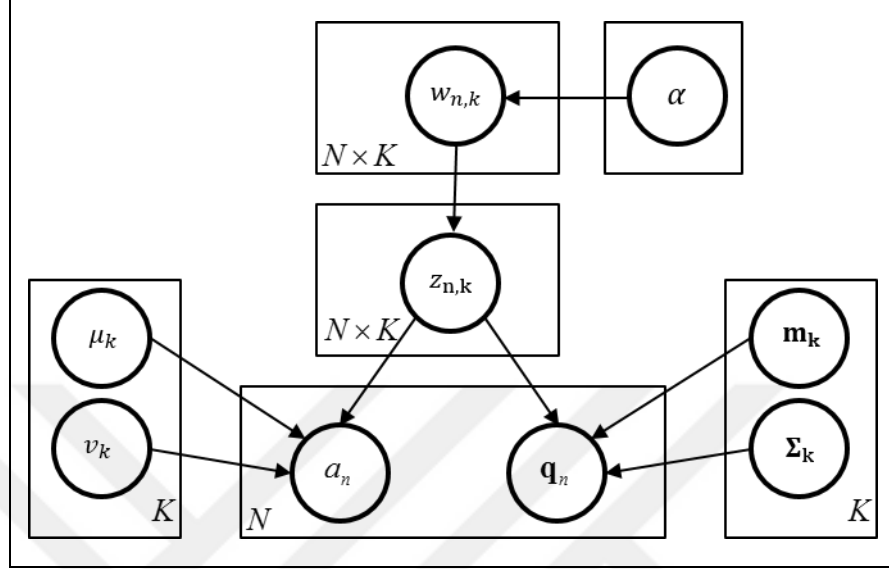
şeklinde elde edilmektedir. Bu durumda karışım oranları için en büyük sonsal kestirim eşitliği

$$w_j = \frac{\sum_{n=1}^N z_{n,j} + \alpha - 1}{N + K(\alpha - 1)} \tag{2.64}$$

olmaktadır. Algoritmanın tüm değişkenleri blok ICM algoritması ile kestirilmektedir. ICM algoritmasından farklı olarak blok ICM algoritması aynı tür değişkenleri birlikte güncellemektedir. Bu durumda geleneksel ICM algoritması yerine daha hızlı çalışan algoritma elde etmekteyiz [23]. Değişkenler özyineleme boyunca aşağıdaki sıra ile güncellenmektedir.

$$\begin{aligned}
\mathbf{z}_n^t & \leftarrow \max_{\mathbf{z}_n} p(\mathbf{f}_n | \mathbf{z}_n, \theta_{1:K}^{t-1}) p(\mathbf{z}_n | w_{1:K}^{t-1}) \\
\theta_k^t & \leftarrow \max_{\theta_k} p(\mathbf{f}_{1:N} | \mathbf{z}_{1:N}^t, \theta_k) \\
w_k^t & \leftarrow \max_{w_k} p(\mathbf{z}_{1:N}^t | w_{1:K}) p(w_{1:K})
\end{aligned} \tag{2.65}$$

Burada $n = 1, \dots, N, k = 1, \dots, K$ ve t sözde zaman indisidir. Özyineleme sonunda farklı dağılımlara sahip süperpikseller oluşmaktadır. Karışım modelinde rastgele değişkenlerin birbirleriyle ilişkisi Şekil 2.2’de gözlemlenmektedir.



Şekil 2.2: MISP yönteminde rastgele değişkenlerin birbirleriyle olan ilişkisi.

2.3.2. Hiperspektral İmgeler için Önerilen Süperpiksel Yöntemi

Yüksek boyutlu vektörlerin parametre kestiriminde kovaryans matrisi tekil olabilmekte ve bunun sonucunda parametreler yanlış bir şekilde kestirilmektedir. Mevcut süperpiksel algoritmaları üç kanallı RGB ya da tek kanallı gri-seviyeli görüntüler için önerilmektedir. Bu sebeplerden dolayı hiperspektral görüntüdeki D boyutlu başlangıç piksel uzayı Bölüm 4.3’te Temel Bileşen Analizi (TBA) yöntemiyle üç boyuta düşürülmektedir.

2.3.2.1. Gauss Karışım Modeli Süperpikselleri

Gauss Karışım Modeli (GKM) süperpikselleri yöntemini ilk olarak [11]’de önermekteyiz. [11]’deki yöntemle göre piksel genlikleri ve koordinatları için ortak Gauss dağılımı kestirilirken bu tezde piksel genlikleri ve konumları için iki ayrı Gauss dağılımı kestirilerek olasılıklar SKM ile birleştirilmektedir. GKM süperpiksellerinde piksel genlikleri $\mathbf{a}_n \in \mathbf{R}^3$ ve koordinatları $\mathbf{c}_n = [x_n, y_n]$, $n = 1, \dots, N$ olarak gösterilmektedir. Bu durumda n . piksele ait öznitelik vektörü $\mathbf{f}_n =$

$[\mathbf{a}_n, \mathbf{c}_n]$ şeklinde tanımlanmaktadır. Burada piksel genlik ve koordinatları istatistiksel bağımsız olarak $p(\mathbf{f}_n|\theta) = p(\mathbf{a}_n|\theta)p(\mathbf{c}_n|\theta)$ şeklinde ve θ parametre kümesini göstermektedir. Piksel genlikleri

$$p(\mathbf{a}_n; \boldsymbol{\mu}_{k_1}, \boldsymbol{\Sigma}_{k_1}) = \frac{1}{(2\pi)^{3/2}} \frac{1}{|\boldsymbol{\Sigma}_{k_1}|^{1/2}} e^{\left\{-\frac{1}{2}(\mathbf{a}_n - \boldsymbol{\mu}_{k_1})^T \boldsymbol{\Sigma}_{k_1}^{-1} (\mathbf{a}_n - \boldsymbol{\mu}_{k_1})\right\}} \quad (2.66)$$

şeklindedir. Piksel konumları ise

$$p(\mathbf{q}_n; \boldsymbol{\mu}_{k_2}, \boldsymbol{\Sigma}_{k_2}) = \frac{1}{2\pi} \frac{1}{|\boldsymbol{\Sigma}_{k_2}|^{1/2}} e^{\left\{-\frac{1}{2}(\mathbf{q}_n - \boldsymbol{\mu}_{k_2})^T \boldsymbol{\Sigma}_{k_2}^{-1} (\mathbf{q}_n - \boldsymbol{\mu}_{k_2})\right\}} \quad (2.67)$$

olarak tanımlanmaktadır. Bu durumda sonlu karışım yoğunluğunu

$$p(\mathbf{f}_n | \theta_{1:K}, w_{1:K}) = \sum_{z_n} \prod_{k=1}^K [p(\mathbf{f}_n | \theta_k) w_k]^{z_{n,k}} \quad (2.68)$$

şeklinde göstermekteyiz. Burada w_k karışım oranı, $z_{n,k}$ Bölüm 2.3.1.2’de olduğu gibi etiket vektörü elemanıdır. w_k karışım oranı için önsel dağılım $p(w_{1:K}) = \frac{1}{\beta(\alpha)} \prod_{k=1}^K w_k^{\alpha - z_{n,k}}$ şeklinde tanımlamaktayız. Burada K süperpiksel sayısı, $k = \{1, 2, \dots, K\}$ şeklindedir. Bu durumda k . süperpiksele ait parametre kümesi $\theta = \{\boldsymbol{\mu}_{k_1}, \boldsymbol{\Sigma}_{k_1}, \boldsymbol{\mu}_{k_2}, \boldsymbol{\Sigma}_{k_2}, w_k\}$ olarak tanımlanmaktadır. Herhangi bir i . özyinelemede k . süperpiksele ait parametreler sırasıyla

$$\boldsymbol{\mu}_{k_1}^i = \frac{1}{m_k^{i-1}} \sum_{j=1}^{m_k^{i-1}} \mathbf{a}_{j,k}^{i-1} \quad (2.69)$$

$$\boldsymbol{\Sigma}_{k_1}^i = \frac{1}{m_k^{i-1}} \sum_{j=1}^{m_k^{i-1}} (\mathbf{a}_{j,k}^{i-1} - \boldsymbol{\mu}_{k_1}^i)(\mathbf{a}_{j,k}^{i-1} - \boldsymbol{\mu}_{k_1}^i)^T \quad (2.70)$$

$$\boldsymbol{\mu}_{k_2}^i = \frac{1}{m_k^{i-1}} \sum_{j=1}^{m_k^{i-1}} \mathbf{q}_{j,k}^{i-1} \quad (2.71)$$

$$\boldsymbol{\Sigma}_{k_2}^i = \frac{1}{m_k^{i-1}} \sum_{j=1}^{m_k^{i-1}} (\mathbf{q}_{j,k}^{i-1} - \boldsymbol{\mu}_{k_2}^i)(\mathbf{q}_{j,k}^{i-1} - \boldsymbol{\mu}_{k_2}^i)^T \quad (2.72)$$

$$w_k^i = \frac{\sum_{n=1}^N z_{n,k} + \alpha - 1}{N + K(\alpha - 1)} \quad (2.73)$$

olarak kestirilmektedir. Burada m_k^{i-1} bir önceki özyinelemede k . süperpiksele ait piksel sayısıdır. Değişken setleri, süperpiksel etiketleri ve karışım oranları Eşitlik (2.65)'te olduğu gibi blok ICM algoritmasıyla özyineli olarak güncellenmektedir. Değişken setleri belli değere yakınsayınca algoritma sona ermekte ve süperpikseller oluşturulmaktadır.

2.4. Süperpikselerin Düzenlenmesi

Süperpiksel algoritmaları özyineleme tabanlı olduğu için algoritma sonunda süperpikseller uzamsal olarak farklı bölgelerde birden fazla bağlı bileşen içerebilmektedir. Süperpikseller oluşturulurken sadece bir bağlı bileşen içermesi ve tek nesneyle örtüşmesi istenmektedir. Bu sebeplerden dolayı birden fazla bağlı bileşen içeren süperpikseller sadece bir bağlı bileşene düşürülmekte ve farklı bölgelerdeki aynı etikete sahip süperpikseller ayrılmaktadır. Burada süperpiksel algoritmaları sonucunda üretilen bağlı bileşenlerin alanlarına bakılmaktadır. Oluşturulmak istenen süperpiksel alanından yaklaşık olarak $1/20$ 'lik oranında küçük alana sahip bağlı bileşenler en büyük alanlı komşu süperpikseller ile birleştirilmektedir. Böylelikle her süperpiksel bir bağlı bileşen içermekte ve farklı bölgelerdeki aynı etikete sahip süperpikseller ayrılmaktadır. Bu son işleme adımı her süperpiksel yöntemi için uygulanmaktadır.

2.5. Süperpiksel Başarım Metrikleri

Süperpiksel literatüründe süperpiksellerin birbirlerine göre başarımların değerlendirilmesi bölütleme hatası (Under-segmentation Error, UE) [4], sınır duyarlılığı (Boundary Recall, BR) [4] metrikleri yaygın olarak kullanılmaktadır. Bunun yanında süperpiksellerin derlitopluluğunu ölçmek için [24]'te önerilen derlitopluluk (Compactness, CM) metriği de kullanılmaktadır. Bu tez kapsamında süperpiksellerin başarımların karşılaştırmaları bölütleme hatası, sınır duyarlılığı ve derlitopluluk metrikleri kullanılarak yapılmaktadır.

2.5.1. Bölütleme Hatası

Bölütleme hatası (Under-segmentation Error, UE) metriği [4] yer gerçekliği haritasına göre imgenin bölütleme sonucundaki hatasını ölçmektedir. Bu hata bölütleme sonucu yer-gerçekliği haritasının sınırları dışında kalan süperpiksel alanına bakılarak ölçülmektedir. Bu tezde bölütleme hatası olarak [8]'de tanımlanan hata metriği

$$UE = \sum_k^K \sum_l^L \frac{|S_l \cap G_k^C|}{|S_l|} \quad (2.74)$$

kullanılmaktadır. Burada S_l süperpiksel alanı, G_k^C yer-gerçekliği haritasındaki k . sınıfın tümleyici alanı, K yer-gerçekliği haritasındaki sınıf sayısını, L süperpiksel sayısını göstermektedir. Yüksek UE değeri süperpiksellerin birden fazla nesne ile örtüşüğünü göstermektedir. UE değerinin düşük olması amaçlanmaktadır.

2.5.2. Sınır Duyarlılığı

Sınır duyarlılığı (Boundary Recall, BR) metriği [4] süperpiksel sınırlarının yer-gerçekliği haritasındaki nesne sınırları ile belli bir d uzaklığı içerisinde örtüşme oranını bakmaktadır. Burada genellikle $d = 2$ olarak seçilmektedir. G yer-gerçekliği sınır haritası, B bölütleme sonucu oluşan süperpiksel sınır haritası olmak üzere sınır duyarlılığı doğru pozitif (True Positive, TP) ve yanlış negatif (False Negative, FN) ölçütleri kullanılarak hesaplanmaktadır. Doğru pozitif G sınır haritasında sınır

piksellerinden d uzaklığındaki bölge içerisine düşen süperpiksel sınırlarının piksel sayısını, yanlış negatif G sınır haritasının d uzaklığı içerisinde B sınır haritası ile kesişmeyen sınır piksel sayısını göstermektedir. Bu durumda sınır duyarlılığı

$$BR = \frac{TP}{TP + FN} \quad (2.75)$$

olmaktadır. Yüksek BR oranı nesne sınırlarının iyi oranda korunduğunu göstermektedir.

2.5.3. Derlitopluluk

Derlitopluluk süperpiksellerin düzenli şekil ve boyutta olmasını temsil etmektedir. Süperpikseller üretilirken derlitoplu olması amaçlanmaktadır. Bu tezde derlitopluluk ölçüsü [24]'te önerilen isoperimetrik bölüm tabanlı derlitopluluk (Compactness, CM) metriğiyle hesaplanmaktadır. İso-perimetrik bölüm verilen herhangi bir şeklin alanının bu şekille aynı çevre uzunluğuna sahip daire alanı oranı olarak tanımlanmaktadır. Bu durumda herhangi bir daire şekli için bu oran 1 olmaktadır. A_s alanına ve L_s çevresine sahip herhangi bir süperpiksel için ilgili dairenin yarıçapı

$$r = \frac{L_s}{2\pi} \quad (2.76)$$

olarak bulunmaktadır. A_c , r yarıçaplı dairenin alanı ise isoperimetrik bölüm

$$Q_s = \frac{A_s}{A_c} = \frac{4\pi}{L_s^2} \quad (2.77)$$

şeklinde hesaplanmaktadır. Bu durumda verilen herhangi bir süperpiksel bölütleme haritası için derlitopluluk oranı her süperpikselin isoperimetrik bölümü ile ilgili süperpiksel alanının imgenin tüm alanına oranı ile çarpımlarının toplanmasıyla hesaplanmaktadır. \mathcal{O} süperpiksel seti olmak üzere I alanına sahip imge için derlitopluluk metriği

$$CO = \sum_{s \in \mathcal{S}} Q_s \frac{|S|}{|I|} \quad (2.78)$$

olarak hesaplanmaktadır. Derlitopluluk oranı düzenli ve pürüzsüz sınırlar için yüksek olmaktadır.




3. SAR İMGELERİN SÜPERPİKSEL TABANLI SINIFLANDIRILMASI

3.1. SAR İmgesine Giriş

SEASAT uydusunun 1978 yılında uzaya gönderilmesiyle başlayan sentetik açıklı radar (Synthetic Aperture Radar, SAR) görüntüleme sistemi yeryüzü görüntülenmesinde zengin bilgiler sunmaktadır. SAR uyduları yüzey dalgası, akış yönü, gemi geçişi, buz dağları gibi okyanus hareketlerini gözlemlemede, sel ve yangın alanlarının görüntülenmesinde, tarım alanlarında ürünlerin gelişmelerinin gözlemlenmesinde, insan ya da araç takibinde, şehir bölgesinin görüntülenmesi gibi birçok farklı alanda yaygın olarak kullanılmaktadır. SAR sensörleri 1m'nin birkaç cm aşağısına kadar küçük yüzey değişimlerine karşı duyarlı ve güneş ışınları, bulut örtüleri gibi hava koşullarından bağımsız olarak yüksek çözünürlüklü iki boyutlu görüntüler sağlamaktadır.

SAR sistemi yan-bakış görüntüleme geometrisine sahiptir. İleri yönde bir doğru üzerinde hareket ederek hedefe darbe sinyallerini sıralı bir şekilde gönderir. Hedeften geri saçılan sinyaller farklı pozisyonlarda radar antenleri tarafından toplanmaktadır. Toplanan sinyallerin evreuyumlu (coherent) kombinasyonları fiziksel anten aralığından daha uzun sanal açıklık yapısı sunmaktadır. Geri saçılan sinyalin genlik ve faz karakteristiği hedef nesnesinin fiziksel ve elektriksel özelliklerine bağlıdır.

Basit anlamda SAR sistemi gözlemlenen alandan 2-B yansıma haritası oluşturmaktadır. Hedef nesnesinden yüksek geri saçılan sinyaller parlak noktalar, düz yüzeylerden geri saçılan sinyaller karanlık noktalar ile gösterilmektedir. Sensör sisteminin uçuş yönü azimut (azimuth), hedefe bakış yönü eğik erim (slant range) olarak adlandırılır. Şekil 3.1'de SAR görüntüleme sisteminin geometrik yapısı gösterilmektedir. SAR sistemi azimut yönünde v hızıyla hareket etmektedir. Hedefin radar uçuşuna baktığı yön eğim aralığı (slant range), radar sahnesinin hedefi gördüğü aralık olarak genişliği (swath width) olarak adlandırılır. Burada r_0 en kısa yaklaşım uzaklığı, θ_a azimut hüzmeye açıklığını göstermektedir. Sistemin hareketi yavaş zaman (slow time) olarak adlandırılmakta ve hedefteki noktalarının zamandaki değişim



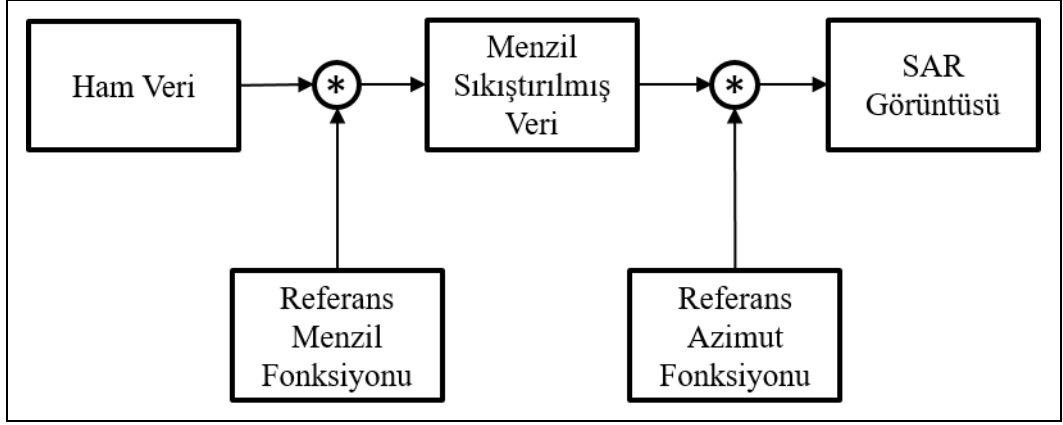
Şekil 3.1: SAR görüntüleme geometrisi.

çeşitliliği azimut fazı ile gösterilmektedir. Bu fazlar hafızada saklanır ve sinyal işleme sırasında kullanılarak sahnedeki nesne şekilleri çıkarılmaktadır [25].

Sisteme geri saçılan sinyal iki boyutlu karmaşık veri matrisi olup genlik ve fazla gösterilmektedir. İlk boyut hedef ile radar arasındaki doğru yönündeki karmaşık yankı sinyallerini içeren menzil (range) ile, ikinci boyut azimut ile ilişkilidir.

Standart optik sensörlere oranla işlenmemiş SAR veri seti doğrudan sahne hakkında kullanılabilir bilgi sunmamaktadır. Sinyal işleme adımları ile SAR görüntüsü kullanılabilir hale gelmektedir. Bu adımlar Şekil 3.2’de gösterildiği gibi menzil ve azimut boyutları için iki ayrı uyumlu süzgeç ile gerçekleştirilmektedir. İlk süzgeç işlenmiş SAR sinyallerini referans menzil fonksiyonu ile evrişimiyle kısa darbelerle sıkıştırılmaktadır. Bu süreç radar ile zemindeki herhangi bir noktanın uzaklıklarını vermektedir. İkinci süzgeç işlemi ise sıkıştırılmış görüntüyü uzaklığa göre değişim ve geometri ile alakalı referans azimut fonksiyonu ile evrişimiyle sahne resmi oluşturulmaktadır [25].

SAR görüntülerinde menzil çözünürlüğü darbe sıkıştırma yöntemleri ile geliştirilebilir. Azimut çözünürlüğü ise anten büyüklüğü ve radar dalga uzunluğuna bağlıdır. N_r menzil genişliği, N_a azimut hücre sayısı ise çözünürlük hücre sayısı $N_r N_a$ şeklinde hesaplanmaktadır [26]. SAR görüntüleri elde edilirken birçok farklı saçıcıların çözünürlük hücresinde evreuyumlu toplanması sonucu tuz-biber gürültüsü görünümünde benek gürültüsü oluşmaktadır.



Şekil 3.2: SAR görüntülerinin oluşturulması sırasında sinyal işleme süreci.

Genlik ve fazların evreyumlu toplanması hücreden hücreye güçlü dalgalanmalı geri saçılma neden olmaktadır. Bu sebepten dolayı nihai görüntünün yoğunluk ve faz değerleri deterministik olmamaktadır. Benek gürültüsü çarpımsal karakteristiğe sahiptir ve anten verici gücü artırılarak azaltılamamaktadır. Benek gürültüsünü azaltmak için çoklu-bakış görüntüleme tekniğinden faydalanılmaktadır. Çoklu-bakış tekniğinde görüntü spektral bant genişliğinin örtüşmeyen birkaç bölgeye bölünerek birbirinden istatistiksel bağımsız farklı bakış sahne imgeleri oluşturulmakta ve bu imgelerin birleştirilmesi sonucu oluşmaktadır. Bakış sayısı arttıkça benek gürültüsü azaltılmaktadır.

SAR sistemlerinde sahnenin kapsamlı nicel ve nitel fiziksel özelliklerinin çıkarımında polarizasyon tekniği kullanılmaktadır. Polarizasyon tekniğinde SAR sistemlerinde antenden gönderilen elektromanyetik dalga polarize edilmiş şekilde gönderilmektedir. Alıcı anten gönderilen polarize edilmiş dalgayı polarizasyon karakteristiğine göre algılamaktadır. Dalganın polarizasyonu sırasında yaygın olarak yatay (horizontal, H) ve dikey (vertical, V) olmak üzere iki temel teknik kullanılmaktadır. Karmaşık SAR sistemlerinde antenler tarafından birden fazla polarize edilmiş dalga gönderebilmektedir. Dalgalar antende sıralı olarak yatay ve dikey polarizasyonda gönderileceği gibi dairesel olarak aynı anda da gönderilebilir. Antenden gönderilen ve alınan polarizasyon türüne göre doğrusal polarizasyon çiftleri arasında polarizasyon kanalı oluşmaktadır. HH kanalı alınan ve gönderilen polarizasyonun türünün yatay olduğunu, VV kanalı alınan ve gönderilen polarizasyonun türünün dikey olduğunu, HV kanalı gönderilen yatay iken alınan


dalganın polarizasyon türünün dikey olması ve VH kanalı da gönderilen dikey iken alınan dalganın polarizasyon türünün yatay olduğunu göstermektedir [27].

3.2. SAR İmgesi Veri Kümesi

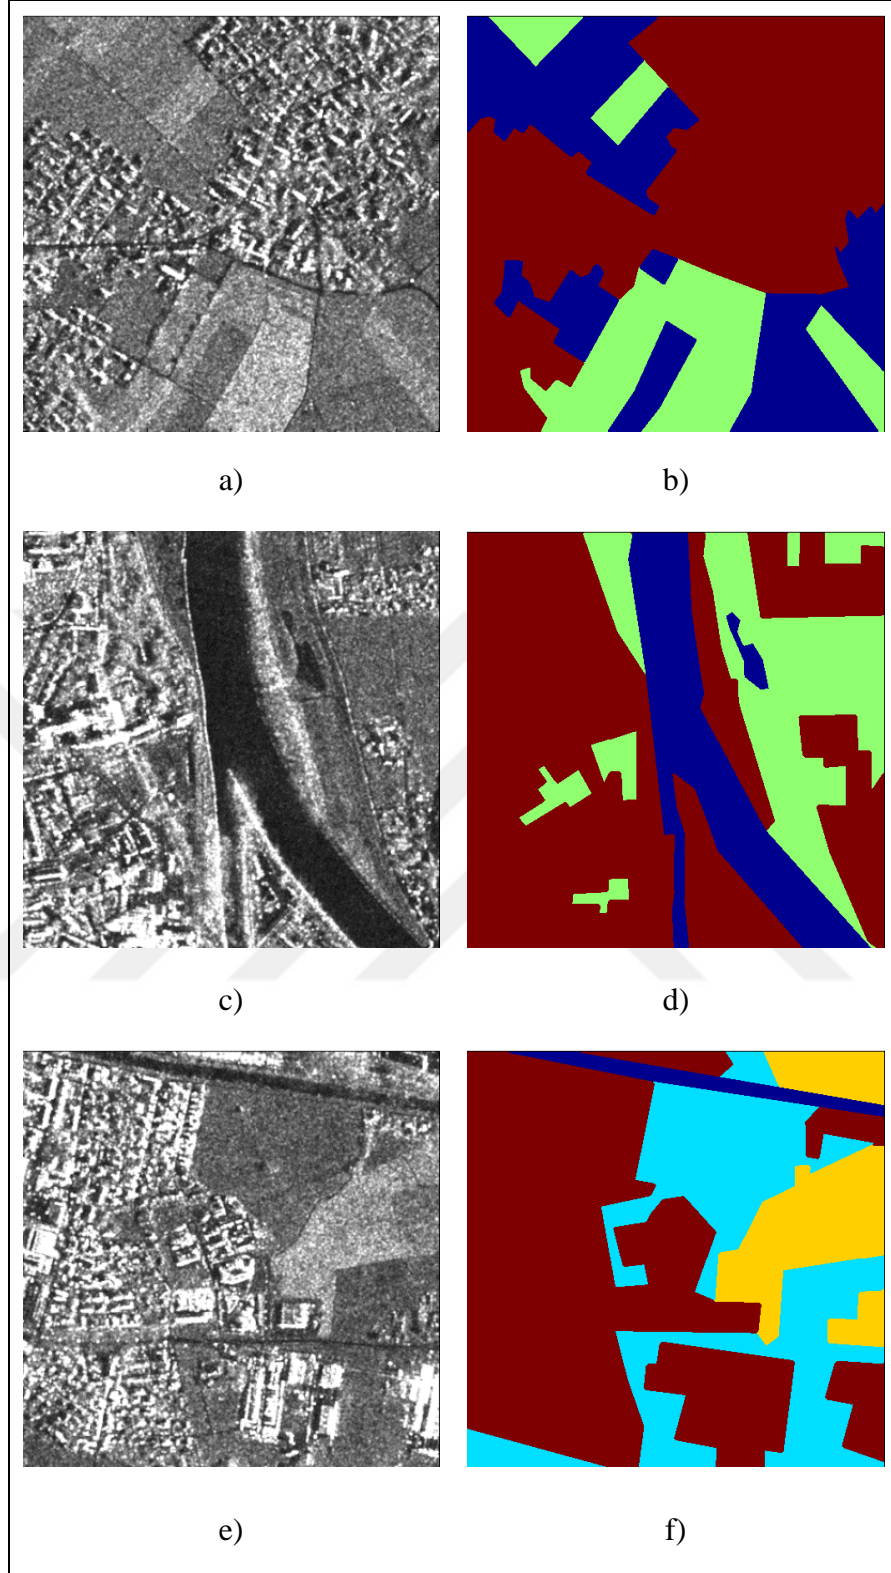
Almanya'nın 2007 yılında uzaya gönderdiği TerraSAR-X uydusu tarafından elde edilen SAR görüntüleri tez kapsamında kullanılmaktadır. Bu görüntüler Almanya'nın Rosenheim kentinden ve ABD'nin Mississippi eyaleti üzerinden çekilmiş görüntülerdir.

3.2.1. Rosenheim İmgesi

TerraSAR-X SpotLight uydusu tarafından 27 Ocak 2008 tarihinde Almanya'da bulunan Rosenheim kenti üzerinden elde edilmiştir. HH polarizeli, çoklu-bakış tekniğiyle çekilmiş olup bakış sayısı 4'tür. 8.2 m uzamsal çözünürlüğe sahiptir. İmge boyutu 9142x9428'tür. Şekil 3.3'te Rosenheim şehri görüntüsünün tamamı gösterilmektedir. Bu imgenin üç farklı bölgesinden 500x500 boyutlarında TSX1, TSX2 ve TSX3 imgeleri alınarak sınıflandırma yapılmaktadır. Kullanılan imgeler ve yer-gerçekliği haritaları Şekil 3.4'te gözlemlenmektedir.




Şekil 3.3: Rosenheim şehri imgesi.




Şekil 3.4: Rosenheim şehri imgesinden elde edilen TSX1, TSX2 ve TSX3 SAR imgeleri ve yer-gerçekliği haritaları. a) TSX1, b) TSX1-GT, c) TSX2, d) TSX2-GT, e) TSX3, f) TSX3-GT.

3.2.2. Mississippi İmgesi

ABD eyaletlerinden Mississippi'nin güneyinden 2 Ocak 2008 tarihinde TerraSAR-X StripMap uydusu tarafından elde edilmiştir. HH polarizeli, çoklu-bakış tekniğiyle elde edilmiş ve 6.9 m uzamsal çözünürlüğüne sahiptir. İmge boyutu 21666x15666 olup Şekil 3.5'te gösterilmektedir. Bu resim üzerinden 600x500 boyutunda TSX4 imgesi alınarak sınıflandırma yapılmaktadır. Alınan bölge ve yergerçekliği haritası Şekil 3.6'da gözlemlenmektedir.



Şekil 3.5: Mississippi bölgesi imgesi.



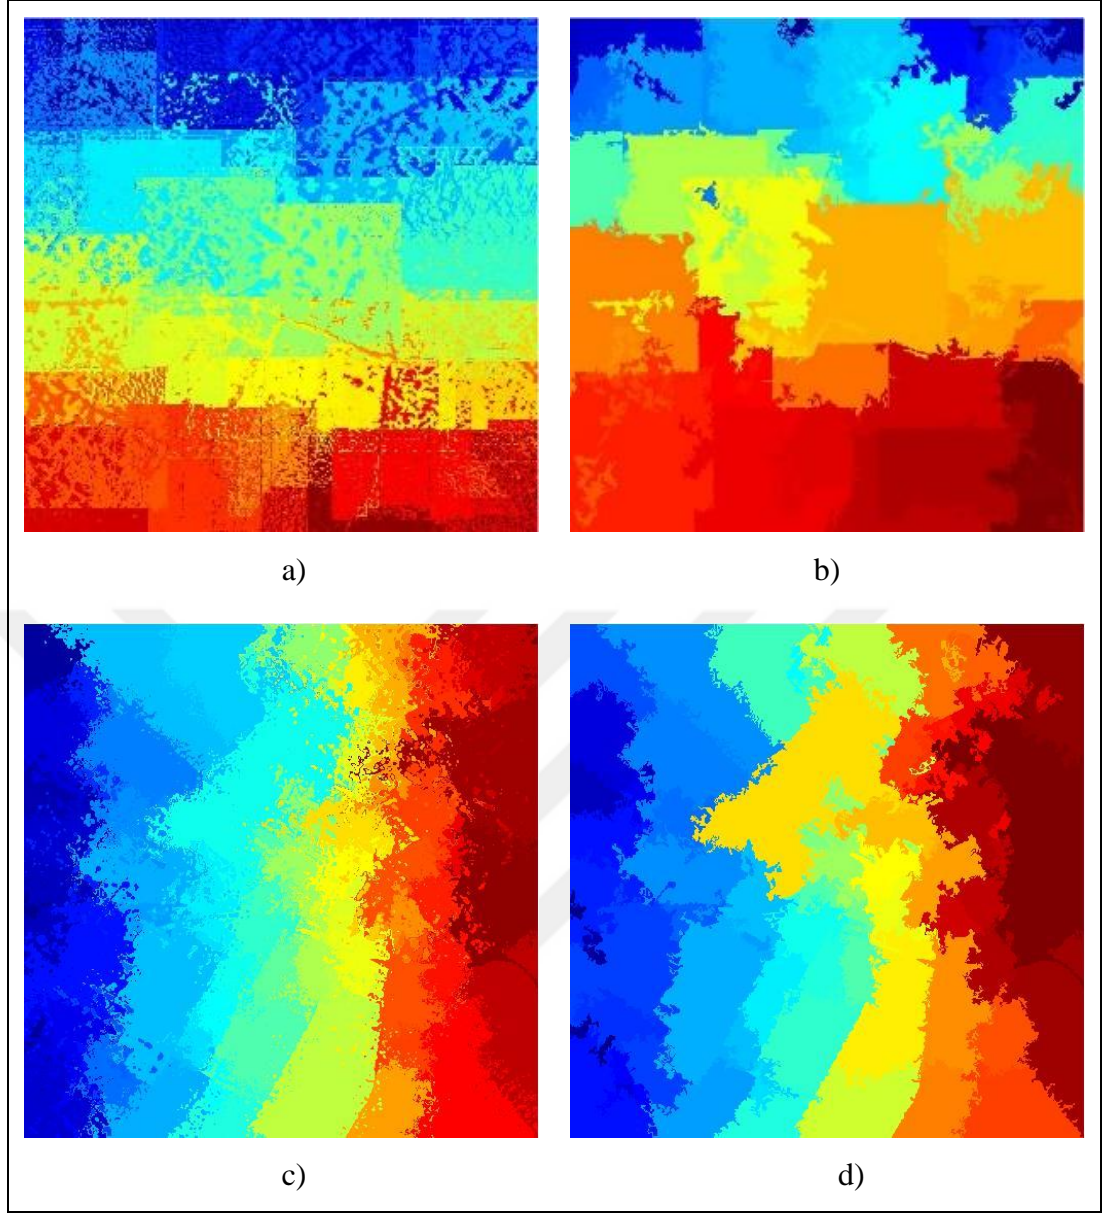
Şekil 3.6: Mississippi imgesinden elde edilen TSX4 SAR imgesi ve yergerçekliği haritası. a) TSX4, b) TSX4-GT.

3.3. SAR İmgelerden Süperpiksellerin Çıkarılması

TSX1, TSX2, TSX3 ve TSX4 görüntüleri tek kanallı 0-255 aralığında gri-seviyeli görüntülerdir. Bu bölümde SAR görüntülerinden NC, TP, ERS, SLIC, QS ve SAR imgelerine özgü önerilen PILS ve MISP yöntemleri kullanılarak süperpikseller çıkarılmakta ve algoritmaların birbirlerine göre başarımları karşılaştırılmaktadır. Süperpiksel algoritmalarının fonksiyon parametreleri sırasıyla şu şekilde seçilmektedir. NC ve TP algoritmalarında süperpikseller imgeden çıkarılırken fonksiyon parametresi olarak sadece üretilmek istenen süperpiksel sayısı girilmektedir. ERS yönteminde entropi oranı ve derlitopluluk arasındaki denge terimi 0.5 olarak, çekirdek bant genişliği 8 olarak ayarlanmaktadır. SLIC yönteminde kenarların düzgünlüğünü ayarlayan düzenleştirme parametresi 5 olarak sabitlenmektedir. QS yönteminde çekirdek fonksiyonu pencere büyüklüğü 10 olarak sabitlenmektedir. Süperpiksel sayısı maksimum uzaklık parametresi ile ayarlanmaktadır. PILS yönteminde piksel yeğînlîği ile konumu arasında baskınlığı ayarlayan denge terimi 2 olarak seçilmekte ve TSX1, TSX2 ve TSX3 imgelerin bakış sayısı 4, TSX4 imgesinin bakış sayısı 5 olarak alınmaktadır. MISP yönteminde karışım oranları için kullanılan α parametresi değeri 100000 olarak seçilmektedir. Başlangıç olarak karışım oranları $W_k = 1/K$ olarak seçilmektedir.

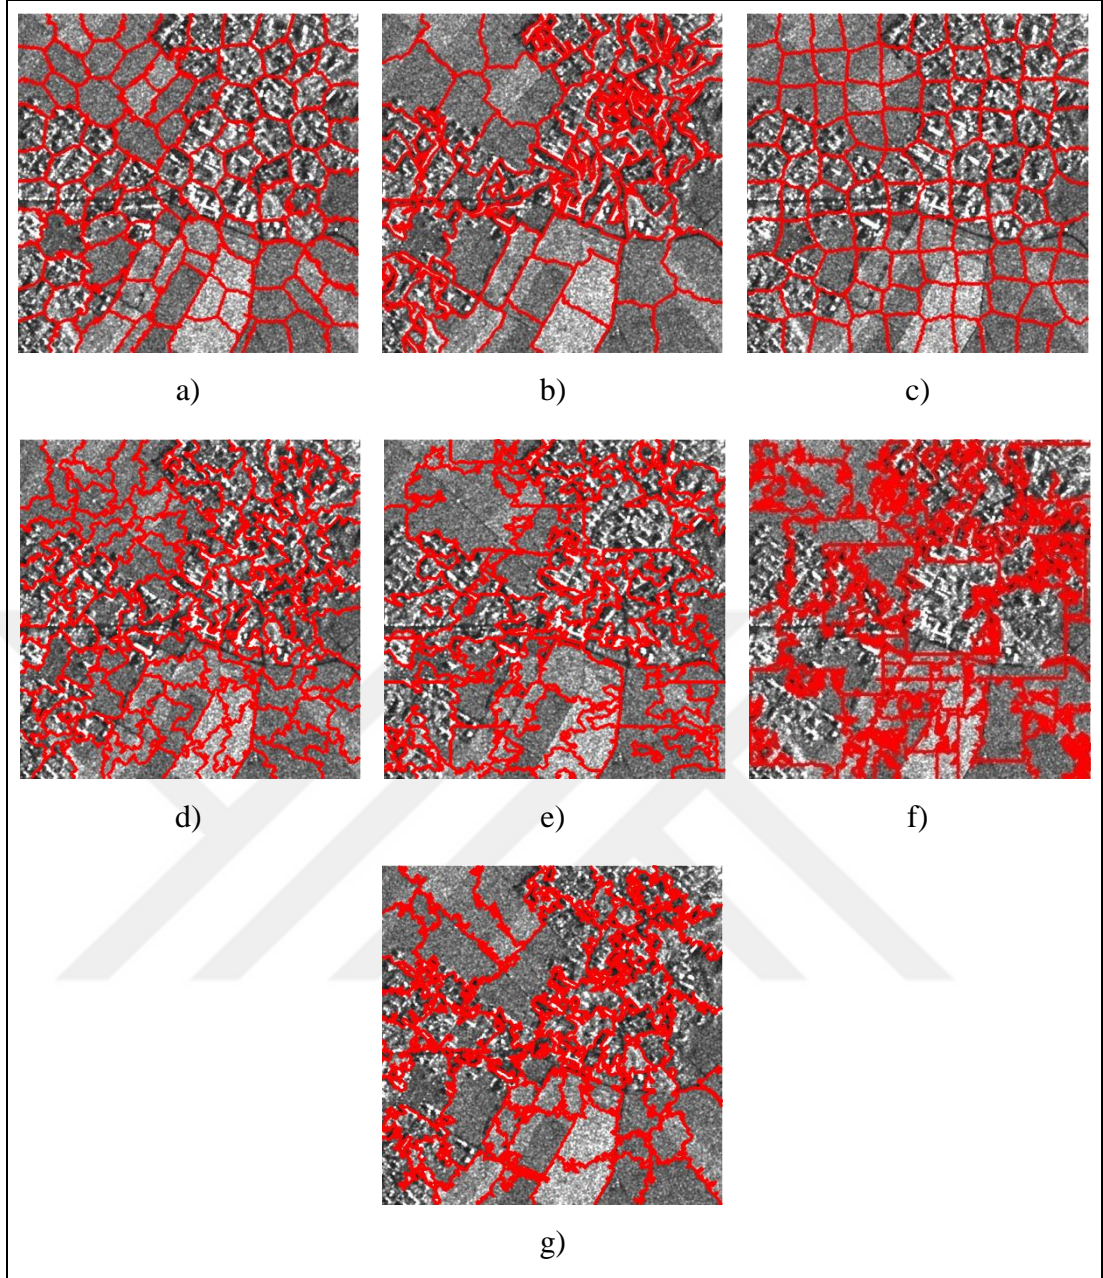
Kümeleme tabanlı süperpiksel yöntemleri piksellerin uzamsal bağımlılığını dikkate almamaktadır. Bu sebepten süperpikseller birden fazla bağılı bileşen içerebilmektedir. Örneğin TSX1 görüntüsünde 100 süperpiksel üretilmek istendiğinde bağılı bileşen sayısı NC, ERS, TP, MISP, QS, SLIC ve PILS yöntemleri için sırasıyla 100, 100, 104, 743, 6004, 7985 ve 13085 çıkmaktadır. Çizge tabanlı yöntemler istenilen süperpiksel sayısında bağılı bileşen içerirken, kümeleme tabanlı yöntemler istenilen süperpiksel sayısından fazla bağılı bileşen içermektedir. Bölüm 2.4'te anlatıldığı gibi her algoritmanın sonunda üretilmek istenilen süperpiksel alanının 1/20'sinden küçük bağılı bileşenler en yakın büyük alanlı komşu süperpikseller ile birleştirilmektedir.

TSX1 imgesinin PILS ve QS yöntemleri için küçük bağılı bileşenlerin işlenmemiş durumu ve komşuları ile birleştirilmiş durumuna bağılı süperpiksel haritaları sırasıyla Şekil 3.7.a), Şekil 3.7.c) ve Şekil 3.7.b), Şekil 3.7.d)'de




Şekil 3.7: TSX1 imgesi için PILS ve QS yöntemlerinde KBT süreci süperpiksel haritaları. a) PILS yönteminde KBT öncesi süperpiksel haritası, b) PILS yönteminde KBT sonrası süperpiksel haritası, c) QS yönteminde KBT öncesi süperpiksel haritası, d) QS yönteminde KBT sonrası süperpiksel haritası.

gözlemlenmektedir. Şekil 3.7.a) ve Şekil 3.7.c)'den görüldüğü gibi aynı etikete sahip süperpikseller farklı konumlarda birden fazla bölüt halinde olmakta ve büyük alanlı süperpiksellerin içerisinde küçük bölütlere sahip olmaktadır. Süperpiksellerin içerisinde küçük bileşenlerin temizlenmesi (KBT) sürecinden sonra Şekil 3.7.b) ve Şekil 3.7.d)'den görüldüğü gibi her bir süperpiksel tek bir konumda ve tek bir bölüte sahip olmaktadır.



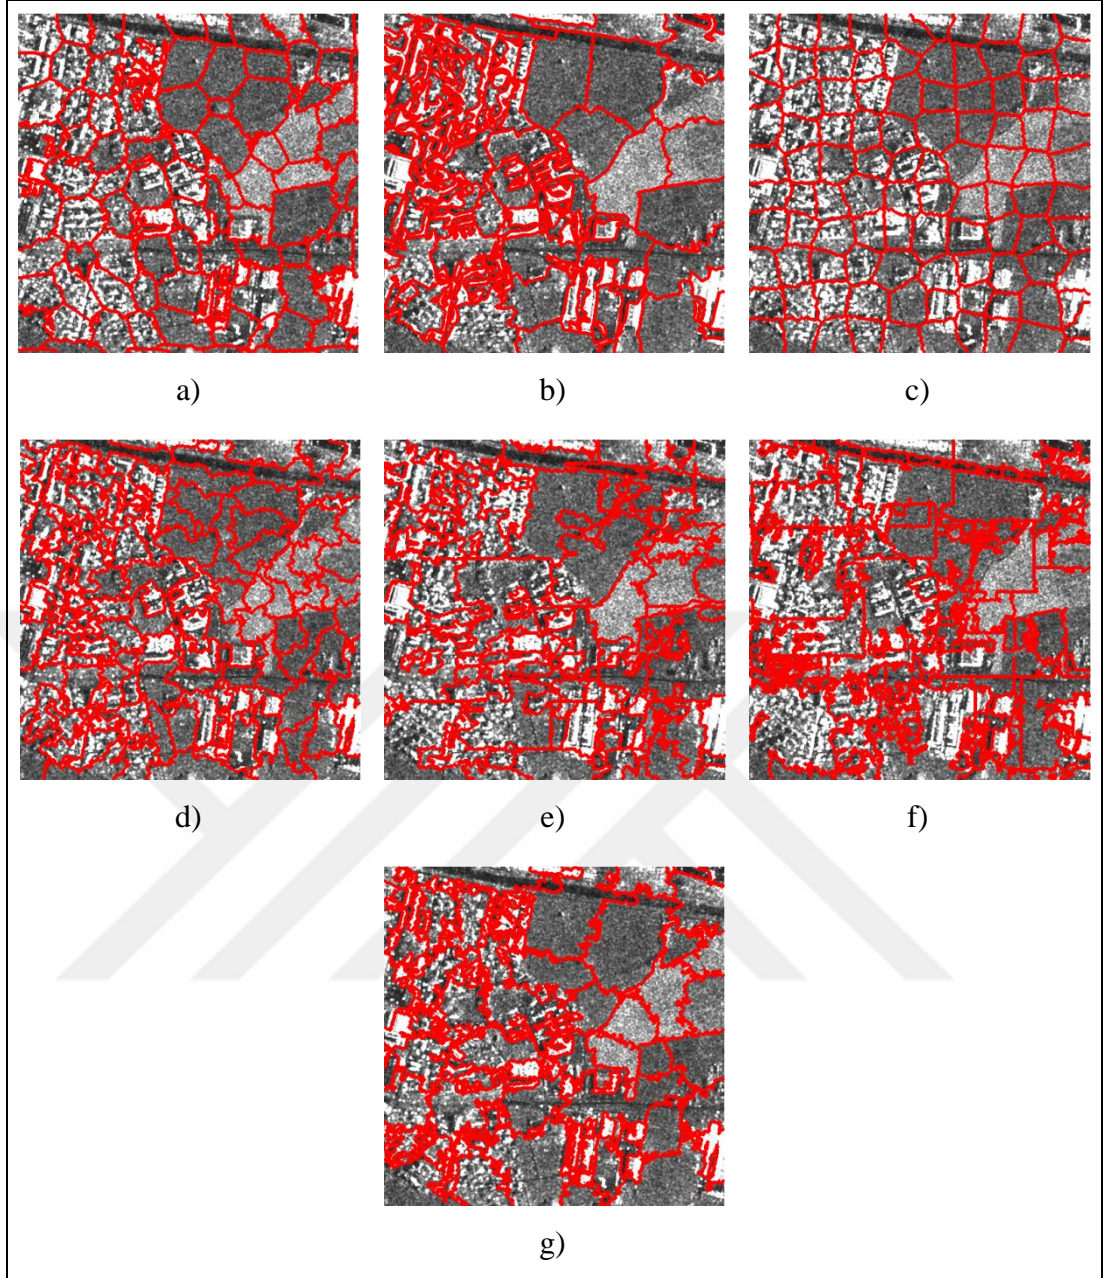
Şekil 3.8: TSX1 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları. a) MISP, b) NC, c) TP, d) ERS, e) SLIC, f) PILS, g) QS.

TSX1, TSX2, TSX3 ve TSX4 görüntülerinden elde edilen süperpiksellerin imge üzerindeki haritaları sırasıyla Şekil 3.8, Şekil 3.9, Şekil 3.10 ve Şekil 3.11’de gözlenmektedir. Bu şekillerden gözlemlendiği gibi MISP yöntemi imge sınırları ile en iyi örtüşen düzenli süperpikseller üretmektedir. Çizge tabanlı NC yöntemi Şekil 3.8.b)’den görüldüğü gibi değişimin fazla olmadığı kırsal alanlarda süperpiksel sınırları imge sınırları ile iyi örtüşme sağlasa da değişimin fazla olduğu şehir



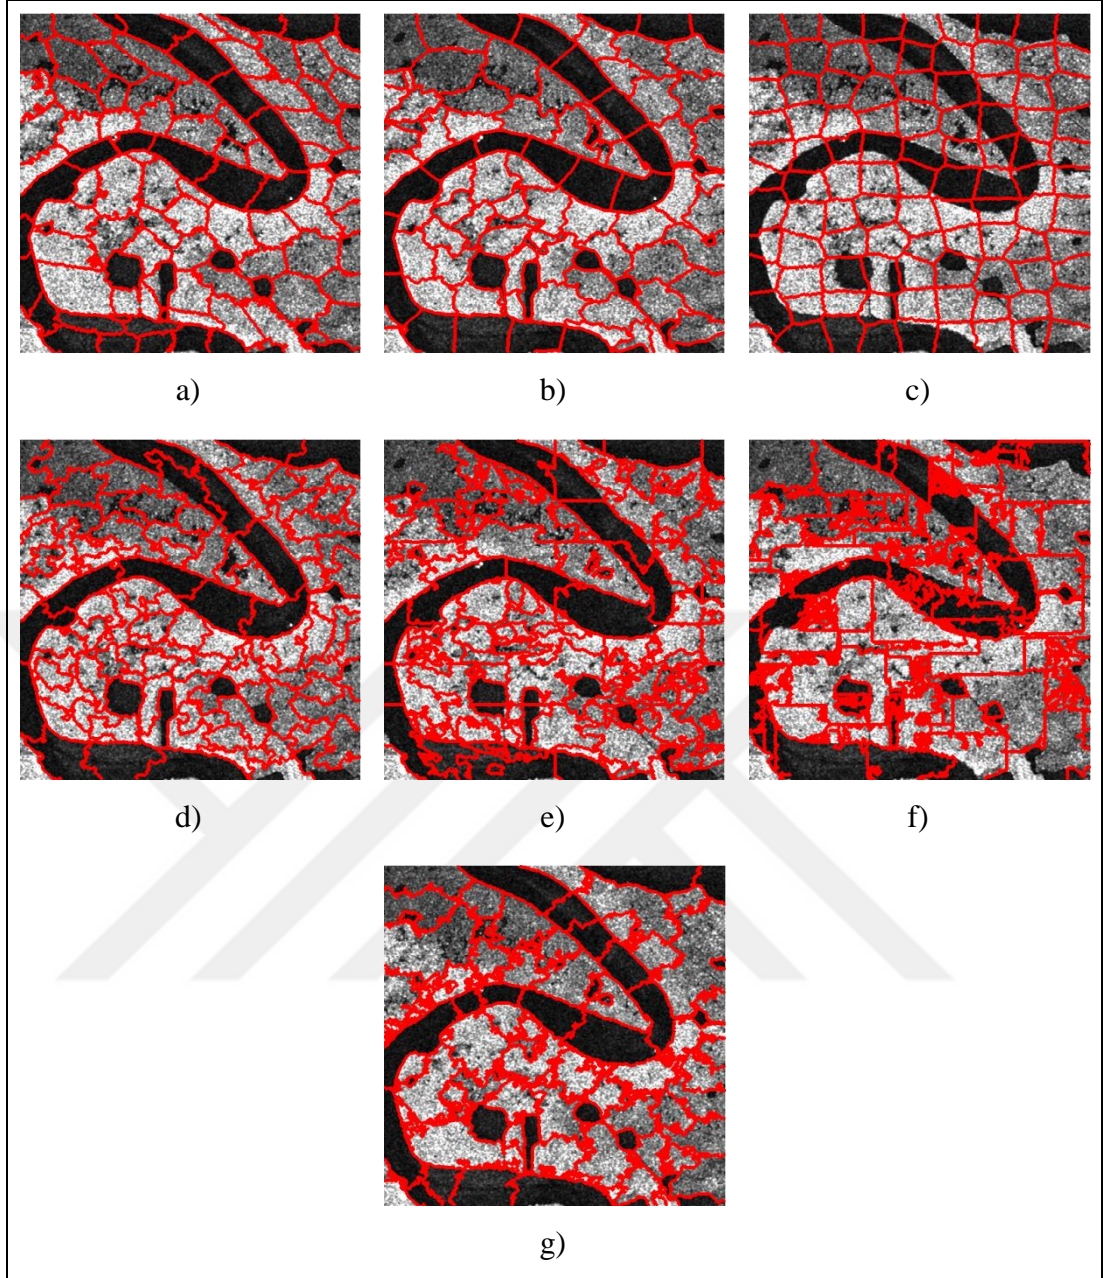
Şekil 3.9: TSX2 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları. a) MISP, b) NC, c) TP, d) ERS, e) SLIC, f) PILS, g) QS.

bölgelerinde sınır bölgeleriyle uyuşmamaktadır. TP yöntemi Şekil 3.8.c), Şekil 3.9.c), Şekil 3.10.c) ve Şekil 3.11.c)'den görüldüğü gibi düzenli ve derlitoplu süperpikseller üretmiş olsa da süperpiksel sınırları imge sınırlarıyla bazı bölgelerde uyuşmamaktadır. ERS, SLIC ve QS yöntemlerinde Şekil 3.8.d), Şekil 3.8.e) ve Şekil 3.8.g)'den gözlemlendiği gibi benek gürültüsü etkili olmakta ve süperpiksel sınırları dalgali olmaktadır. Bunun sonucunda süperpiksel sınırları bazı bölgelerde



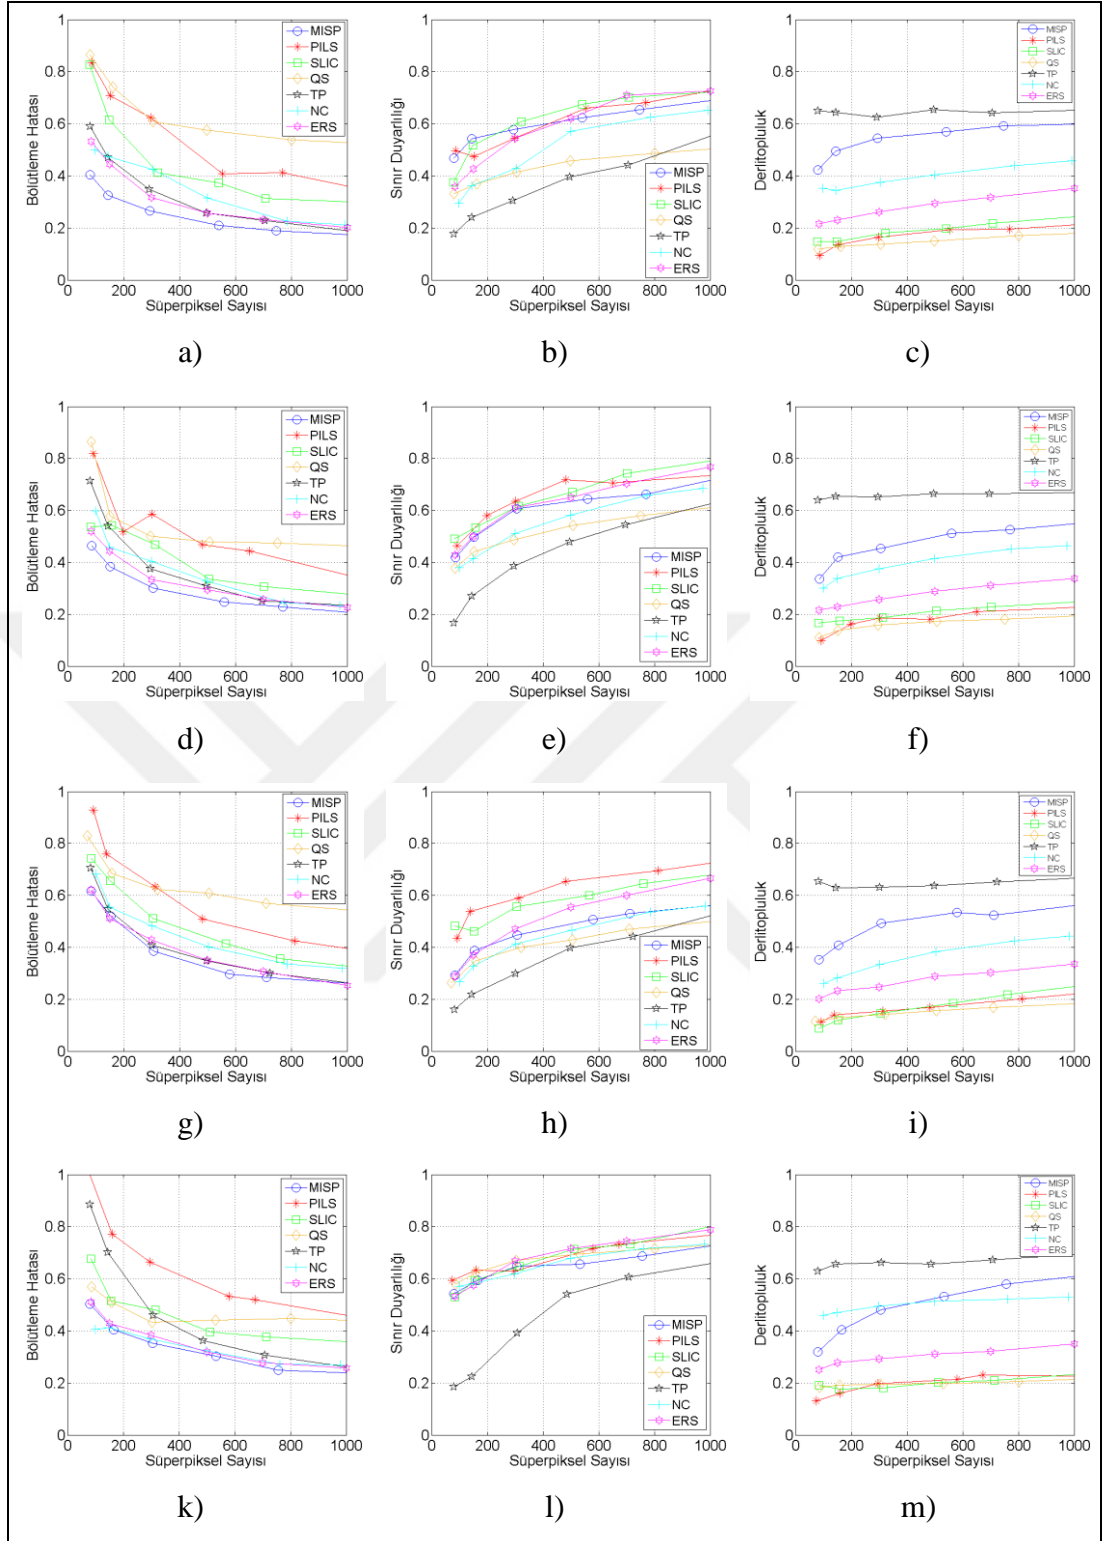
Şekil 3.10: TSX3 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları. a) MISP, b) NC, c) TP, d) ERS, e) SLIC, f) PILS, g) QS.

nesne sınırları ile örtüşmemektedir. PILS yönteminde benek gürültüsü temizleme oranı çoklu-bakış imgesinin bakış sayısı ile ilişkilidir. Bakış sayısının PILS yöntemi için yeterli olmaması sonucunda Şekil 3.8.f), Şekil 3.9.f), Şekil 3.10.f) ve Şekil 3.11.f)'den görüldüğü gibi süperpikseller oluşturulurken benek gürültüsünden büyük oranda etkilenilmekte ve bunun sonucunda süperpiksel sınırları çoğu bölgede nesne sınırları ile örtüşmemektedir.



Şekil 3.11: TSX4 imgesinde MISP, NC, TP, ERS, SLIC, PILS ve QS yöntemlerinin süperpiksel haritaları. a) MISP, b) NC, c) TP, d) ERS, e) SLIC, f) PILS, g) QS.

Süperpiksel algoritmalarının sayısal olarak başarımlarını karşılaştırmaları bölütleme hatası, sınır duyarlılığı ve derlitopluluk metrikleri ile yapılmaktadır [2]-[5], [8]-[11]. Şekil 3.12’de TSX1, TSX2, TSX3 ve TSX4 imgelerinden üretilmek istenen süperpiksel sayısı 100’den 1000’e kadar değiştirilmekte ve bunun sonucunda MISP, PILS, SLIC, QS, TP, NC ve ERS algoritmalarıyla üretilen süperpiksellerin UE, BR ve CM ölçüm sonuçları gözlemlenmektedir. Şekil 3.12.a), Şekil 3.12.d), Şekil 3.12.g) ve Şekil 3.12.k)’dan görüldüğü gibi MISP yöntemi nesne sınırları ile iyi oranda

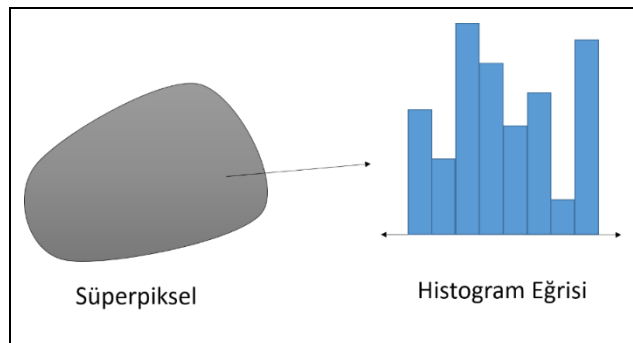


Şekil 3.12: TSX1, TSX2, TSX3 ve TSX4 imgelerinde süperpiksel yöntemlerinin UE, BR ve CM başarımlarının karşılaştırılması. a) TSX1-UE, b) TSX1-BR, c) TSX1-CM, d) TSX2-UE, e) TSX2-BR, f) TSX2-CM, g) TSX3-UE, h) TSX3-BR, i) TSX3-CM, k) TSX4-UE, l) TSX4-BR, m) TSX4-CM.

örtüştüğü için diğer yöntemlere oranla en düşük bölütleme hatası vermektedir. QS, PILS ve SLIC yöntemleri benek gürültüsünden yüksek oranda etkilendiği için yüksek bölütleme hatası vermektedir. Sınır duyarlılığı metriği bakımından SLIC, PILS, ERS yöntemleri Şekil 3.12.b), Şekil 3.12.e), Şekil 3.12.h) ve Şekil 3.12.l)'den görüldüğü gibi üstün performans vermektedir. Bu yöntemlerde süperpiksel imgedeki nesne sınırları ile iyi oranda örtüşmese de süperpiksel sınırlarının dalgalı formda olması sınır duyarlılığını artırmaktadır. TSX1 imgesinde süperpiksel sınırlarının kenar uzunluklarını ölçecek olursak TP, MISP, NC, ERS, QS, PILS ve SLIC yöntemleri için sırasıyla 8616, 10454,12449, 15302, 15415, 22567 ve 27054 şeklinde çıkmaktadır. TP ve MISP yöntemleri en kısa sınır kenar uzunluğuna sahiptir. Sınır duyarlılığında TP ve QS yöntemleri ise en düşük oran göstermektedir. Derlitopluluk metriğinde Şekil 3.12.c), Şekil 3.12.f), Şekil 3.12.i) ve Şekil 3.12.m)'den görüldüğü gibi TP ve MISP yöntemi diğer yöntemlere oranla üstün gelmektedir. TP yöntemi derlitopluluk oranında en üstün yöntem olsa da MISP yöntemi Şekil 3.8.c)'ye kıyasla Şekil 3.8.a)'dan görüldüğü gibi nesne sınırları ile daha iyi örtüşmektedir.

3.4. Süperpikseller için Öznitelik Çıkarımı

Süperpikseller imge içerisindeki farklı bölgeleri tespit etmek için tek başına yeterli olmamaktadır. İmgeden daha yüksek seviye bir çıkarım yapmak için süperpiksellerin kümelenmesi gerekmektedir. Bu tezde süperpikseller içerisindeki piksellerden çıkarılan öznitelik vektörleri ile kümelenmektedir. Süperpikselleri temsil eden öznitelik vektörleri Şekil 3.13'ten gözlemlendiği gibi süperpiksel içerisinde bulunan piksel genliklerinin histogramları ile bulunmaktadır. Histogram vektörü m uzunluğunda olmaktadır. Burada m değeri 8 olarak alınmaktadır.



Şekil 3.13: Süperpiksel özniteliklerinin çıkarılması.

3.5. Süperpiksellerin Kümelenmesi

Her bir süperpikseli temsil eden histogram vektörleri çıkarıldıktan sonra süperpikseller imge içerisindeki farklı bölge sayısına göre kümelenmektedir. Böylelikle imge içerisinde süperpiksellerden daha geniş alanlı şekillere ulaşılmaktadır. Kümeleme tabanlı yöntemler olarak bu bölümde k-ortalamlar [28], sıradüzensel kümeleme [29] ve Gauss Karışım Modeli [30] kümeleme yöntemleri kullanılmakta ve birbirlerine göre başarımları karşılaştırılmaktadır.

3.5.1. k-ortalamlar Yöntemi

k-ortalamlar yönteminde [28] veri kümesi içerisinde belirli bir benzerlik ölçüsüne göre k adet birbiriyle örtüşmeyecek şekilde küme oluşturulmaktadır. Gözlem veri kümesinde her bir elemanın konumu mevcuttur. Veri kümesi, küme içerisindeki elemanlar olabildiğince yakın, küme dışı elemanlar olabildiğince uzak şekilde gruplanmaktadır. Her bir küme, içerisindeki elemanlar ve ağırlık merkezi ya da merkezi ile tanımlanmaktadır. Küme içerisindeki elemanları merkezlere göre benzeşmezlik ölçüsü toplamı en az olurken benzeşim ölçüsü toplamı en büyük olmaktadır.

Matematiksel olarak \mathbf{D} veri kümesi k adet kümeye $\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_k$ ve $\mathbf{C}_i \cap \mathbf{C}_j = \emptyset$ olacak şekilde ayrılacağı varsayılmaktadır. Bu tezde benzerlik ölçüsü olarak farklı deneysel ölçümler sonucunda *cityblock* benzerlik ölçüsü kullanılmaktadır. Bu ölçü *minkowski* metriğinin $p = 1$ koşulu için özel durumudur. Bu ölçüye göre n boyutlu \mathbf{x}_s ve \mathbf{x}_t vektörleri arasındaki uzaklık

$$d_{st} = \sum_{j=1}^n |x_{sj} - x_{tj}| \quad (3.1)$$

olarak gösterilmektedir.

Algoritmada başlangıç olarak k adet rastgele merkez seçilmektedir. Veri kümesindeki her bir elemanın bu merkezlere göre uzaklığı *cityblock* metriğiyle ölçülmektedir. Her bir eleman bu metriğe göre en yakın olduğu küme merkezine atanmaktadır. Atanan elemanlar ile oluşturulan yeni kümeye göre küme merkezleri

güncellenmekte ve elemanların merkezlere göre uzaklıkları yeniden hesaplanmaktadır. Küme elemanlarının merkeze olan uzaklıkları toplamı yakınsayınca kadar bu süreç özyineli olarak devam etmektedir.

3.5.2. Sıradüzensel Kümeleme Yöntemi

Sıradüzensel kümeleme yönteminde [29] başlangıçta n adet tüm veri kümesi ayrı grup kabul edilerek benzerlik ölçüsüne göre bir grup oluşuncaya kadar en küçük kayıpla sıradüzensel olarak birleştirilmektedir. Başlangıçtaki n adet nesne ayrı grup kabul edildiğinde karesel toplam hata (Error Sum of Squares, ESS) sıfır olmaktadır. n adet nesnenin bir grup kabul edilmesi durumunda karesel toplam hata

$$ESS = \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})^T (\mathbf{y}_i - \bar{\mathbf{y}}) = \sum_{i=1}^n \|\mathbf{y}_i - \bar{\mathbf{y}}\|^2 \quad (3.2)$$

şeklindedir. Bu durumda karesel toplam hata 0 ile ESS değeri arasında olmaktadır [31]. Ward's yöntemi [29] grupların birbirine bağlanması sırasında oluşan karesel toplam hata artışını en küçük yapacak şekilde grupları birbirine bağlamaktadır. Her bir adımda $n(n-1)/2$ çift arasında artan karesel hata hesaplanmakta ve toplam karesel hatada en küçük artışı sağlayan çiftler sıradüzensel olarak birleştirilmektedir. **R** ve **S** kümeleri için karesel toplam hata sırasıyla

$$E_r SS = \sum_r \|\mathbf{y}_r - \bar{\mathbf{y}}_r\|^2, r \in \mathbf{R} \quad (3.3)$$

$$E_s SS = \sum_s \|\mathbf{y}_s - \bar{\mathbf{y}}_s\|^2, s \in \mathbf{S} \quad (3.4)$$


şeklindedir. **R** ve **S** kümelerinin birleştirilmesi ile oluşan **T** kümesinde toplam karesel hata

$$E_t SS = \sum_t \|\mathbf{y}_t - \bar{\mathbf{y}}_t\|^2, t \in \mathbf{T} \quad (3.5)$$

olmaktadır. Burada $\bar{y}_t = (n_R \bar{y}_r + n_S \bar{y}_s) / (n_R + n_S)$ şeklindedir. **R** ve **S** kümelerinin birleşimiyle oluşan **T** kümesi sonucunda artan toplam karesel hata $E_t SS - (E_s SS + E_r SS)$ şeklindedir. Bu durumda kümeler arasındaki artan toplam karesel hata (incremental between cluster sum of squares, IBCSS)

$$\begin{aligned} (IBCSS)_{(R)(S)} &= n_R \|y_r - \bar{y}_r\|^2 + n_S \|y_s - \bar{y}_s\|^2 \\ &= \left(\frac{n_R n_S}{n_R + n_S} \right) \|\bar{y}_r - \bar{y}_s\|^2 \end{aligned} \quad (3.6)$$

şeklinde hesaplanmaktadır. Burada \bar{y}_r ve \bar{y}_s sırasıyla **R** ve **S** küme ağırlık merkezleri, n_R ve n_S küme eleman sayısı, $\|\dots\|_2$ Öklid uzaklığıdır. Bir nesne için Eşitlik (3.6) $d_{r_s}^2/2$ şeklinde Öklid uzaklığının karesinin yarısı olmaktadır [31]. Sıradüzensel birleşme süreci $n = 1$ oluncaya kadar devam etmekte ve süreç sonunda Şekil 3.14'te gözlemlendiği gibi ağaç yapısı oluşmaktadır. Ağaç yapısı oluşturulmak istenen küme sayısına göre kesilerek kümeler oluşturulmaktadır.



Şekil 3.14: Sıradüzensel kümeleme algoritmasında kullanılan ağaç yapısı.

3.5.3. GKM Kümeleme Yöntemi

k-ortalamlar yönteminde veri noktaları deterministik olarak sadece bir kümeye atanmaktadır. Bu yöntem sert kümeleme (hard clustering) denmektedir. Gauss Karışım Modeli'nde [30] veri noktaları en büyük olasılığa göre kümelere atanmaktadır. Bu yöntem ise yumuşak kümeleme (soft clustering) olarak adlandırılmaktadır. Her bir küme elemanı Gauss dağılımlı olarak düşünülmektedir. Çok boyutlu Gauss dağılımında küme belli bir $\boldsymbol{\mu}$ ortalama vektörü ve $\boldsymbol{\Sigma}$ kovaryans matrisine sahiptir. Kümeleme işlemine rastgele k adet Gauss merkezi seçilerek başlanmaktadır. Özyineli olarak her bir sınıfın Gauss dağılımı parametre kümesi $\boldsymbol{\mu}$ ve $\boldsymbol{\Sigma}$ beklenti enbüyükleme (Expectation-Maximization, EM) algoritması ile öğrenilmektedir. Beklenti adımında her bir veri setinin kümelere göre olasılıkları hesaplanmaktadır. Herhangi bir \mathbf{x}_j vektörünün $y = i$ 'nci kümeye ait olma olasılığı en büyük sonsal olasılığa göre

$$p(y = i | \mathbf{x}_j) \propto \frac{1}{(2\pi)^{m/2} \|\boldsymbol{\Sigma}_i^t\|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}_j - \boldsymbol{\mu}_i^t)^T \boldsymbol{\Sigma}_i^{t-1} (\mathbf{x}_j - \boldsymbol{\mu}_i^t)\right) p^t(y = i) \quad (3.7)$$

şeklinde hesaplanmaktadır. Burada $\boldsymbol{\mu}_i^t$ ve $\boldsymbol{\Sigma}_i^t$ t . özyinelemede i . kümeye ait ortalama vektörü ve kovaryans matrisleri, $p^t(y = i)$ t . özyinelemede i . kümenin önsel olasılığıdır. \mathbf{x}_j vektörü en büyük olasılığa sahip kümeye Eşitlik (3.7)'deki sonsal olasılığa göre atanmaktadır. Enbüyükleme adımında ise maksimum olasılıklara göre atanan veri noktaları kullanılarak küme parametreleri $\boldsymbol{\mu}_i^{t+1}$, $\boldsymbol{\Sigma}_i^{t+1}$ ve p_i^{t+1} sırasıyla

$$\boldsymbol{\mu}_i^{t+1} = \frac{\sum_j P(y = i | \mathbf{x}_j) \mathbf{x}_j}{\sum_j P(y = i | \mathbf{x}_j)} \quad (3.8)$$

$$\boldsymbol{\Sigma}_i^{t+1} = \frac{\sum_j P(y = i | \mathbf{x}_j) [\mathbf{x}_j - \boldsymbol{\mu}_i^{t+1}][\mathbf{x}_j - \boldsymbol{\mu}_i^{t+1}]^T}{\sum_j P(y = i | \mathbf{x}_j)} \quad (3.9)$$

$$p_i^{t+1} = \frac{\sum_j P(y = i | \mathbf{x}_j)}{m} \quad (3.10)$$

şeklinde hesaplanmaktadır. Burada toplam veri noktası m piksel sayısını göstermektedir. Belli bir özyineleme sayısından sonra küme parametreleri yakınsamakta ve istenilen k sayıda küme oluşturulmaktadır [32].

3.6. Deney Sonuçları ve Algoritmaların Başarım Karşılaştırmaları

Bu bölümde yukarıda anlatılan k-ortalamlar, sıradüzensel ve GKM kümeleme yöntemleri kullanılarak SAR imgelerindeki bölgeler süperpiksel tabanlı sınıflandırılmaktadır. Bölüm 3.3'te kullanılan MISP, PILS, SLIC, QS, TP, NC ve ERS süperpiksel algoritmaları sonucu elde edilen süperpiksellerden çıkarılan histogram öznelikleri ile belli sayıda küme oluşturulmaktadır. Oluşturulan kümeler ile yer-gerçekliği haritasındaki her bir sınıf karşılaştırılarak sınıflandırma başarımları sayısal olarak ölçülmektedir. Başarım ölçütü olarak tam doğruluk (TD) metriği kullanılmaktadır. TD ölçüsü

$$TD = \frac{\text{Doğru sınıflandırılmış pikseller}}{\text{Tüm piksellerin sayısı}} \quad (3.11)$$

şeklinde tanımlanmaktadır.

TSX1, TSX2, TSX3 ve TSX4 imgeleri için k-ortalamlar, sıradüzensel ve GKM kümeleme tam doğruluk sonuçları sırasıyla Tablo 3.1, Tablo 3.2, Tablo 3.3 ve Tablo 3.4'te gözlemlenmektedir. TSX1 imgesinde düşük süperpiksel sayısında MISP yöntemi üstün gelirken süperpiksel sayısının artması ile NC yöntemi k-ortalamlar ve sıradüzensel kümeleme yöntemlerinde en iyi sınıflandırma sonucu vermektedir. GKM kümelemede ise MISP ve TP yöntemleri yüksek başarım göstermektedir. TSX2 imgesinde düşük süperpiksel sayısında MISP yöntemi üstün başarım göstermektedir. Süperpiksel sayısının artması ile k-ortalamlar ve GKM kümeleme yöntemlerinde TP yöntemi, sıradüzensel kümeleme yönteminde NC yöntemi üstün başarım göstermektedir. TSX3 imgesinde farklı kümeleme yöntemleri için genel olarak NC ve TP yöntemleri yüksek başarım göstermektedir. TSX4 imgesinde ise k-ortalamlar ve sıradüzensel yöntemlerinde NC ve ERS yöntemleri üstün gelirken GKM yönteminde MISP, NC, ERS yöntemleri yüksek başarım göstermektedir.

Tablo 3.1: TSX1 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımları sonuçları.

	k-ortalamlar Kümelenme Yöntemi					Sıradüzensel Kümelenme Yöntemi					GKM Kümelenme Yöntemi				
	100	300	500	750	1000	100	300	500	750	1000	100	300	500	750	1000
MISP	83.8	75.1	62.8	59.9	56.4	88.0	68.4	59.7	51.8	55.3	91.1	80.4	69.6	67.1	71.2
NC	81.6	88.8	92.1	89.6	88.6	83.3	87.1	90.8	90.5	87.9	65.9	49.8	52.2	58.6	53.3
TP	85.3	86.2	83.6	69.9	67.3	83.5	81.7	66.6	73.8	67.0	70.3	68.6	62.9	56.6	80.1
SLIC	52.8	37.6	44.0	42.5	47.2	53.9	37.8	50.4	47.4	43.6	55.0	53.2	47.5	53.4	46.2
PILS	50.1	35.0	35.9	38.9	41.9	39.2	40.6	44.1	43.7	36.5	62.5	54.3	48.1	46.1	42.9
ERS	56.3	63.9	67.1	61.7	60.3	73.7	75.8	65.8	53.5	50.1	73.4	73.8	67.6	67.0	59.9
QS	50.2	46.9	43.3	43.8	43.5	47.9	51.4	49.4	45.3	43.0	60.7	38.0	42.2	42.3	43.3

Tablo 3.2: TSX2 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımları sonuçları.

	k-ortalamlar Kümelenme Yöntemi					Sıradüzensel Kümelenme Yöntemi					GKM Kümelenme Yöntemi				
	100	300	500	750	1000	100	300	500	750	1000	100	300	500	750	1000
MISP	83.1	77.9	71.0	69.6	69.6	83.8	83.5	74.9	70.3	69.3	58.2	59.1	71.2	48.1	50.3
NC	51.6	86.7	71.3	68.0	67.7	81.8	89.1	90.3	90.1	90.0	57.2	62.0	68.5	71.0	69.4
TP	82.3	84.1	82.6	66.7	46.6	81.6	83.9	81.1	72.0	62.7	76.6	82.1	72.5	65.8	50.4
SLIC	50.0	63.1	65.2	59.9	67.0	50.0	63.0	75.0	70.0	71.4	60.4	57.2	44.2	47.5	59.3
PILS	48.6	57.8	48.0	53.1	53.0	54.5	32.3	48.1	56.4	51.3	53.6	51.8	51.7	62.7	63.0
ERS	81.2	45.6	57.3	52.4	53.3	82.1	86.4	75.5	71.9	78.7	75.0	72.5	70.5	65.5	51.1
QS	59.1	35.8	67.9	72.0	71.8	77.8	76.9	72.4	71.1	70.2	59.6	63.6	50.2	42.0	56.1

Tablo 3.3: TSX3 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımları sonuçları.

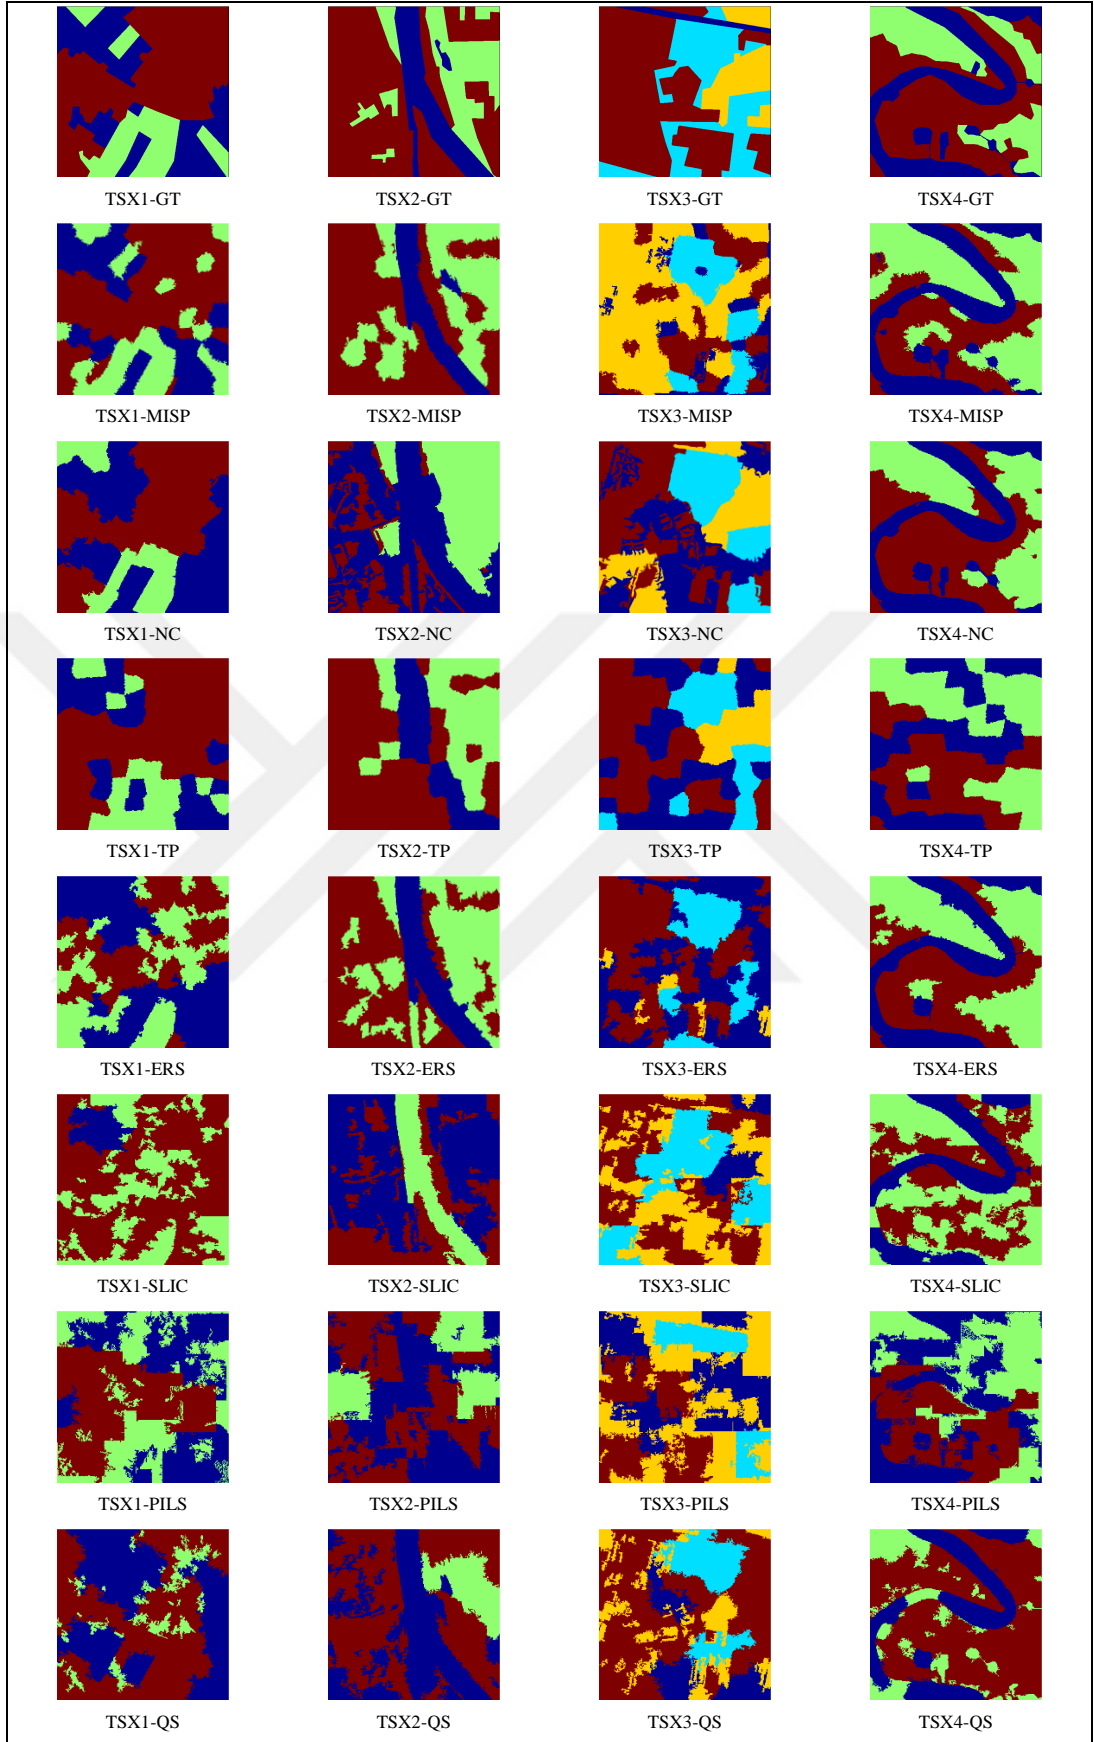
	k-ortalamlar Kümelenme Yöntemi					Sıradüzensel Kümelenme Yöntemi					GKM Kümelenme Yöntemi				
	100	300	500	750	1000	100	300	500	750	1000	100	300	500	750	1000
MISP	57.3	54.0	55.2	54.3	48.6	51.0	50.0	44.5	48.5	42.2	43.0	67.6	53.9	48.7	59.1
NC	56.4	54.1	59.6	59.4	60.2	59.4	73.6	62.6	61.1	58.4	54.3	51.3	32.7	61.5	44.9
TP	61.9	64.3	58.3	60.9	54.3	69.9	55.0	56.5	49.4	39.1	55.3	53.0	64.5	52.5	46.9
SLIC	45.1	49.3	46.2	48.7	54.1	41.8	28.1	48.6	52.1	47.0	35.8	42.7	26.3	46.0	44.0
PILS	38.5	30.0	37.3	39.6	43.1	43.4	31.1	43.8	43.8	47.4	46.9	52.0	44.2	42.6	41.9
ERS	56.1	56.3	52.1	41.9	42.8	39.5	57.7	66.8	55.0	60.6	54.0	66.3	40.2	53.7	54.1
QS	45.1	54.0	49.4	51.0	58.5	40.2	49.9	62.7	54.6	58.2	40.8	41.2	40.8	30.8	39.8

Tablo 3.4: TSX4 imgesinde süperpiksellerin k-ortalamlar, sıradüzensel ve GKM kümelenmesi başarımları sonuçları.

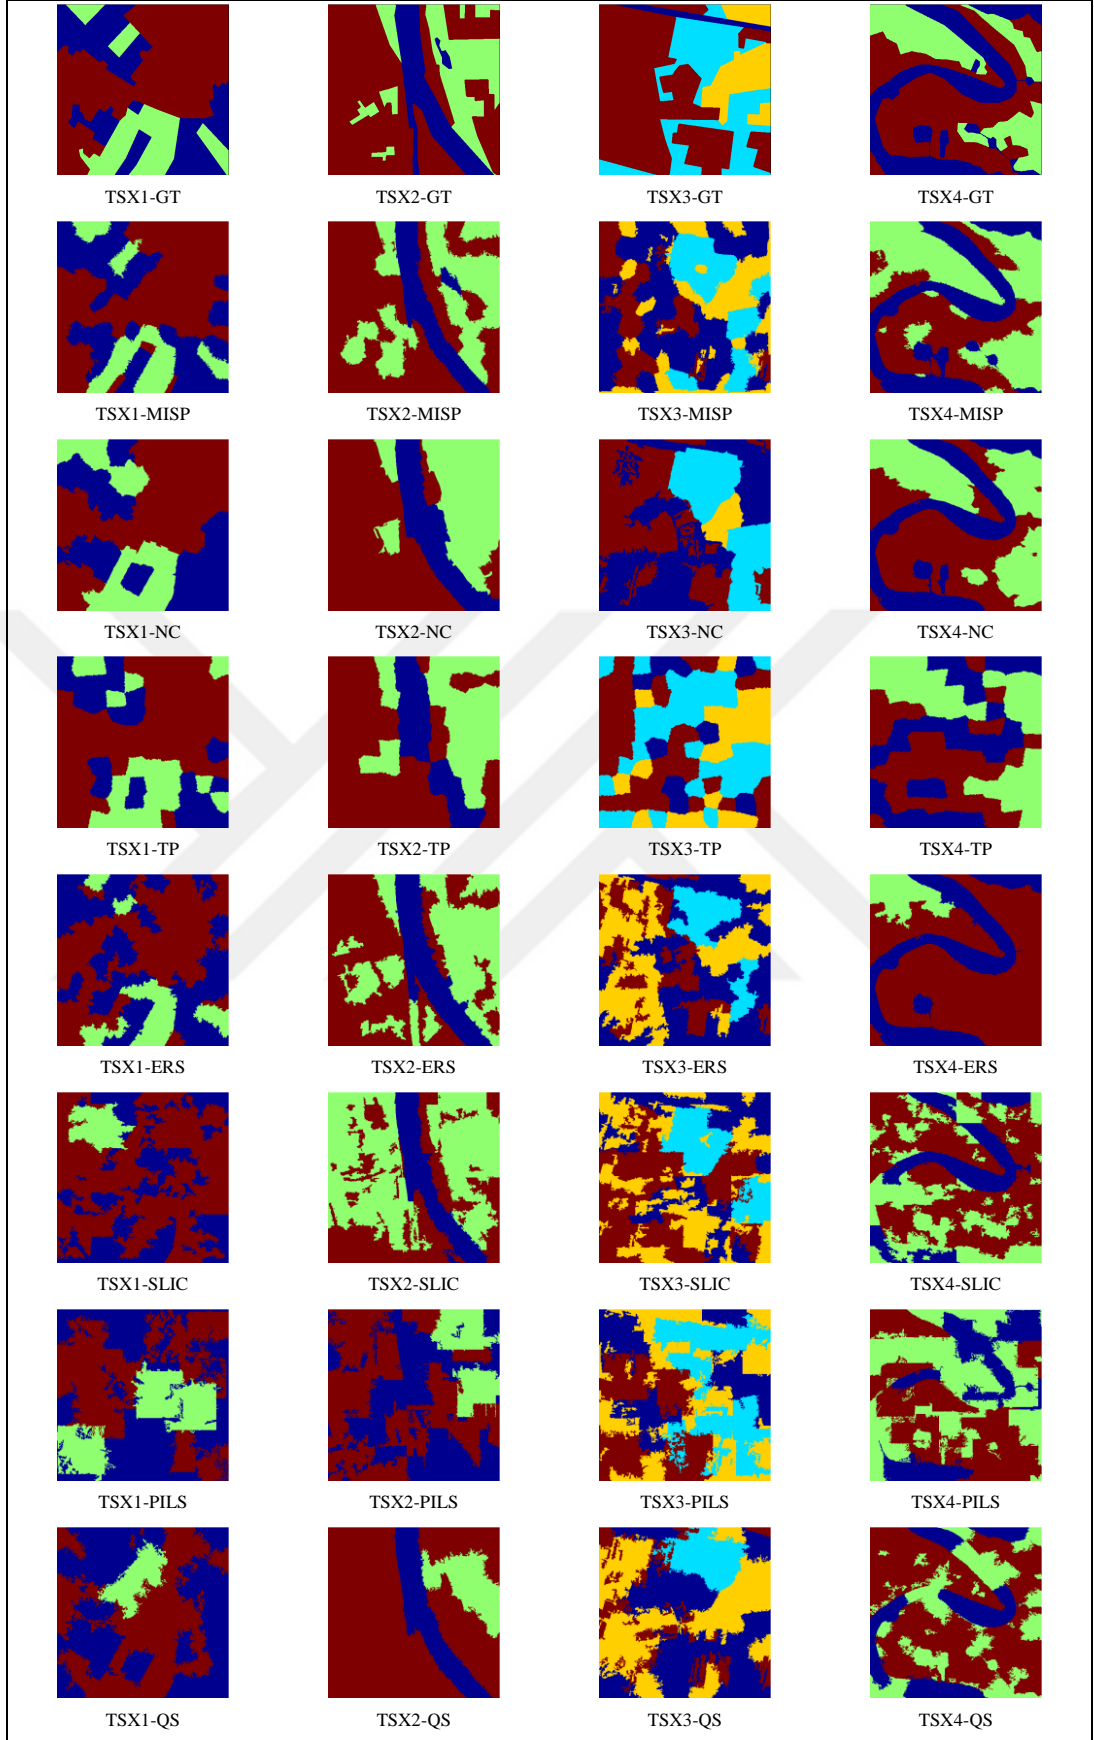
	k-ortalamlar Kümelenme Yöntemi					Sıradüzensel Kümelenme Yöntemi					GKM Kümelenme Yöntemi				
	100	300	500	750	1000	100	300	500	750	1000	100	300	500	750	1000
MISP	82.8	81.9	80.2	80.9	80.9	83.2	80.6	75.5	79.8	78.1	86.2	80.7	81.5	67.5	83.2
NC	87.3	86.0	81.4	81.2	80.5	85.4	82.4	86.8	85.2	81.9	68.9	87.2	82.9	73.2	74.7
TP	74.8	81.8	82.2	84.3	81.9	77.0	81.6	75.0	80.8	83.9	51.6	63.9	79.5	82.2	86.2
SLIC	68.8	65.7	57.4	63.5	57.1	58.1	61.9	63.2	74.1	75.1	71.4	64.2	79.7	68.0	80.4
PILS	59.2	53.9	62.1	61.9	59.2	50.5	53.0	67.3	53.6	48.1	61.3	51.9	49.3	54.6	56.5
ERS	83.0	84.0	83.9	84.1	84.5	77.2	80.3	86.3	78.5	85.9	78.3	71.0	84.9	84.1	80.3
QS	67.5	64.2	66.7	64.3	63.2	52.7	54.2	58.2	57.1	56.6	61.7	66.9	39.6	64.4	63.4

Sınıflandırma başarımlarını genel olarak yorumlayacak olursak MISP, NC ve TP yöntemleri diğer süperpiksel yöntemlerine oranla yüksek başarımlar göstermektedir. Şekil 3.12.c), Şekil 3.12.f), Şekil 3.12.i) ve Şekil 3.12.m)'den görüldüğü gibi bu üç yöntem derlitopluluk bakımından üstün gelmektedir. Derlitopluluk bakımında düşük performans gösteren SLIC, PILS ve QS yöntemleri ise sınıflandırma adımında da düşük performans göstermektedir. Derlitoplu süperpikseller sınıflandırma adımında yüksek başarımlar göstermektedir. MISP, NC ve TP yöntemleri benek gürültüsüne karşı etkili yöntemlerdir. SLIC, PILS ve QS yöntemleri ise benek gürültüsünden yüksek oranda etkilenerek sınıflandırma adımında düşük sonuçlar üretmektedir.

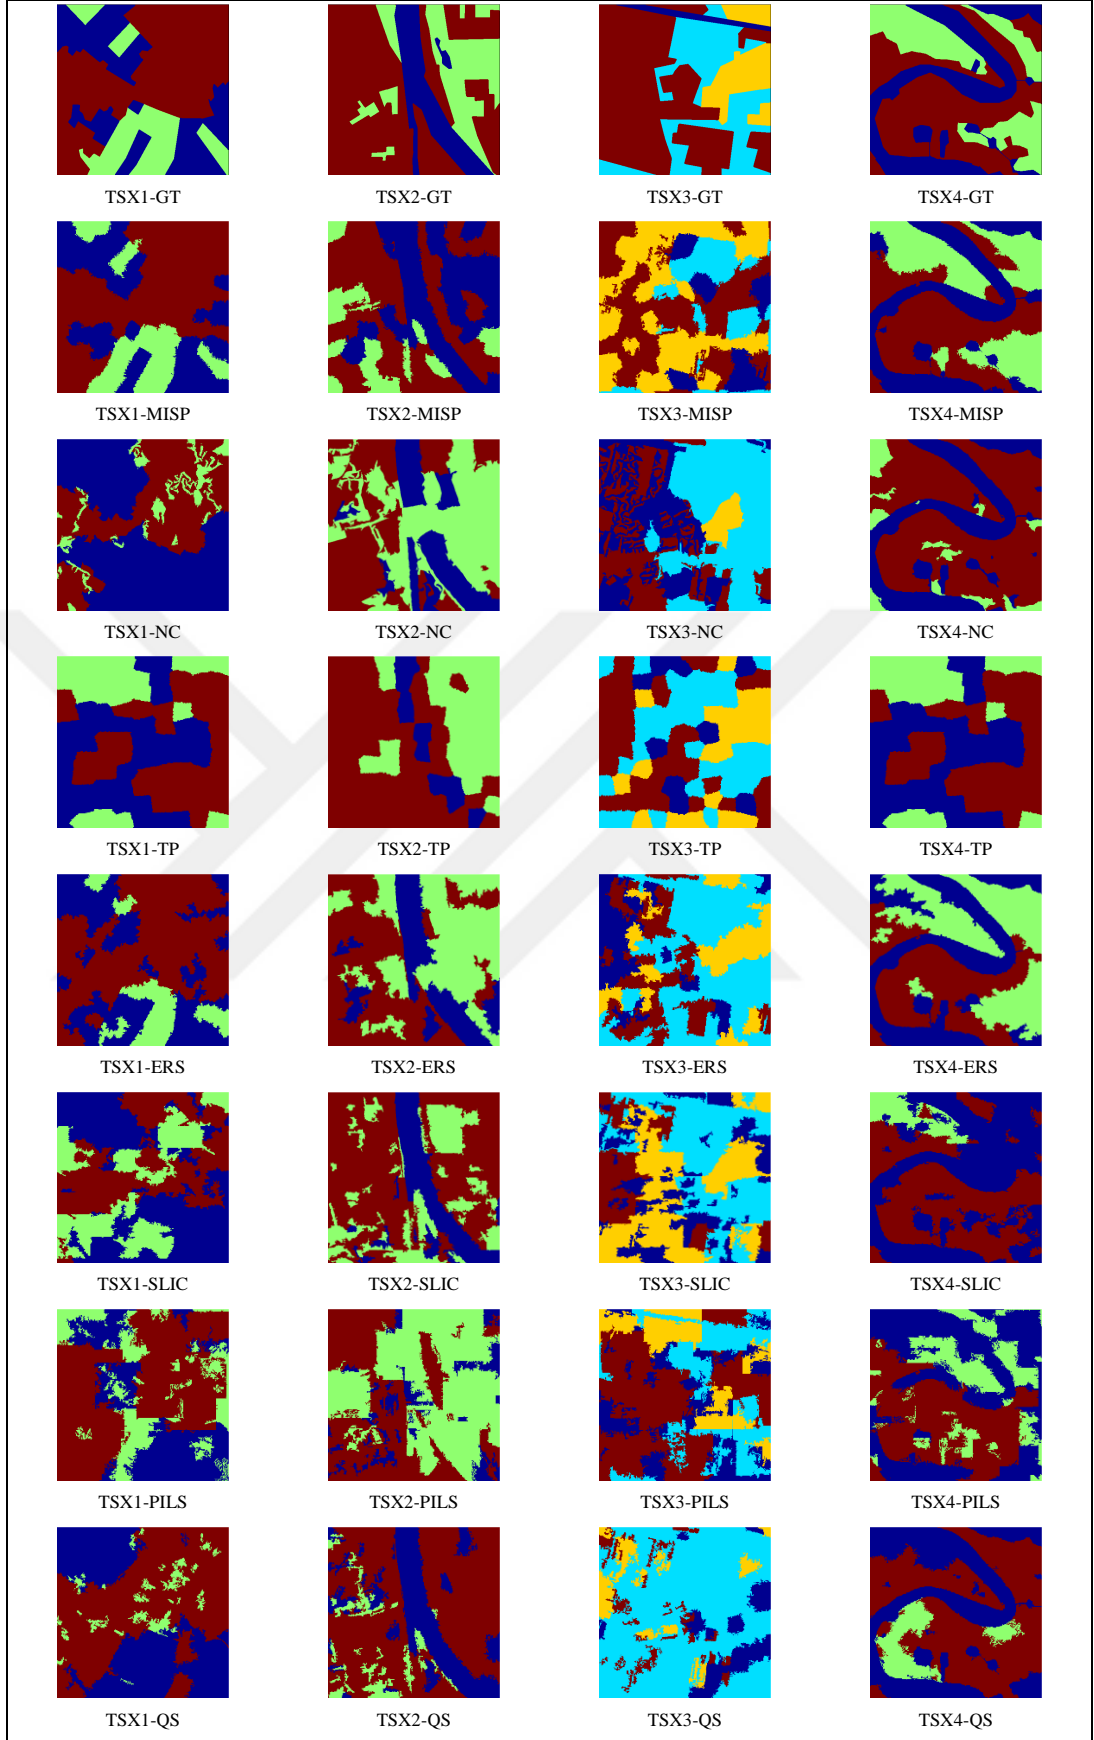
Süperpiksel algoritmalarından elde edilen 100 süperpiksel için k-ortalamlar, sıradüzensel ve GKM kümeleme yöntemleri ile sınıflandırma haritaları sırasıyla Şekil 3.15, Şekil 3.16 ve Şekil 3.17'de gözlemlenmektedir. k-ortalamlar kümeleme yöntemi için Şekil 3.15'ten gözlemlendiği gibi TSX1 ve TSX2 imgeleri için MISP yöntemi iyi oranda sonuç vermektedir. TSX3 imgesi için TP yöntemi, TSX4 imgesi için ise NC yöntemi iyi sonuç vermektedir. Sıradüzensel kümeleme yöntemi için Şekil 3.16'da TSX1, TSX2 ve TSX3 imgeleri için MISP yöntemi iyi oranda sonuç verirken TSX4 imgesinde NC yöntemi üstün başarımlar göstermektedir. GKM kümeleme yöntemi için Şekil 3.17'de TSX1 imgesi için MISP yöntemi, TSX2 ve TSX3 imgeleri için TP yöntemi, TSX4 imgesi için ise MISP yöntemi iyi oranda sınıflandırma haritası sonucu vermektedir. Sınıflandırma haritalarını genel olarak yorumlayacak olarak MISP yöntemi az sayıdaki 100 süperpiksel sayısı için iyi oranda sınıflandırma haritası üretmektedir. TP yöntemi yapay dama tahtası görünümü sınıflandırma haritası göstermektedir. ERS, SLIC, PILS ve QS yöntemleri benek gürültüsünden etkilenmesi sonucu iyi sınıflandırma haritası sunmamaktadır.



Şekil 3.15: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin k-ortalamalar kümelmesi sonucu sınıflandırma haritaları.



Şekil 3.16: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin sıradüzensel kümelmesi sonucu sınıflandırma haritaları.



Şekil 3.17: TSX1, TSX2, TSX3 ve TSX4 imgelerinde 100 adet süperpikselin GKM yöntemine göre kümelmesi sonucu sınıflandırma haritaları.

Süperpiksel algoritmalarının imgeden 100 adet süperpiksel üretmeleri için gerekli zaman saniye cinsinden Tablo 3.5'te gözlemlenmektedir. Ölçüm sonuçları MATLAB ortamında Intel(R) Core i7-4790 3.60 Ghz CPU ve 16GB Ram özelliklerine sahip bilgisayar kullanılarak yapılmaktadır. Burada algoritmanın çalışması için gerekli zaman, KBT zamanı ve süperpiksellerin tek bölüt halinde elde edilmesi için gerekli toplam zaman gözlemlenmektedir. ERS yöntemi C tabanlı açık koda sahip olduğu için tabloya konulmamaktadır. ERS yöntemi [5]'de görüldüğü gibi C ortamında SLIC yönteminden yavaştır. Tablo 3.5'ten görüldüğü gibi en hızlı algoritma ve toplam zamana sahip süperpiksel yöntemi MISP'tir. SLIC, QS ve PILS yöntemleri benek gürültüsünden etkilendiği için KBT sürecinde zaman gerektirmektedir. NC yöntemi ise en yavaş yöntem olarak gözlemlenmektedir. NC yönteminde her süperpiksel için özdeğer hesaplandığından hesaplama yükü fazla olmaktadır.

Tablo 3.5: MISP, SLIC, TP, QS, PILS ve NC süperpiksel algoritmalarının çalışma zamanları.

Algoritma	Algoritma Zamanı	KBT Zamanı	Toplam Zamanı
MISP	9.1735	1.6047	10.7782
SLIC	10.4454	14.0233	24.4687
TP	23.7439	0.9208	24.6647
QS	21.4597	9.7583	31.2180
PILS	66.2552	30.6891	96.9443
NC	443.9033	1.3374	445.2407

3.7. Vargı

SAR imgeleri güncel süperpiksel yöntemleri kullanılarak yeni bir yaklaşımli sınıflandırılmaktadır. Piksel tabanlı yöntemlere oranla karmaşıklık ve işlem kapasitesi düşürülmektedir. Süperpiksellerin derlitoplu bir şekilde çıkarımı sınıflandırma başarımını büyük oranda etkilemektedir. MISP, NC ve TP yöntemleri benek gürültüsüne karşı dayanıklı (robust) yöntemler olup SAR imgelerin sınıflandırılmasında etkilidir. Özdeğer problemi tabanlı NC yöntemi sınıflandırma adımında etkili sonuçlar gösterse de süperpiksellerin üretimi aşamasında aşırı zaman

gereksinimine ihtiyaç duymaktadır. SAR imgeleri istatistiğiyle uyumlu MISP yöntemi süperpikselleri en hızlı ve derlitoplu biçimde üretmektedir. MISP süperpikselleri SAR imgesi içerisindeki bölge sınırları ile uyumlu olması sonucunda sınıflandırma adımında imgeden çıkarılan az sayıda süperpiksel ile etkili sonuçlar göstermektedir. SLIC, QS ve PLS yöntemleri Öklid uzaklığı ya da Gauss çekirdek fonksiyonu tabanlı yöntemler olduğundan benek gürültüsüne karşı dirençli olmamaktadır. Bu tezde süperpikselleri temsil eden öznitelikler histogram vektörü ile çıkarılmaktadır. Farklı öznitelik çıkarım yöntemleri de kullanılabilir.




4. HİPERSPEKTRAL İMGELERİN SÜPERPİKSEL TABANLI SINIFLANDIRILMASI

4.1. Hiperspektral İmgesine Giriş

Hiperspektral görüntüler AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), HYDICE (Hyperspectral Digital Imagery Collection Experiment) gibi hiperspektral sensörler tarafından onlarca spektral dalga boyları ile eş zamanlı olarak ölçüm sonucunda oluşmaktadır. Her dalga boyu bir kanalı temsil ettiğinden hiperspektral görüntü pikselleri yüksek boyutlu vektörler ile ifade edilmektedir. Vektör büyüklüğü spektral veri kanalına eşittir. Hiperspektral görüntüler ekoloji biliminde orman bölgesindeki biyoçeşitliliği tespit etmede, jeoloji biliminde minerallerin fiziko-kimyasal özelliklerini belirlemede, hidroloji biliminde sulak alanların değişim karakteristiğini gözlemlemede, tarım alanında bölgelerinin sınıflandırılmasında, askeri uygulamalarda hedef tespiti gibi birçok farklı alanda yaygın olarak kullanılmaktadır.

Hiperspektral görüntü kübü Şekil 4.1’de gözlemlenmektedir. Görüntü art arda gelen gri-seviyeli imge kümesi olarak düşünülebilir. Uzamsal koordinatlar k_1 ve k_2 olmak üzere iki ayrı boyutu, art arda sıralı gelen d adet imge üçüncü boyutu oluşturmak üzere hiperspektral imge üç boyutlu imge kübü olarak $k_1 \times k_2 \times d$ şeklinde düşünülebilir. Burada d hiperspektral görüntünün kanal sayısıdır. Şekil 4.1’de λ eksenini sahnede ilgili noktanın farklı dalga boylarına cevabını göstermektedir.




Şekil 4.1: Hiperspektral imge kübü.

4.2. Hiperspektral İmge Veri Kümesi

Hiperspektral imgelerin sınıflandırılmasında ticari olmayan kullanıma açık Indian Pines, Salinas ve Pavia Üniversitesi'nin hiperspektral görüntüleri yaygın olarak kullanılmaktadır. Tez kapsamında hiperspektral görüntülerin süperpiksel tabanlı sınıflandırılmasında bu üç veri seti kullanılmaktadır.

4.2.1. Indian Pines İmgesi

Indian Pines imgesi Indiana eyaletinin kuzeybatısında AVIRIS sensörü tarafından 1992 yılında Indian Pines tarımsal bölgesinden elde edilmiştir. İmge boyutu 145x145x220 olarak 20 m uzamsal çözünürlükte ve spektral kaplam aralığı 0.2-2.4 μm 'dir. Spektral bant sayısı 20 su buharı soğurma bantları çıkarılarak bant sayısı 200'e düşürülmüştür. İmge 16 farklı ekin sınıfına sahiptir. Şekil 4.2'de Indian Pines imgesinin belirli üç kanalının birleşimiyle oluşan görüntü ve imgenin yer gerçekliği haritası gözlemlenmektedir.




Şekil 4.2: Indian Pines imgesinin 80,150,190 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası. a) IP, b) IP-GT.

4.2.2. Salinas İmgesi

Salinas imgesi Kaliforniya'da bulunan Salinas Vadisi'nden AVIRIS sensörü tarafından 1998 yılında elde edilmiştir. İmge boyutu 512x217x224 olarak 3.7 m uzamsal çözünürlüktedir. 20 adet su buharı soğurma bantları çıkarılarak bant sayısı 204'e düşürülmüştür. İmge içerisinde 16 ayrı sınıf mevcuttur. Şekil 4.3'te Salinas

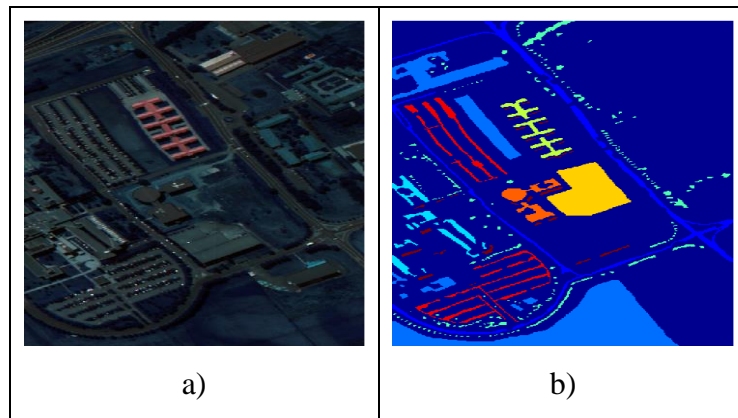
imgesinin belirli üç kanalının birleşimiyle oluşan görüntü ve yer-gerçekliği haritası gözlemlenmektedir.



Şekil 4.3: Salinas imgesinin 30, 100, 190 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası. a) S, b) S-GT.

4.2.3. Pavia Üniversitesi İmgesi

Pavia Üniversitesi imgesi ROSIS-03 (Reflective Optics System Imaging Spectrometer) sensörü tarafından İtalya'da bulunan Pavia Üniversitesi'ni çevreleyen şehir alanı üzerinden elde edilmiştir. İmge boyutu 610x340x103 olarak 1.3 m uzamsal çözünürlükte ve 0.43-0.86 μm spektral kaplam aralığına sahiptir. İmge içerisinde 9 ayrı sınıf bulunmaktadır. Şekil 4.4'te Pavia Üniversitesi imgesinin belirli üç kanalının birleşimiyle oluşan görüntü ve imgenin yer-gerçekliği haritası gözlemlenmektedir.



Şekil 4.4: Pavia Üniversitesi imgesinin 10, 50, 70 numaralı bantlarının birleşiminden oluşan görüntü ve yer-gerçekliği haritası. a) PU, b) PU-GT.

4.3. Hiperspektral İmgelerde Boyut İndirgenmesi

Hiperspektral görüntüler yeryüzünde tarım alanlarının sınıflandırılmasından hedef tespitine kadar geniş uygulama alanında kullanılmaktadır. Onlarca spektral bant içerisinde veriyi temsil etmede gereksiz ve gürültülü bantlar mevcuttur. Komşu spektral bantlar birbirleriyle yüksek oranda ilişkili olabilmekte ve birbirlerinin doğrusal bileşeni olarak yazılabilmektedir. Bu bantlar tespit edilerek veriyi temsil etmede gereksiz spektral bantlar piksel vektör uzayından çıkarılmalıdır. Su buharı soğurması, araç gürültüsü gibi nedenlerden dolayı gürültülü spektral bantlar oluşmaktadır. Yüksek boyutlu hiperspektral görüntünün direk kullanımı aşırı işlem yükü ve işleme zamanı, sistemde hafıza sorununa neden olmaktadır. Bu sebeplerden dolayı hiperspektral görüntüler uygulamalarda kullanılmadan önce öznitelik çıkarımı ya da öznitelik seçimi yöntemleri ile boyutu indirgenmektedir.

Öznitelik seçimi yöntemlerinde tüm öznitelik uzayını temsil eden en iyi alt öznitelik uzayı seçimi yapılırken, öznitelik çıkarımı yöntemlerinde dönüşüm matrisi kullanılarak veri farklı bir uzaya aktarılıp burada en iyi alt uzay seçimi yapılmaktadır. Öznitelik çıkarım yöntemleri doğrusal ve doğrusal olmayan yöntemler olarak iki kısma ayrılabilir. Doğrusal tabanlı yöntemlerde görüntü içerisinde birbirleriyle doğrusal ilişkili bantlar tespit edilerek boyut indirgenmesi yapılırken, doğrusal olmayan yöntemlerde veri çekirdek fonksiyonu ile başka uzaya aktarılıp bu uzayda boyut indirgenmesi yapılmaktadır. Doğrusal tabanlı yöntemler arasında Temel Bileşen Analizi (TBA) [33] yaygın olarak kullanılmaktadır [11], [16], [17]. TBA yöntemiyle hızlı bir şekilde boyut indirgenmesi yapılmaktadır. Doğrusal tabanlı olmayan yöntemlere Kernel Temel Bileşen Analizi [34] örnek verilebilir. Bu yöntemde ise yüksek boyutlu verinin doğrusal uzaya aktarılması sırasında aşırı zaman gereksinimine ihtiyaç duyulmaktadır.

4.3.1. Temel Bileşen Analizi

Temel Bileşen Analizi [33] değişimin maksimum olduğu yönden başlayarak birbirlerine dik temel vektörler (bileşenler) oluşturarak veriyi doğrusal biçimde ifade etmektedir. En büyük varyansa sahip değişimin maksimum olduğu yön en önemli ya da en temel (principle) bileşen olarak adlandırılır. Bileşen vektör uzaylarının

doğrusal kombinasyonları ile veri yeniden temsil edilmektedir. Veri kümesi içerisindeki gürültü ve veriyi temsil etmede gereksiz veri kümesi ayrılarak boyut indirgenmesi yapılmaktadır [35].

Temel bileşen analizini matematiksel olarak modellersek M adet $N \times 1$ 'lik $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$ gözlem veri kümemiz olsun. Bu durumda veri kümemiz \mathbf{X}

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_M^1 \\ x_1^2 & x_2^2 & \dots & x_M^2 \\ \vdots & \vdots & \vdots & \vdots \\ x_1^N & x_2^N & \dots & x_M^N \end{bmatrix} \quad N \times M \quad (4.1)$$

şeklinde yazılmaktadır. \mathbf{X} gözlem kümesi matrisinin satırları bir değişkene ait farklı ölçüm sonuçlarını sütunları ise farklı gözlem kümelerini göstermektedir. Gözlem kümesindeki değişken değerleri birbirinden uzak olabilmektedir. Gözlem vektörlerinin ortalaması

$$\mathbf{m} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}^i = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_N \end{bmatrix} \quad (4.2)$$

olarak yazılmaktadır. Ortalamalar veri kümesinden $\hat{\mathbf{X}} = \mathbf{X} - \mathbf{m}$ şeklinde çıkarılarak değişken değerleri başlangıç noktası etrafında merkezleştirilmektedir. \mathbf{X} gözlem matrisinin tüm değişken çiftleri arasındaki ilişkiyi (correlation) bulmak için kovaryans matrisi hesaplanmaktadır. Kovaryans matrisi

$$\mathbf{S} = \frac{1}{n-1} \hat{\mathbf{X}} \hat{\mathbf{X}}^T \quad (4.3)$$

şeklinde hesaplanmaktadır. \mathbf{S} kovaryans matrisinin köşegenleri varyans değerini, diğer tüm elemanları kovaryans değerini göstermektedir. Varyans değeri veri kümesindeki herhangi bir elemanın kendi üzerinde değişimini gösterirken, kovaryans değeri veri kümesindeki elemanların küme içerisinde diğer elemanlar üzerindeki değişimini göstermektedir. Kovaryans matrisi simetrik matris özelliğine sahiptir. Simetrik matris dik özvektör matrisi ile köşegenleşmektedir. Bu durumda kovaryans matrisi

$$\mathbf{S} = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (4.4)$$

olarak yazılmaktadır. Burada \mathbf{D} köşegen matris, \mathbf{E} özvektör matrisidir. \mathbf{D} köşegen matrisinde elemanlar büyükten küçüğe doğru sıralanarak değişimin maksimum olduğu yön ilk sıraya getirilmektedir. Sıralı özdeğerlere karşı gelen özvektörlerden ilk p tanesi seçilerek \mathbf{W} izdüşüm matrisinin sütunlarına

$$\mathbf{W} = [\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_p] \quad (4.5)$$

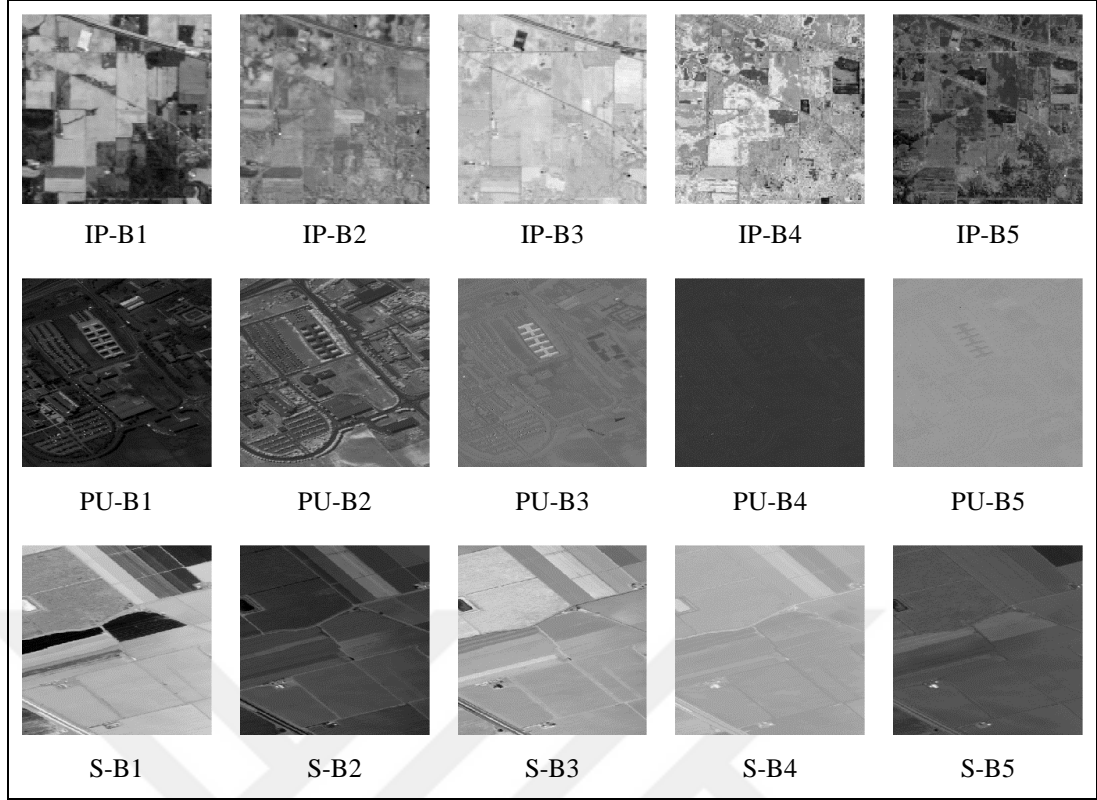
şeklinde yazılmaktadır. İzdüşüm matrisinin gözlem veri kümesi ile çarpılmasıyla gözlem vektörleri başka uzaya aktarılmakta ve boyutu azaltılmış veri kümesi elde edilmektedir [36].

$$\mathbf{Y} = \mathbf{W}^T \mathbf{X} \quad (4.6)$$

Doğrusal tabanlı TBA yöntemiyle boyut indirgeme işlemi hızlı bir şekilde yapılmaktadır. \mathbf{W} izdüşüm matrisinde tüm özvektör değerleri kullanılarak boyutu indirgenmiş veriden işlenmemiş veri uzayına tekrardan dönülebilmektedir.

4.4. Hiperspektral İmgelerden Süperpiksellerin Çıkarılması

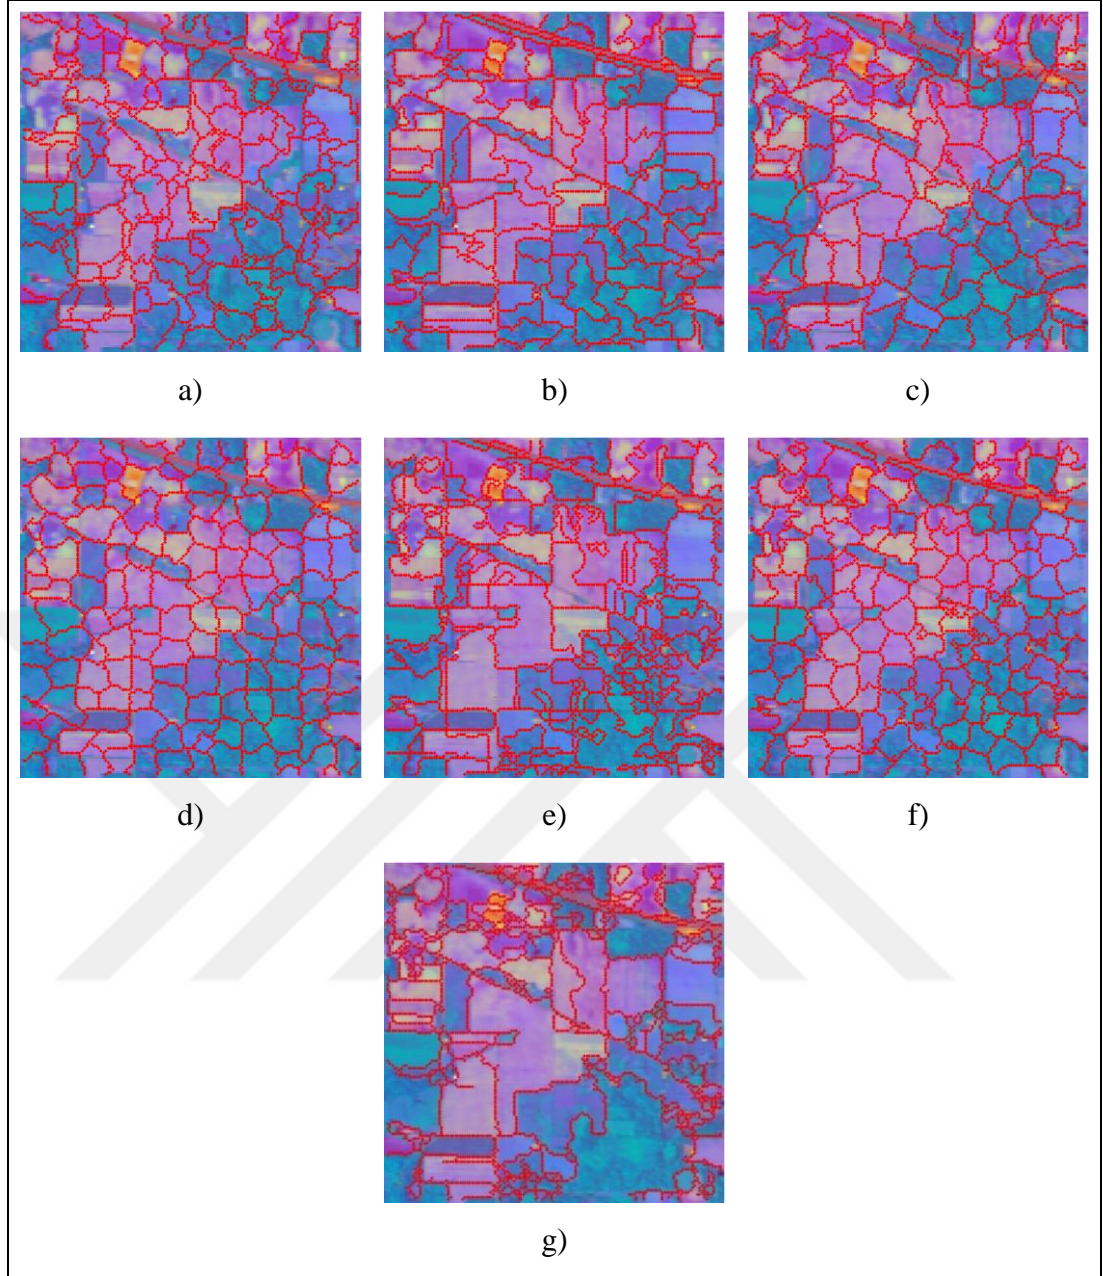
Hiperspektral görüntüler onlarca banttan oluşan yüksek boyutlu piksel vektörlerine sahiptir. Mevcut süperpiksel yöntemleri bilgisayarla görme alanındaki üç kanallı RGB ya da tek kanallı gri seviyeli görüntüler için önerildiğinden hiperspektral görüntüler üzerinde doğrudan kullanımı yoktur. Bu amaçla tez kapsamında yüksek boyutlu hiperspektral görüntülerin boyutu TBA yöntemiyle üçe düşürülmektedir. Şekil 4.5'te Indian Pines, Pavia Üniversitesi ve Salinas görüntülerinin TBA yöntemiyle elde edilen ilk beş bileşeni gözlemlenmektedir. Görüntülerin ilk bileşenlerinden gözlemlendiği gibi imgenin büyük ayrıntıları bu bileşenlerde toplanmış ve gürültü kısmı imgeden temizlenmiştir. Dördüncü bileşende ise gürültü imgelere dahil olmaya başlamıştır. Bu amaçla ilk üç bileşen art arda eklenerek hiperspektral görüntü boyutu $k_1 \times k_2 \times 3$ olarak düzenlenmektedir. Burada k_1 ve k_2 piksel vektörlerinin koordinat bilgileridir.



Şekil 4.5: Indian Pines, Pavia Üniversitesi ve Salinas hiperspektral imgelerinin TBA yöntemiyle elde edilen sıralı ilk beş bileşen görüntüleri.

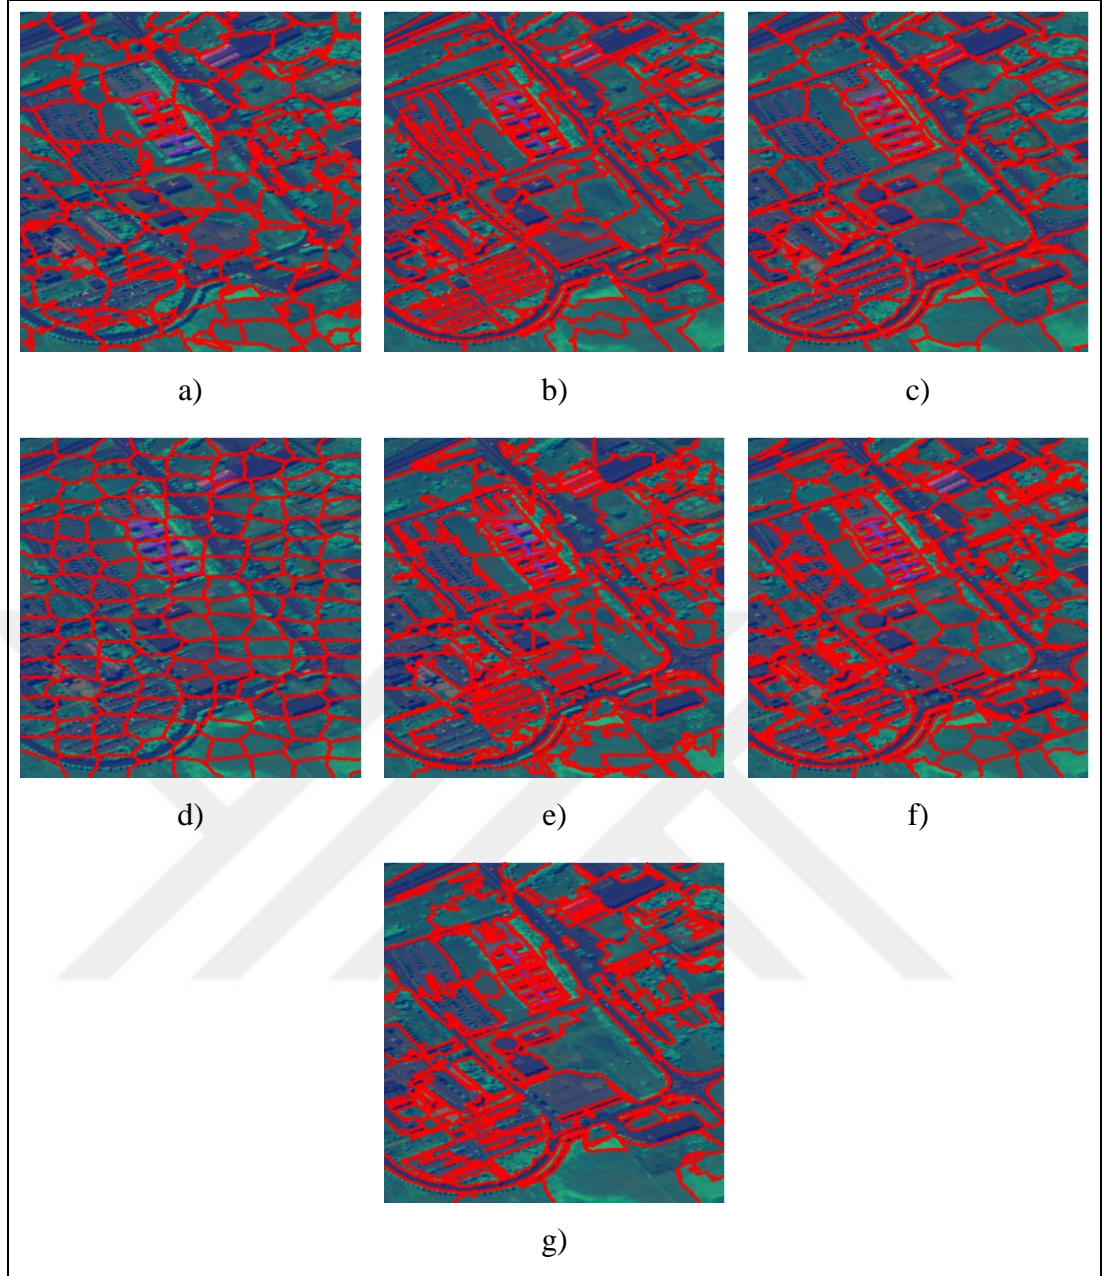
Bu kısımda Bölüm 2’de anlatılan süperpiksel yöntemlerinden GKM, ERS, NC, TP, SLIC, LSC ve QS süperpiksel yöntemleri ile farklı büyüklüklerde süperpikseller çıkarılmakta ve yöntemlerin birbirlerine göre başarımları bölütleme hatası, sınır duyarlılığı ve derlitopluluk bakımından sayısal olarak karşılaştırılmaktadır.

Indian Pines, Pavia Üniversitesi ve Salinas imgelerinden GKM, ERS, NC, TP, SLIC, LSC ve QS süperpikseller yöntemleri kullanılarak elde edilen 150 adet süperpiksel için süperpiksel haritaları sırasıyla Şekil 4.6, Şekil 4.7 ve Şekil 4.8’de gözlemlenmektedir. Şekil 4.6’da Şekil 4.6.b), Şekil 4.6.c) ve Şekil 4.6.d)’den görüldüğü gibi ERS, NC ve TP yöntemleri imge sınırları ile uyumlu süperpikseller üretmektedir. Şekil 4.6.g)’de ise QS yönteminin global imge sınırlarını koruduğu gözlemlenmektedir. Şekil 4.6’da NC, TP ve LSC yöntemleri derlitoplu süperpikseller üretmektedir



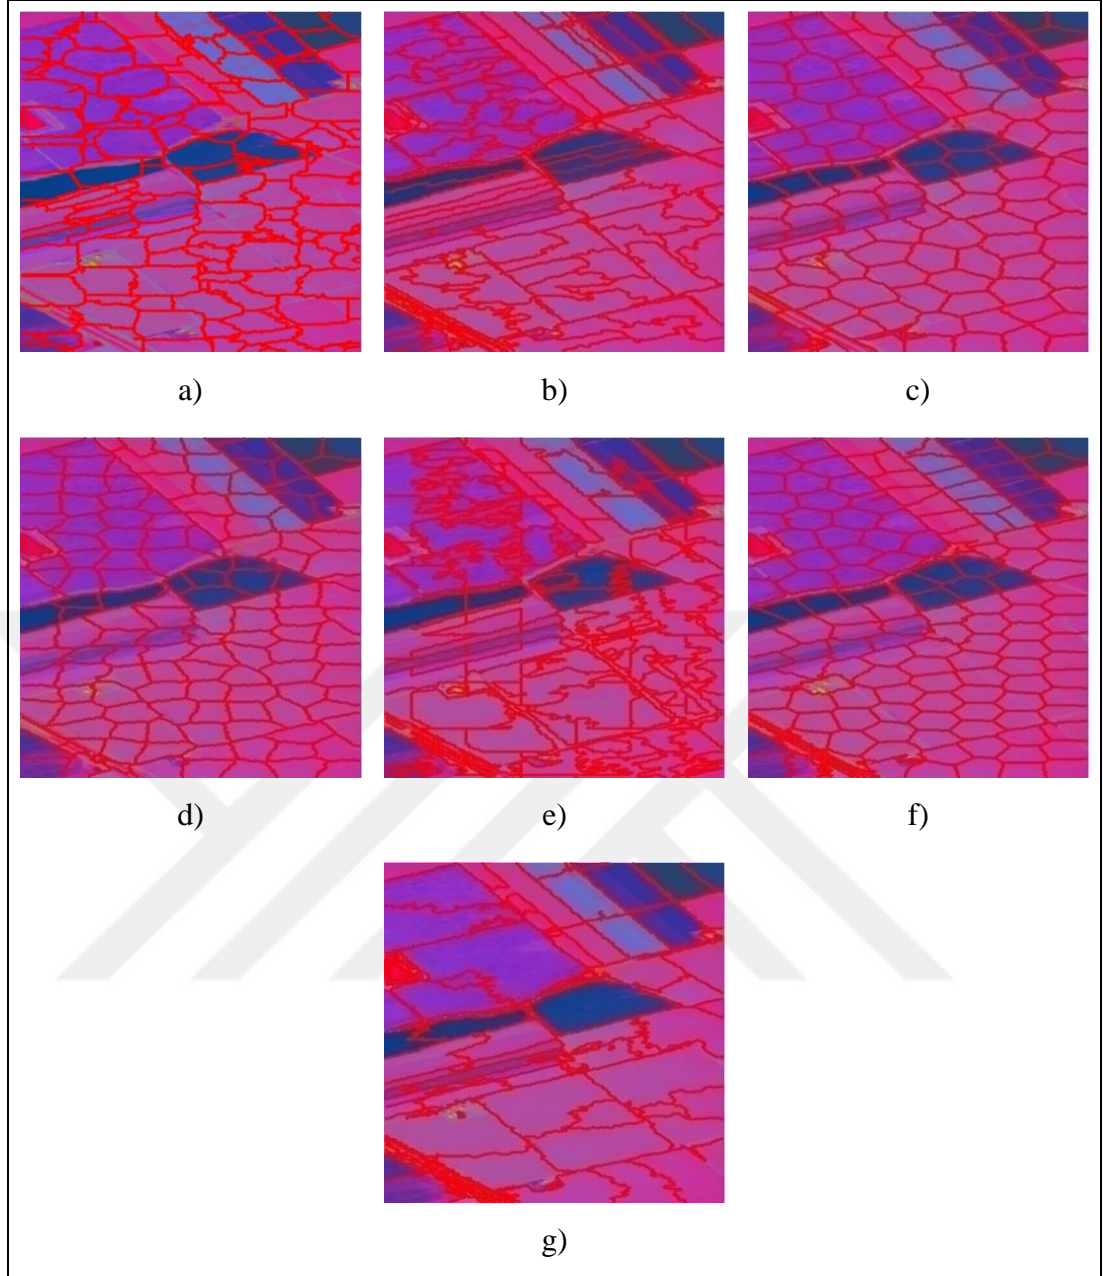
Şekil 4.6: Indian Pines imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları. a) GKM, b) ERS, c) NC, d) TP, e) SLIC, f) LSC, g) QS.

Şekil 4.7’de Şekil 4.7.b), Şekil 4.7.c), Şekil 4.7.f) ve Şekil 4.7.g)’den görüldüğü gibi ERS, NC, LSC ve QS yöntemleri imge sınırları ile uyumlu süperpikseller üretmektedir. QS yöntemi süperpikselleri diğer yöntemlere oranla büyük bölütler göstererek global imge sınırlarını korumaktadır. NC ve TP yöntemleri derlitopluluk bakımından üstün süperpikseller üretmektedir.



Şekil 4.7: Pavia Üniversitesi imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları. a) GKM, b) ERS, c) NC, d) TP, e) SLIC, f) LSC, g) QS.

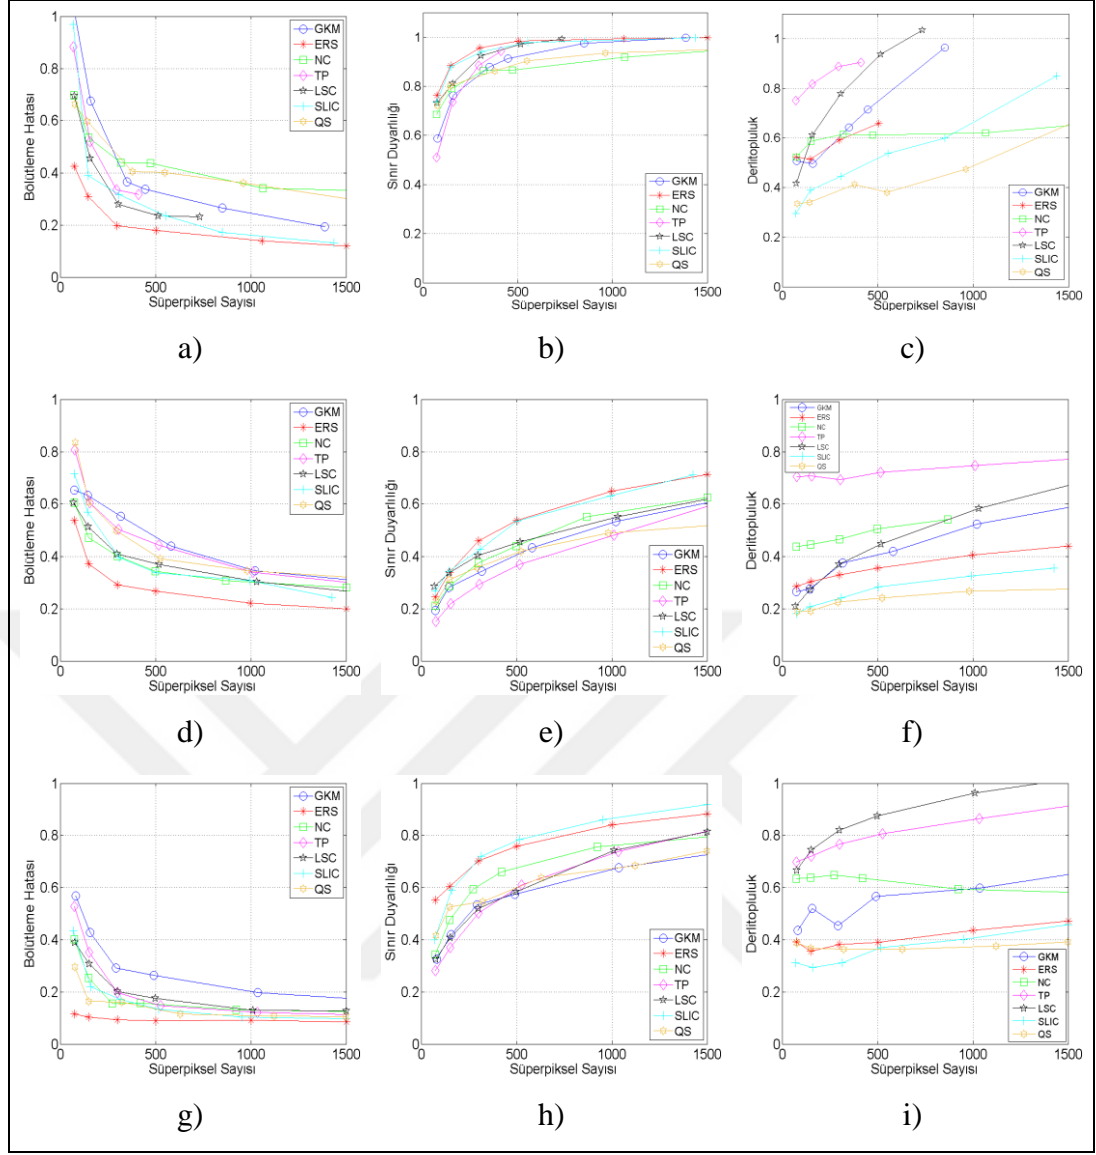
Şekil 4.8’de Şekil 4.8.c), Şekil 4.8.d), Şekil 4.8.f) ve Şekil 4.8.g)’den görüldüğü gibi NC, TP, LSC ve QS yöntemleri sınırlar ile uyumlu süperpikseller üretmektedir. Süperpiksel haritalarını genel olarak yorumlayacak olursak NC, TP ve LSC yöntemleri derlitoplu düzgün süperpikseller üretmektedir. ERS, NC, LSC ve QS yöntemleri düşük süperpiksel sayısında imge sınırları ile uyumlu süperpikseller üretmektedir. Özellikle QS yöntemi imgedeki değişim noktalarında genel sınır



Şekil 4.8: Salinas imgesinin GKM, ERS, NC, TP, SLIC, LSC ve QS yöntemleri kullanılarak elde edilen süperpiksel haritaları. a) GKM, b) ERS, c) NC, d) TP, e) SLIC, f) LSC, g) QS.

bütünlüğünü korumaktadır. GKM yönteminde süperpiksel sınırları ile imge içerisindeki nesnelerin sınırları bazı bölgelerde örtüşmemektedir.

Şekil 4.9'da Indian Pines, Pavia Üniversitesi ve Salinas imgelerinde GKM, ERS, NC, TP, SLIC, LSC ve QS süperpiksel yöntemlerinin bölütleme hatası, sınır duyarlılığı ve derlitopluluk metrikleri ile sayısal karşılaştırılması yapılmaktadır. Bölütleme hatası ölçümünde Şekil 4.9.a), Şekil 4.9.d) ve Şekil 4.9.g)'den görüldüğü



Şekil 4.9: Indian Pines, Pavia Üniversitesi ve Salinas imgeleri için süperpiksel yöntemlerinin UE, BR ve CM ölçümlerinin karşılaştırılması. a) IP-UE, b) IP-BR, c) IP-CM, d) PU-UE, e) PU-BR, f) PU-CM, g) S-UE, h) S-BR, i) S-CM.

gibi imge sınırları ile uyumlu süperpiksel üreten ERS yöntemi en az bölütme hatasına sahiptir. Sınır duyarlılığı ölçümünde Şekil 4.9.b), Şekil 4.9.e) ve Şekil 4.9.h)'den görüldüğü gibi ERS ve SLIC yöntemleri yüksek değer göstermektedir. ERS ve SLIC süperpiksellerinin sınırları diğer yöntemlere göre dalgalı olması sınır duyarlılığı sonucunu artırmaktadır. Derlitopluluk ölçümünde ise Şekil 4.9.c), Şekil 4.9.f) ve Şekil 4.9.i)'den görüldüğü gibi TP, LSC ve GKM süperpiksel yöntemleri derlitoplu süperpiksel üreterek üstün oran vermektedir.

Indian Pines imgesinde GKM, NC, TP, SLIC ve QS algoritmalarında 100 süperpiksel üretmek için gerekli zamanlar saniye cinsinden Tablo 4.1'de

gösterilmektedir. Ölçüm sonuçları MATLAB ortamında Intel(R) Core i7-4790 3.60 Ghz CPU ve 16GB Ram özelliklerine sahip bilgisayar kullanılarak yapılmaktadır. Tabloda algoritmaların çalışması için gerekli zaman, KBT zamanı ve süperpiksellerin tek bölüt halinde elde edilmesi için gerekli toplam zaman gözlemlenmektedir. ERS ve LSC yöntemleri C tabanlı açık koda sahip olduğu için tabloya eklenmemiştir. [5]'te C ortamında SLIC yönteminin LSC ve ERS süperpiksel yöntemlerinden hızlı olduğu gözlemlenmektedir. Tablo 4.1'den görüldüğü gibi algoritma ve toplam zaman bakımından en hızlı yöntem SLIC yöntemidir. Algoritma ve toplam zaman bakımından en yavaş yöntem NC yöntemidir. KBT zamanında en hızlı yöntem ise TP yöntemidir. TP yöntemi üretilmek istenen süperpiksel sayısına bağlı olarak en uyumlu bölüt üretmektedir.

Tablo 4.1: GKM, NC, TP, SLIC ve QS süperpiksel algoritmalarının çalışma zamanları.

Süperpiksel Yöntemleri	Algoritma Zamanı	KBT Zamanı	Toplam Zaman
GKM	3.5353	0.2001	3.7354
NC	8.1948	0.2304	8.4252
TP	1.6537	0.1391	1.7928
SLIC	1.0494	0.2199	1.2693
QS	3.0622	0.8568	3.9190

4.5. Hiperspektral İmgelerin Spektral Alanda Sınıflandırılması

Bu bölümde yüksek spektral boyuttaki pikseller denetimli olarak sınıflandırılmaktadır. Eğitim aşamasında her sınıftan rastgele $N = 15$ olacak şekilde eşit miktarda eğitim verisi seçilerek Olasılıksal Temel Bileşen Analizi (OTBA) [37] ile ilgili sınıfa ait ortalama vektörleri ve kovaryans matrisleri bulunmaktadır. Test aşamasında spektral piksel vektörleri Bayes karar kuralına [38] göre ilgili sınıfa atanmaktadır.

4.5.1. Olasılıksal Temel Bileşen Analizi

Olasılıksal Temel Bileşen Analizi (OTBA) [37] istatistiksel faktör analizi yöntemiyle ilişkili olarak Gauss gizli değişken modeli ile formalize edilmektedir. Temel vektörler en büyük olabilirlik parametre kestirim yöntemiyle bulunmaktadır. Matematiksel olarak d boyutlu \mathbf{t} gözlem vektörü gizli değişken modeli ile doğrusal biçimde

$$\mathbf{t} = \mathbf{W}\mathbf{x} + \boldsymbol{\mu} + \boldsymbol{\epsilon} \quad (4.7)$$

şeklinde yazılmaktadır. Burada \mathbf{x} $q < d$ olmak üzere q boyutlu saklı değişken, \mathbf{W} izdüşüm matrisi, $\boldsymbol{\mu}$ sıfır olmayan ortalamaya sahip parametre vektörü, $\boldsymbol{\epsilon}$ gürültü olarak tanımlanmaktadır. Burada $\mathbf{x} \sim N(\mathbf{0}, \mathbf{I})$ şeklinde sıfır ortalamalı ve birim kovaryans matrisine sahip Gauss dağılımlı ve gürültü $\boldsymbol{\epsilon} \sim N(\mathbf{0}, \boldsymbol{\Psi})$ şeklinde sıfır ortalamalı ve $\boldsymbol{\Psi}$ kovaryans matrisine sahip Gauss dağılımlı olarak modellenirse gözlem vektörü $\mathbf{t} \sim N(\boldsymbol{\mu}, \mathbf{W}\mathbf{W}^T + \boldsymbol{\Psi})$ olarak tanımlanmaktadır. \mathbf{W} ve $\boldsymbol{\Psi}$ matrisleri en büyük olabilirlik teoremi ile kestirilmektedir.

Olasılıksal temel bileşen analizinde gürültü $\boldsymbol{\epsilon}$ isotropik hata modeli olarak tanımlanırsa artık varyans $\Psi_i = \sigma^2$ olarak yazılmaktadır. Bu durumda gürültü $\boldsymbol{\epsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$ şeklinde ifade edilmektedir. \mathbf{t} gözlem vektörünün \mathbf{x} saklı değişkenine göre koşullu olasılığı $\mathbf{t}|\mathbf{x} \sim N(\mathbf{W}\mathbf{x} + \boldsymbol{\mu}, \sigma^2 \mathbf{I})$ olacak şekilde Gauss dağılımına sahiptir. Her iki rastgele değişkenin ayrıştırılmasıyla rastgele değişkenler $\mathbf{x} \sim N(\mathbf{0}, \mathbf{I})$ ve $\mathbf{t} \sim N(\boldsymbol{\mu}, \mathbf{C})$ olarak yazılmaktadır. Burada \mathbf{C} kovaryans matrisi $\mathbf{C} = \mathbf{W}\mathbf{W}^T + \sigma^2 \mathbf{I}$ şeklindedir. Gözlem vektörünün logaritmik olabilirliği

$$L = -\frac{N}{2} \{d \ln(2\pi) + \ln|\mathbf{C}| + \text{tr}(\mathbf{C}^{-1}\mathbf{S})\} \quad (4.8)$$

olarak yazılmaktadır. Burada \mathbf{S}

$$\mathbf{S} = \frac{1}{N} \sum_{n=1}^N (\mathbf{t}_n - \boldsymbol{\mu})(\mathbf{t}_n - \boldsymbol{\mu})^T \quad (4.9)$$

şeklindedir. Burada $\boldsymbol{\mu}$ \mathbf{t} gözlem vektörlerinin ortalaması, \mathbf{S} gözlem matrisinin örnek kovaryans matrisidir. Eşitlik (4.8)'deki L olasılık değerini en büyük yapan \mathbf{W} ve σ^2 değerleri en büyük olabilirlik teoremiyle bulunmaktadır. \mathbf{C} kovaryans matrisi

$$\mathbf{W}_{ML} = \mathbf{U}_q (\boldsymbol{\Lambda}_q - \sigma^2 \mathbf{I})^{1/2} \mathbf{R} \quad (4.10)$$

eşitliği ile enbüyüklenmektedir. Burada \mathbf{U}_q \mathbf{S} matrisinin temel özvektörlerini içeren $d \times q$ boyutlu matris, $\boldsymbol{\Lambda}_q$ \mathbf{S} matrisinin $\lambda_1, \dots, \lambda_q$ özdeğerlerini içeren $q \times q$ boyutlu köşegen matrisi, \mathbf{R} keyfi $q \times q$ boyutlu dikgen matristir. Bu durumda σ^2 için kestirim eşitliği

$$\sigma_{ML}^2 = \frac{1}{d - q} \sum_{j=q+1}^d \lambda_j \quad (4.11)$$

olarak bulunmaktadır [37].

4.5.2. Hiperspektral İmgelerin Spektral Alanda OTBA Tabanlı Sınıflandırılması

İşlenmemiş yüksek boyutlu piksel vektörleri Bayes sınıflandırıcısına [38] göre denetimli olarak OTBA yöntemi tabanlı sınıflandırılmaktadır. Her bir sınıf farklı Gauss dağılımlı olarak düşünülmektedir. Eğitim aşamasında görüntü içerisindeki her sınıftan $N = 15$ adet piksel vektörleri alınarak ilgili sınıfa ait ortalama vektörü ve kovaryans matrisi OTBA yöntemi ile bulunmaktadır. Ortalama vektörü

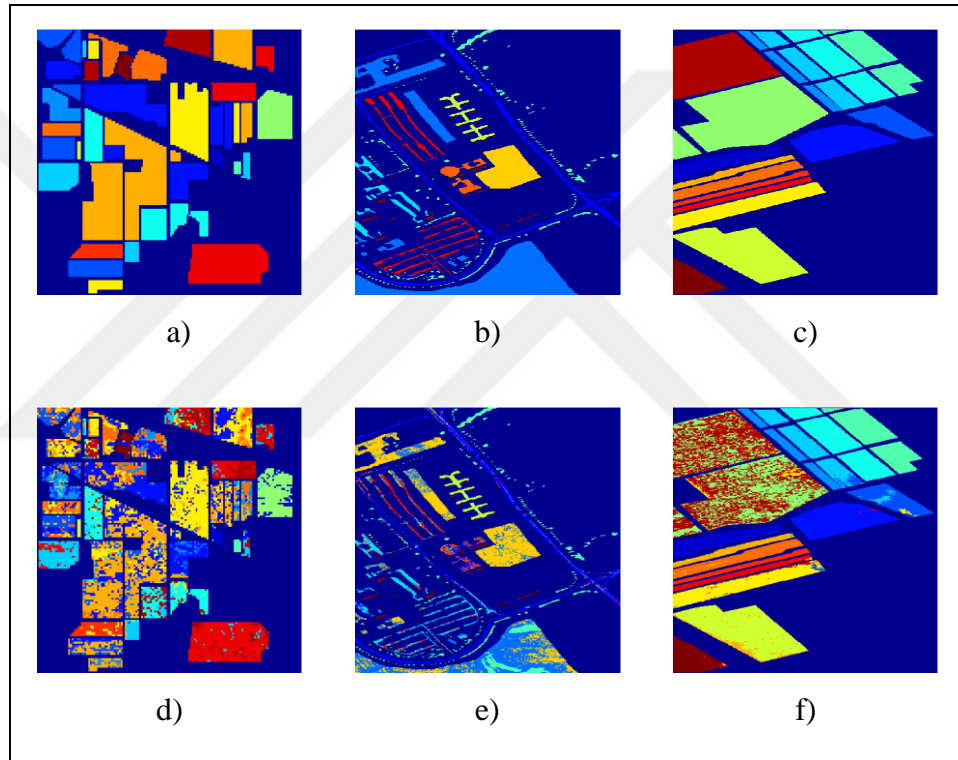
$$\boldsymbol{\mu}_k = \frac{1}{N_k} \sum_{\mathbf{x} \in S_k} \mathbf{x}_n \quad (4.12)$$

şeklinde hesaplanmaktadır. Kovaryans matrisi \mathbf{C} ise Eşitlik (4.9), Eşitlik (4.10) ve Eşitlik (4.11) kullanılarak $\mathbf{C} = \mathbf{W}\mathbf{W}^T + \sigma^2 \mathbf{I}$ şeklinde bulunmaktadır. Burada \mathbf{W} matrisinde q boyutu 5 olarak seçilmektedir. Test aşamasında \mathbf{x} piksel vektörlerinin n adet S_1, S_2, \dots, S_n sınıflarına olan olasılıkları

$$\Pr(S_k|\mathbf{x}) = \frac{p(\mathbf{x}|S_k)\Pr(S_k)}{p(\mathbf{x})} \quad (4.13)$$

şeklinde hesaplanmaktadır. Burada $\Pr(S_k)$ S_k sınıfının önsel olasılığı, $p(\mathbf{x}) = \sum_{k=1}^c p(\mathbf{x}|S_k)\Pr(S_k)$ şeklindedir. Her sınıfın önsel dağılımı eşit alınmaktadır.

Eşitlik (4.13)'teki hiperspektral \mathbf{x} vektörünün S_k sınıfa ait olma olasılıkları hesaplandıktan sonra Bayes kuralına göre en büyük olasılığa sahip sınıfa atanmaktadır. Örneğin iki sınıflı bir durumda \mathbf{x} test vektörü $\Pr(S_1|\mathbf{x}) > \Pr(S_2|\mathbf{x})$ koşulunda S_1 sınıfına atanmaktadır.



Şekil 4.10: Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin OTBA tabanlı Bayes sınıflandırma sonucu haritaları. a) IP-GT, b) PU-GT, c) S-GT, d) IP-Bayes-OTBA, e) PU-Bayes-OTBA, f) S-Bayes-OTBA.

Şekil 4.10'da imgelerin sınıflandırma sonucunda oluşan sınıflandırma haritaları gözlemlenmektedir. Bu haritalardan gözlemlendiği gibi spektral alanda sınıflandırılan piksellerde uzamsal piksel komşulukları dikkate alınmadığından sınıflandırma sonucunda tuz-biber görüntüsüne benzer noktalar oluşmaktadır. Bölüm 4.6'da süperpiksel bölütlerinin sınıflandırılması ile bu noktaların giderilmesi amaçlanarak sınıflandırılmada performans artışı amaçlanmaktadır.

Tablo 4.2’de OTBA tabanlı Bayes sınıflandırıcısının Indian Pines, Pavia Üniversitesi ve Salinas imgeleri için sınıflandırma başarımları gözlemlenmektedir. Burada daha düzenli sınıf konumlarına sahip Salinas görüntüsünde en iyi sınıflandırma sonucu gözlemlenmektedir.

Tablo 4.2: Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin OTBA tabanlı Bayes sınıflandırma sonuçları.

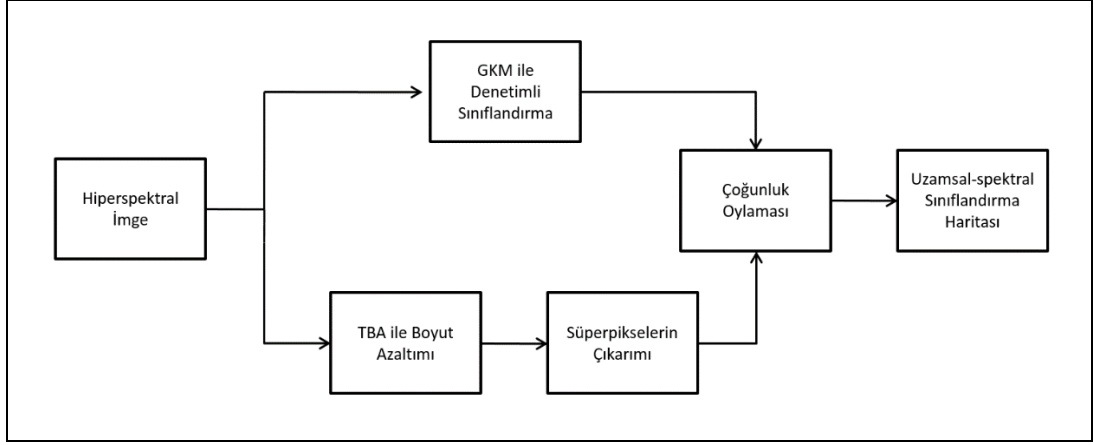
İmge	Bayes - OTBA Sınıflandırma Başarımı
Indian Pines	56.52
Pavia Üniversitesi	71.60
Salinas	83.15

4.6. Uzamsal-Spektral Sınıflandırma

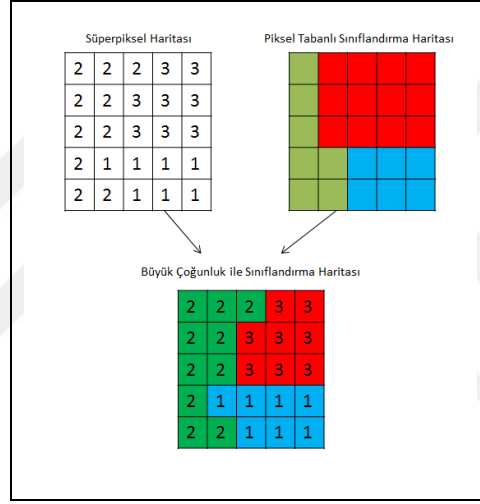
Özniteliklerin sadece spektral alandan çıkarımı Şekil 4.10’den görüldüğü gibi sınıflandırma adımında kısıtlamalar getirmektedir. Bu kısıtlamaları gidermek için uzamsal olarak piksellerin komşuluk bilgilerinin kullanılması ile yeni öznitelikler kullanılmaya başlanmıştır. [11], [16], [17], [39]. [11], [16] ve [17]’de süperpiksel tabanlı uzamsal öznitelikler kullanılırken [39]’de morfolojik tabanlı uzamsal öznitelikler kullanılmaktadır. Bu amaçla bu tezde süperpiksellerin uzamsal bilgiye katkısı kullanılmaktadır.

Hiperspektral görüntülerin uzamsal-spektral sınıflandırma süreci Şekil 4.11’de gösterilmektedir. İlk kısımda TBA ile boyutu azaltılmış hiperspektral görüntülerden süperpikseller çıkarılmaktadır. İkinci kısımda spektral alanda işlenmemiş piksel vektörleri denetimli olarak OTBA tabanlı Bayes sınıflandırıcı ile sınıflandırılmaktadır. Son kısımda ise uzamsal alanda elde edilen süperpikseller ile spektral alanda sınıflandırılmış pikseller çoğunluk oylaması yöntemiyle işbirliği yaparak ortak sınıflandırılmaktadır.

Çoğunluk oylaması yönteminde süperpiksel içerisindeki sınıflandırılmış piksel sınıflarının baskınlığı kontrol edilmektedir. Çoğunluk oylaması süreci Şekil 4.12’de gösterilmektedir. Süperpiksel içerisindeki en büyük sayıda piksel içeren sınıf etiketi süperpikselin sınıfı olarak atanmaktadır. Böylelikle uzamsal ve spektral alanın işbirliği kullanılarak ortak sınıflandırma oluşturulmaktadır.



Şekil 4.11: Hiperspektral imgerde uzamsal-spektral sınıflandırma süreci.



Şekil 4.12: Çoğunluk oylaması yöntemi.

4.7. Deney Sonuçları ve Algoritmaların Başarım Karşılaştırmaları

Bu bölümde çoğunluk oylaması yöntemiyle uzamsal ve spektral alanın iş birliği ile oluşturulan ortak sınıflandırıcının uzamsal alanda farklı süperpiksel yöntemlerine karşı başarımları hesaplanmaktadır. Sınıflandırma başarımları sayısal olarak Eşitlik (3.11)'de açıklanan TD metriğiyle ölçülmektedir.

Indian Pines, Pavia Üniversitesi ve Salinas imgeleri için uzamsal-spektral sınıflandırma başarımları GKM, ERS, NC, TP, LSC, SLIC ve QS süperpiksel yöntemlerinde farklı büyüklükte süperpikseller için sırasıyla Tablo 4.3, Tablo 4.4 ve Tablo 4.5'te gözlemlenmektedir. Tablo 4.3'ten görüldüğü gibi Indian Pines görüntüsü için düşük süperpiksel sayısında ERS yöntemi üstün gelirken süperpiksel

sayısının artırılması ile QS yöntemi üstün gelmektedir. 1000 süperpiksel sayısından sonra ise NC yöntemi diğer yöntemlerden üstün başarımlar göstermektedir. Tablo 4.4'te Pavia Üniversitesi için düşük süperpiksel sayılarında ERS yöntemi etkili olmaktadır. Süperpiksel sayısının artırılması ile QS yöntemi ERS yönteminden ortalama %2 oranında üstün gelmektedir. Tablo 4.5'te ise Salinas görüntüsü için 75 ve 150 süperpiksel için ERS yöntemi üstün gelirken daha yüksek sayıda süperpikseller için QS yöntemi ERS yöntemine ortalama %1 oranla üstün gelmektedir. Tabloları genel olarak yorumlayacak olursak ERS yöntemi geniş alanlı süperpikselerde üstün uzamsal-spektral sınıflandırma sağlarken, süperpiksel boyutunun azaltılması ile QS yöntemi uzamsal-spektral sınıflandırmada diğer süperpiksel yöntemlerine oranla iyi sınıflandırma performansı vermektedir. Tablo 4.2'de gözlemlenen spektral sınıflandırma sonuçlarına oranla Indian Pines imgesi için uzamsal-spektral sınıflandırma ile yaklaşık olarak %17 oranında performans artışı görülürken,

Tablo 4.3: Indian Pines imgesinde uzamsal-spektral sınıflandırma sonuçları.

S. Sayısı	GKM	ERS	NC	TP	LSC	SLIC	QS
75	64.64	71.85	68.26	68.88	70.18	63.05	70.84
150	66.51	73.18	69.84	69.45	68.63	71.03	73.61
300	67.62	70.24	67.33	68.89	68.61	70.42	73.11
500	67.57	69.26	67.73	66.59	66.97	67.55	71.04
1000	65.61	65.81	68.49	-	65.94	66.42	67.52
1500	65.21	64.79	67.48	-	-	63.43	65.53

Tablo 4.4: Pavia Üniversitesi imgesinde uzamsal-spektral sınıflandırma sonuçları.

S. Sayısı	GKM	ERS	NC	TP	LSC	SLIC	QS
75	66.11	77.75	75.44	67.45	73.01	70.88	72.78
150	69.18	82.71	76.57	71.81	76.19	74.43	77.75
300	73.33	78.81	75.96	74.22	77.59	76.01	80.09
500	74.40	78.29	78.14	76.18	75.21	76.42	79.56
1000	75.40	78.25	75.43	75.27	75.92	76.30	80.38
1500	75.02	77.23	77.45	76.79	77.41	75.96	79.08

Tablo 4.5: Salinas imgesinde uzamsal-spektral sınıflandırma sonuçları.

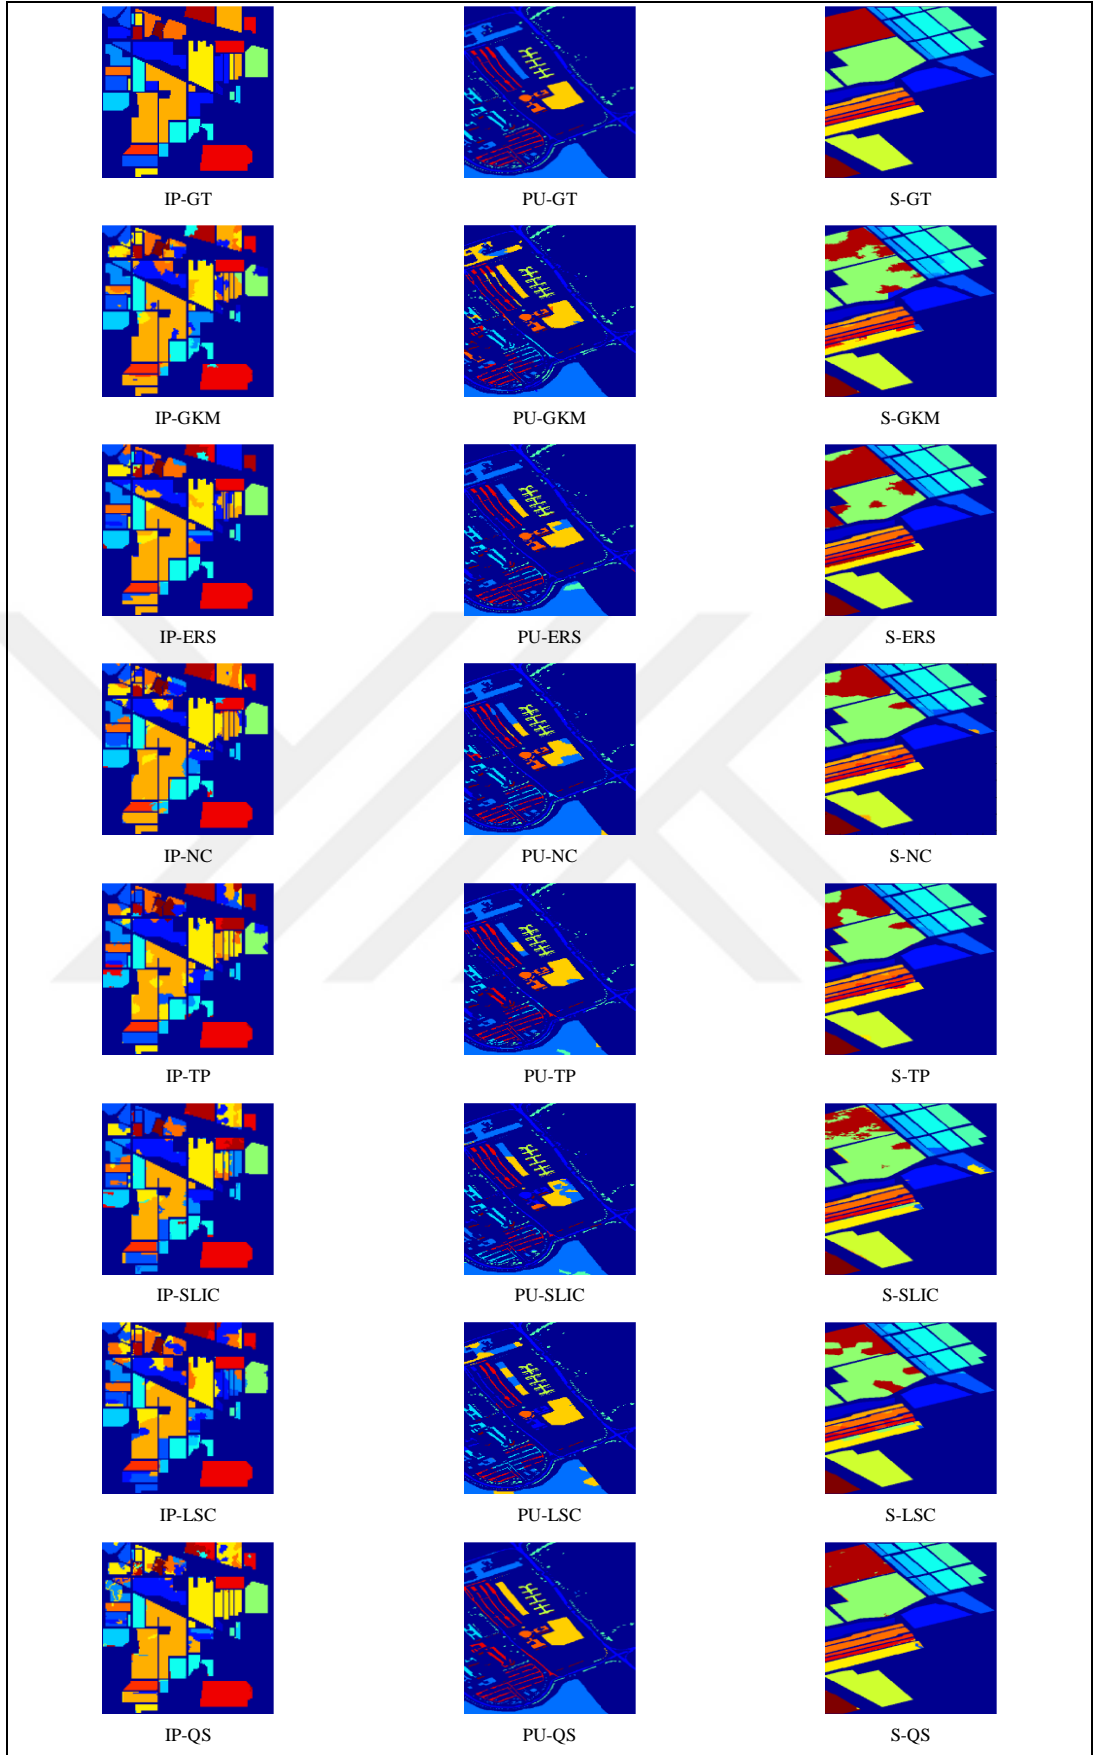
S. Sayısı	GKM	ERS	NC	TP	LSC	SLIC	QS
75	78.92	92.58	81.21	78.44	81.99	82.78	85.57
150	84.96	89.37	84.82	81.31	81.48	85.07	87.91
300	83.36	89.52	87.30	86.46	87.38	87.64	90.18
500	83.91	88.05	88.03	87.96	86.47	87.61	88.91
1000	86.48	87.57	87.38	87.09	87.48	86.83	87.67
1500	85.80	86.40	87.35	86.57	85.38	86.15	87.81

Pavia Üniversitesi imgesi için %12 oranında artış ve Salinas imgesi için ise yaklaşık %10 oranında performans artışı gözlemlenmektedir.

Şekil 4.13'te Indian Pines, Pavia Üniversitesi ve Salinas imgelerinden elde edilen 300 adet süperpiksel için uzamsal-spektral sınıflandırma sonucu haritası gözlemlenmektedir. Bölüt olarak sınıflandırma sonucunda Şekil 4.10)'a oranla imge içerisindeki nokta şeklindeki gürültüler giderilmiştir. Şekil 4.13'ten gözlemlendiği gibi en iyi sınıflandırma haritası uzamsal alanda QS süperpiksel yöntemi kullanıldığında çıkmaktadır.

4.8. Vargı

Geleneksel spektral tabanlı sınıflandırma yöntemlerinden farklı olarak uzamsal-spektral sınıflandırma yaklaşımı ile hiperspektral imgeler sınıflandırılmıştır. Süperpiksellerin imgeden nesne sınırları korunarak çıkarılması sınıflandırma başarımını etkilemektedir. Uzamsal alanda süperpiksel yöntemlerinden ERS yöntemi geniş alanlı süperpikselerde üstün başarımlar gösterirken, süperpiksel boyutunun azaltılmasıyla QS yöntemi en iyi sınıflandırma sonucu vermektedir. Bu tezde spektral alanda denetimli OTBA tabanlı Bayes sınıflandırıcı kullanılmıştır. Farklı denetimli ya da denetimsiz sınıflandırıcılar kullanılabilir. Süperpiksellerden öznelik çıkarımı yapılarak öznelik uzayında yapılacak sınıflandırma ile başarımlar artırılabilir.



Şekil 4.13: Indian Pines, Pavia Üniversitesi ve Salinas imgelerinin uzamsal-spektral sınıflandırma haritaları.

KAYNAKLAR

- [1] Shi J., Malik J., (2000), "Normalized cuts and image segmentation", IEEE Transactions on Pattern Analysis and Machine Intelligence, 22 (8), 888-905.
- [2] Levinshtein A., Stere A., Kutulakos K., Fleet D. J., Dickinson S. J., Siddiqi K., (2009), "TurboPixels: Fast superpixels using geometric flows", IEEE Transactions on Pattern Analysis and Machine Intelligence, 31 (12), 2290-2297.
- [3] Liu M. Y., Tuzel O., Ramalingam S., Felzenszwalb R. C., Huttenlocher D., (2011), "Entropy rate superpixel segmentation", IEEE Conference on Computer Vision and Pattern Recognition, 2097-2104, Colorado Spring, USA, 20-25 June.
- [4] Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Susstrunk S., (2012), "SLIC superpixels compared to state-of-the-art superpixel methods", IEEE Transactions on Pattern Analysis and Machine Intelligence, 34 (11), 2274-2281.
- [5] Li Z., Chen J., (2015), "Superpixel segmentation using linear spectral clustering", IEEE Conference on Computer Vision and Pattern Recognition, 1356-1363, Boston, USA, 7-12 June.
- [6] Vedaldi A., Soatto S., (2008), "Quick shift and kernel methods for mode seeking", IEEE Conference on Computer Vision, 705-718, Marseille, France, 12-18 October.
- [7] Xiang D., Tang T., Zhao L., Su Y., (2013), "Superpixel generating algorithm based on pixel intensity and location similarity for SAR image classification", IEEE Geoscience and Remote Sensing Letters, 10 (6), 1414-1418.
- [8] Kayabol K., (2015), "Model-based superpixel segmentation of SAR images", European Signal Processing Conference, 1800-1804, Nice, France, 31 August - 4 September.
- [9] Arisoy S., Kayabol K., (2016), "Mixture-based superpixel segmentation and classification of SAR images", IEEE Geoscience and Remote Sensing Letters (under revision).
- [10] Arisoy S., Kayabol K., (2015), "Superpixel-based classification of SAR images", 23. IEEE Signal Processing and Communications Applications Conference, 780-783, Malatya, Turkey, 16-19 May.
- [11] Arisoy S., Kayabol K., (2016), "Comparison of superpixel algorithms on hyperspectral images", 24. IEEE Signal Processing and Communications Applications Conference, 1469-1472, Zonguldak, Turkey, 16-19 May.

- [12] He X., Zemel S. R., Ray D., (2006), "Learning and incorporating top-down cues in image segmentation", European Conference on Computer Vision, 338-351, Graz, Austria, 7-13 May.
- [13] Fulkerson B., Vedaldi A., Soatto S., (2009), "Class segmentation and object localization with superpixel neighborhoods", IEEE International Conference on Computer Vision, 670-677, Kyoto, Japan, 29 September - 2 October.
- [14] Hoiem D., Stein A. N., Efros A. A., Hebert M., (2007), "Recovering occlusion boundaries from a single image", IEEE International Conference on Computer Vision, 1-8, Rio de Janeiro, Brazil, 14-20 October.
- [15] Hoiem D., Efros A. A., Hebert M., (2005), "Automatic photo pop-up", International Conference on Computer Graphics and Interactive Techniques, 577-584, New York, USA, 31 July - 4 August.
- [16] Fang L., Li S., Duan W., Ren J., Benediktsson J. A., (2015), "Classification of hyperspectral images by exploiting spectral-spatial information of superpixel via multiple kernels", IEEE Transactions on Geoscience and Remote Sensing, 53 (12), 6663-6674.
- [17] He Z., Shen Y., Zhang M., Wang Q., Wang Y., Yu R., (2014), "Spectral spatial hyperspectral image classification via SVM and superpixel segmentation", International Instrumentation and Measurement Technology Conference, 422-427, Montevideo, Uruguay, 12-15 May.
- [18] Web 1, (2004), https://en.wikipedia.org/wiki/Lab_color_space, (Erişim Tarihi: 27/05/2016).
- [19] Feng H., Hou B., Gong M., (2011), "SAR image despeckling based on local homogeneous-region segmentation by using pixel-relativity measurement", IEEE Transactions on Geoscience and Remote Sensing, 49 (7), 2724-2737.
- [20] Oliver C., Quegan S., (1998), Understanding Synthetic Aperture Radar Images, 1st Edition, Artech House.
- [21] Ellis W. D., (1999), A Source Book of Gestalt Psychology, 1st Edition, Psychology Press.
- [22] Gelman A., Carlin J. B., Stern H. S., Dunson D. B., Vehtari A., Rubin D. B., (2014), Bayesian Data Analysis, 3rd Edition, CRC Press.
- [23] Besag J., (1974), "Spatial interaction and statistical analysis of lattice system", Journal of the Royal Statistical Society: Series B, 36 (2), 192-236.
- [24] Schick M. A., Stiefelhagen R., (2012), "Measuring and evaluating the compactness of superpixels", International Conference on Pattern Recognition, 930-934, Tsukuba, Japan, 11-15 November.

- [25] Moreira A., Iraola. P. P, Younis M., Krieger G., Hajnsek I., Papathanassiou K. P., (2013), "A Tutorial on synthetic aperture radar", IEEE Geoscience and Remote Sensing Magazine, 1 (1), 6-43.
- [26] Mahafza R. B., (2000), Radar Systems Analysis and Design Using Matlab, 1st Edition, Chapman&Hall/Crc.
- [27] Web 2, (2014), <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9567>, (Eriřim Tarihi: 27/05/2016).
- [28] Lloyd S. P, (1982), "Least squares quantization in PCM", IEEE Transactions on Information Theory, 28 (2), 129-137.
- [29] Ward J. H., (1963), "Hierarchical grouping to optimize an objective function", Journal of the American Statistical Association, 58 (301), 236-244.
- [30] Titterington D., Smith A., Makov U., (1985), Statistical Analysis of Finite Mixture Distributions, 1st Edition, Wiley.
- [31] Timm N. H., (2007), Applied Multivariate Analysis, 1st Edition, Springer.
- [32] Web 3, (2007), <http://www.cs.cmu.edu/~guestrin/Class/10701-S07/Slides/bns-learn-clustering.pdf>, (Eriřim Tarihi: 27/05/2016).
- [33] Jolliffe I. T., (2002), Principal Component Analysis, 2nd Edition, Springer-Verlag New York.
- [34] Scholkopf B., Smola A., Müller K. B., (1997), "Kernel principal component analysis", International Conference on Artificial Neural Networks, 583-588, Lausanne, Switzerland, 8-10 October.
- [35] Web 4, (2006), <http://www.cs.cmu.edu/~elaw/papers/pca.pdf>, (Eriřim Tarihi: 27/05/2016).
- [36] Yazar I., Yavuz H. S., Çay M. A., (2009), "Temel bileřen analizinin ve bazı klasik ve robust uyarlamalarının yüz tanıma uygulamaları", Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 22 (1), 49-63.
- [37] Tipping M. E., Bishop C. M., (1999), "Probabilistic principal component analysis", Journal of the Royal Statistical Society, 61 (3), 611-622.
- [38] Theodoridis S., Koutroumbas K., (2009), Pattern Recognition, 4th Edition, Academic Press.
- [39] Pesaresi M., Benediktsson J. A., (2001), "A new approach for the morphological segmentation of high-resolution satellite imagery", IEEE Transactions on Geoscience and Remote Sensing, 39 (2), 309-320.

ÖZGEÇMİŞ

Sertaç ARISOY 1991 yılında Gebze’de doğdu. 2009 yılında başladığı İstanbul Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü’nü 2013 yılında tamamladı. 2014 yılında yüksek lisans eğitimine Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı’nda başladı. 2015 yılından bu yana Gebze Teknik Üniversitesi Elektronik Mühendisliği Bölümü’nde araştırma görevlisi olarak Görüntü İşleme ve Örüntü Tanıma alanında çalışmaktadır.



EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Arisoy S., Kayabol K., (2015), “Superpixel-based classification of SAR images”, 23. IEEE Signal Processing and Communications Applications Conference, 780-783, Malatya, Turkey, 16-19 May.

Arisoy S., Kayabol K., (2016), “Mixture-based superpixel segmentation and classification of SAR images”, IEEE Geoscience and Remote Sensing Letters (under revision).

Arisoy S., Kayabol K., (2016), “Comparison of superpixel algorithms on hyperspectral images”, 24. IEEE Signal Processing and Communications Applications Conference, 1469-1472, Zonguldak, Turkey, 16-19 May.