

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YEREL ÖZNİTELİK TEMELLİ ÖZELLİK PROFİLLERİ VE
SÜPERPİKSEL BÖLÜTLEME KULLANILARAK
HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

ÇAĞATAY DEVECİ

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YEREL ÖZNİTELİK TEMELLİ ÖZELLİK PROFİLLERİ VE
SÜPERPİKSEL BÖLÜTLEME KULLANILARAK
HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

ÇAĞATAY DEVECİ

Doç. Dr. M. Kemal GÜLLÜ
Danışman, Kocaeli Üniversitesi
Prof. Dr. Oğuzhan URHAN
Jüri Üyesi, Kocaeli Üniversitesi
Dr. Öğr. Üyesi Köksal HOCAOĞLU
Jüri Üyesi, Gebze Teknik Üniversitesi

(Handwritten signatures in blue ink)

Tezin Savunulduğu Tarih: 09.07.2019

ÖNSÖZ VE TEŞEKKÜR

Bu tez kapsamında, hiperspektral görüntülerin sınıflandırılması üzerine çalışma yapılmıştır. Hiperspektral görüntü sınıflandırmayla ilgili yaptığım bu çalışmanın, bu konu üzerinde çalışan araştırmacılara yararlı olmasını diliyorum.

Lisans ve yüksek lisans eğitimim boyunca bana yol gösteren, değerli bilgi ve desteğini esirgemeyen çok değerli hocam Doç.Dr. M.Kemal GÜLLÜ'ye teşekkür ederim.

Lisans ve yüksek lisans eğitimim boyunca desteğini benden esirgemeyen sevgili eşim, annem ve babama teşekkürlerimi sunarım.

Eylül - 2019

Çağatay DEVECİ

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ	iii
TABLolar DİZİNİ	v
SİMGELER DİZİNİ VE KISALTMALAR	vi
ÖZET	vii
ABSTRACT	viii
GİRİŞ	1
1. HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA	4
1.1. Giriş	4
1.2. Hiperspektral Görüntüleme	4
1.3. Veri Kümeleri	6
1.4. Boyut Azaltımı	12
1.4.1. Doğrusal tahmin hatası	13
1.4.2. Temel bileşenler analizi (TBA)	14
1.5. Sınıflandırma	16
1.5.1. Özellik profilleri	18
1.5.2. Yerel ikili örüntüler	20
2. ÖNERİLEN SINIFLANDIRMA YÖNTEMİ	23
2.1. Giriş	23
2.2. Yerel Öznitelik Temelli Özellik Profilleri	24
2.3. Süperpiksel Bölütleme	27
2.4. Deneysel Sonuçlar	29
3. SONUÇLAR VE ÖNERİLER	43
KAYNAKÇA	45
KİŞİSEL YAYIN VE ESERLER	47
ÖZGEÇMİŞ	48

ŞEKİLLER DİZİNİ

Şekil 1.	Geliştirilen yöntemin blok şeması	2
Şekil 1.1.	Hiperspektral görüntüleme düzeneği	5
Şekil 1.2.	Hiperspektral görüntü, a) Hiperspektral imge küpü, b) Spektral imza.....	6
Şekil 1.3.	Indian Pines veri kümesi görüntüsü.....	7
Şekil 1.4.	Indian Pines veri kümesi gerçek sınıf haritası.....	7
Şekil 1.5.	Salinas veri kümesi görüntüsü, a) Salinas sahte renklendirilmiş görüntü, b) Salinas veri kümesi gerçek sınıf haritası.....	9
Şekil 1.6.	Pavia merkezi veri kümesi görüntüsü, a) Pavia merkezi sahte renklendirilmiş görüntü, b) Pavia merkezi gerçek sınıf haritası	10
Şekil 1.7.	Pavia Üniversitesi veri kümesi görüntüsü, a) Pavia Üniversitesi sahte renklendirilmiş görüntü, b) Pavia Üniversitesi gerçek sınıf haritası.....	11
Şekil 1.8.	a) Salinas 20. bant görüntüsü, b) 1.TB görüntüsü, c) 2.TB görüntüsü, d) 3.TB görüntüsü.....	15
Şekil 1.9.	Morfolojik özellik profillerinin elde edilme adımları.....	19
Şekil 1.10.	Maksimum-ağaç oluşturma adımları, a) Her piksel için gri değer gösterildiği görüntü, b) Bağlı bölgeleri temsil eden izo-seviyeli bölgeler, c) C bileşeninde görüntüyü tanımlayan maksimum ağaç yapısı.....	19
Şekil 1.11.	Örnek bir görüntünün özellik profilleri ve bir piksele ait öznitelik vektörü gösterimi.....	20
Şekil 1.12.	M ve R değerlerine bağlı komşu piksellerin görünümü.....	21
Şekil 1.13.	M=8 ve R=3 için YİÖ kodu hesaplaması.....	21
Şekil 1.14.	YİÖ görüntüsü ve YİÖ görüntüsünden öznitelik çıkartılması	22
Şekil 2.1.	Önerilen yöntemle ait blok şema	23
Şekil 2.2.	LFAP (YÖTÖP) ortalama vektörünün çıkartılması adımları.....	26
Şekil 2.3.	LFAP (YÖTÖP) aralık vektörünün çıkartılması adımları	26
Şekil 2.4.	Süperpiksel haritası elde etme adımları, a) Salinas sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme (100 adet süperpiksel) sonrasında süperpiksel haritası, c) Süperpiksel birleştirme sonrasında nihai süperpiksel haritası.....	29
Şekil 2.5.	Indian Pines veri kümesinin sınıflandırma aşamalarındaki sınıflandırma haritaları, a) Gerçek sınıf haritası, b) LFAP sınıflandırma haritası, c) Süperpiksel birleştirme öncesindeki sınıflandırma haritası, d) Süperpiksel birleştirme sonrasındaki sınıflandırma haritası	34

Şekil 2.6.	Indian Pines veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası.....	36
Şekil 2.7.	Salinas veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası	37
Şekil 2.8.	Pavia Üniversitesi veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası.....	38
Şekil 2.9.	Pavia merkezi veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası.....	39
Şekil 2.10.	Yöntemlerin toplam süre ve sınıflandırma başarımları gösterimleri, a) Salinas veri kümesi sınıflandırma başarımları-toplam süre gösterimi, b) Indian Pines veri kümesi sınıflandırma başarımları-toplam süre gösterimi, c) Pavia Üniversitesi veri kümesi sınıflandırma başarımları-toplam süre gösterimi, d) Pavia merkezi veri kümesi sınıflandırma başarımları-toplam süre gösterimi.....	42

TABLolar DİZİNİ

Tablo 1.1.	Indian Pines gerçek sınıf haritasındaki sınıfların eleman sayıları	8
Tablo 1.2.	Salinas gerçek sınıf haritasındaki sınıfların eleman sayıları	9
Tablo 1.3.	Pavia merkezi gerçek sınıf haritasındaki sınıfların eleman sayıları	11
Tablo 1.4.	Pavia Üniversitesi gerçek sınıf haritasındaki sınıfların eleman sayıları.....	12
Tablo 1.5.	Salinas veri seti için literatür sınıflandırma sonuçları	17
Tablo 1.6.	Indian Pines veri seti için literatür sınıflandırma sonuçları	18
Tablo 1.7.	Pavia Üniversitesi veri seti için literatür sınıflandırma sonuçları	18
Tablo 2.1.	Indian Pines veri kümesi eğitim ve test sayıları	30
Tablo 2.2.	Salinas veri kümesi eğitim ve test sayıları	30
Tablo 2.3.	Pavia Üniversitesi veri kümesi eğitim ve test sayıları	31
Tablo 2.4.	Pavia merkezi veri kümesi eğitim ve test sayıları	31
Tablo 2.5.	Farklı süperpiksel sayıları için sınıflandırma başarımları.....	33
Tablo 2.6.	Indian Pines için sınıflandırılması aşamalarındaki sınıflandırma başarımları.....	33
Tablo 2.7.	Salinas veri seti sınıflandırma sonucu karşılaştırma tablosu.....	40
Tablo 2.8.	Indian Pines veri seti sınıflandırma sonucu karşılaştırma tablosu.....	40
Tablo 2.9.	Pavia Üniversitesi'nin sınıflandırma sonucu karşılaştırma tablosu	40
Tablo 2.10.	Pavia merkezinin sınıflandırma sonucu karşılaştırma tablosu	40
Tablo 2.11.	Salinas'ın bir piksel için ortalama sınıflandırma süreleri	41
Tablo 2.12.	Indian Pines'in bir piksel için ortalama sınıflandırma süreleri	41
Tablo 2.13.	Pavia Üniversitesi'nin bir piksel için ortalama sınıflandırma süreleri.....	41
Tablo 2.14.	Pavia merkezinin bir piksel için ortalama sınıflandırma süreleri.....	41
Tablo 2.15.	LFAP ve ULBP'nin destek vektörü sayıları ve hesapsal karmaşıklık	42

SİMGELER DİZİNİ VE KISALTMALAR

Kısaltmalar

BB	: Bağlı bileşen
DVM	: Destek vektör makinesi
EOS	: Entropi oranı süperpiksel
LFAP (YÖTÖP)	: Yerel öznitelik temelli özellik profilleri
NA	: Uygulanmaz
SB	: Süperpiksel bölütleme
TB	: Temel bileşen
TBA	: Temel bileşenler analizi
YİÖ	: Yerel ikili örüntü

YEREL ÖZNETELİK TEMELLİ ÖZELLİK PROFİLLERİ VE SÜPERPİKSEL BÖLÜTLEME KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

ÖZET

Hiperspektral görüntüler, nesnelere yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandında ölçümü ile elde edilir. Hiperspektral görüntüler, yüksek spektral ayrımsamaya sahip olmanın yanında düşük uzamsal çözünürlüğe sahiptir. Hiperspektral görüntülerin düşük uzamsal çözünürlüğüne rağmen her bir piksel için her bir bant özellik taşıdığından dolayı birbirine yakın farklı sınıfların sınıflandırılmasında başarımlar önemli ölçüde arttırılmaktadır.

Bu tez kapsamında, hiperspektral görüntülerin spektral-uzamsal sınıflandırılmasında yeni yöntemlerin geliştirilmesi üzerinde çalışılmıştır. Öznitelik çıkartımı, özellik profillerinden yerel öznitelikler elde edilerek gerçekleştirilmiştir. Süperpiksel bölütleme(SB) yöntemiyle sınıflandırma haritasındaki hatalı sınıflar düzeltilerek, sınıflandırma başarımlarını arttırılmıştır.

İlk olarak, hiperspektral bantlar yüksek spektral çözünürlüğe sahip oldukları için temel bileşenler analizi ile boyut azaltımı gerçekleştirilmiştir. Yerel öznitelik temelli özellik profilleri ile elde edilen düşük boyutlu öznitelik vektörü kullanılarak sınıflandırma haritası elde edilmiştir. Elde edilen sınıflandırma haritasındaki hataları gidermek amacıyla süperpiksel bölütleme yöntemi kullanılmıştır. Aynı sınıfa ait bölgelerde birden fazla süperpiksel olabileceği için süperpiksel birleştirme işlemi ile mümkün olduğunca aynı sınıfa ait bölgelerdeki süperpikseller birleştirilerek süperpiksel haritası elde edilir. Sınıflandırma haritası, süperpiksel bölütleme ile elde edilen süperpiksel haritası ile düzeltilmiştir. Literatürdeki benzer çalışmalar ile kıyaslandığında hiperspektral görüntülerde düşük öznitelik vektör boyutu kullanılarak yüksek sınıflandırma başarımlarını elde edildiği gösterilmiştir.

Anahtar Kelimeler: Hiperspektral Görüntü, Süperpiksel Bölütleme, Temel Bileşenler Analizi, Yerel Öznitelik Temelli Özellik Profilleri.

HYPERSPECTRAL IMAGE CLASSIFICATION USING LOCAL FEATURE BASED ATTRIBUTE PROFILES AND SUPERPIXEL SEGMENTATION

ABSTRACT

Hyperspectral images are obtained by measuring the reflected energy from objects in narrow and adjacent multiple wavelength bands. Hyperspectral images have high spatial resolution as well as low spatial resolution. Despite low spatial Resolution of hyperspectral images, because of each band has a feature for each pixel, classification performance of classes close to each other is significantly increased

In this thesis, the development of new methods in spectral-spatial classification of hyperspectral images has been studied. Feature extraction is performed by obtaining local features from attribute profiles. By using the superpixel segmentation method, classification performance are increased by correcting the incorrect classes in the classification map.

First of all, as the hyperspectral bands have a high spectral resolution, dimension reduction is performed using the principal component analysis method. The classification map is obtained using the low-dimensional feature vector obtained by local feature-based attribute profiles. Superpixel segmentation method is used to eliminate the errors in the classification map. Because of there may be more than one superpixel in regions of the same class, superpixel map is obtained by combining superpixels in the regions of the same class as possible with superpixel merging. The classification map is corrected with a superpixel map obtained by superpixel segmentation. Compared with similar studies in the literature, it has been shown that hyperspectral images have high classification performance by using a low feature vector dimension.

Keywords: Hyperspectral Image, Local Feature-Based Attribute Profiles, Principal Component Analysis, Superpixel Segmentation.

GİRİŞ

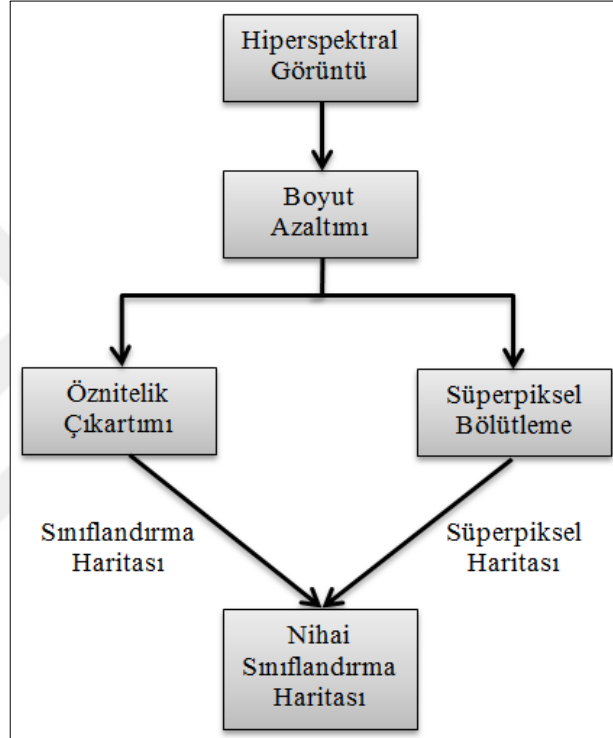
Savunma sanayi, tıp, uzaktan algılama gibi birçok alanda kullanılan hiperspektral görüntüleme farklı dalga boylarında birçok dar ve bitişik dalga boyu bandına ait görüntü alınmaktadır. Bu sebeple hiperspektral görüntüler uzamsal boyuta ek olarak spektral boyutta yoğun bilgi taşımaktadırlar. Hiperspektral görüntüdeki her bir piksel için tüm bantlardaki spektral değerler, o pikseldeki nesnenin spektral imzasını oluşturmaktadır. Bu spektral imza her bir piksel için ayırt edici özellik taşımaktadır. Spektral imza, bölgedeki nesnelere tanımlanması veya görüntünün sınıflandırılması için kullanılmaktadır. Çok sayıda spektral bant görüntüsü kullanılarak, standart görüntü algılayıcılar ile alınan görüntülere göre daha yüksek başarımda sınıflandırma sağlanabilmektedir.

Hiperspektral görüntülerin yüksek boyutlu olması, hesaplama maliyetini ve sınıflandırma başarımını etkilemektedir. Bu sebeple hiperspektral görüntüler üzerinde boyut azaltımı işlemi uygulanarak, hem hesaplama maliyeti düşürülür hem de sınıflandırma başarımı iyileştirilir.

Hiperspektral görüntülerde doğrudan spektral bilgi kullanılarak gerçekleştirilen sınıflandırmada, uzamsal çözünürlüğün düşük olması sebebiyle spektral bilginin ilgili piksele karşılık gelen nesne alanındaki birçok etkenin karışımını içermesinden dolayı başarımları olumsuz yönde etkilenmektedir. Bu yüzden hiperspektral görüntülerin sınıflandırılmasında, boyut azaltımının yanı sıra uzamsal öznitelik çıkartımı yapılmaktadır. Uzamsal ve spektral bilginin birlikte kullanılması sınıflandırma başarımını arttırmaktadır. Öznitelik çıkartımındaki bir problem ise sınıflandırmada kullanılacak olan öznitelik vektörünün boyutunun çok yüksek olabilmesidir. Bu durumda hesapsal maliyet yüksek olmaktadır. Öznitelik vektör boyutu düşürüldüğünde ise sınıflandırma başarımı düşülebilmektedir.

Bu tez çalışmasında, hiperspektral görüntülerin sınıflandırılması konusunda çalışılmıştır. Bu amaçla öncelikle görüntüden yerel öznitelik temelli özellik profilleri kullanılarak yeni öznitelikler çıkartılmıştır. Giriş vektörü boyutunun düşürülmesine

yönelik, boyut azaltımı gerçekleştirilmiştir. Elde edilen düşük boyutlu öznelik vektörüyle sınıflandırma gerçekleştirilmiştir. Sınıflandırma başarımını arttırmak için, süperpiksel bölütleme temelli bir yöntem kullanılmıştır. Bu aşamada, elde edilen sınıflandırma haritasındaki hatalı atanmış sınıf etiketleri, süperpiksel haritası ile düzeltilmiştir. Böylece düşük boyutlu öznelik vektörü kullanılmasına rağmen sınıflandırma başarımının yüksek seviyelerde tutulabildiği bir sınıflandırıcı yapısı elde edilmiştir. Geliştirilen yönteme ilişkin blok şeması Şekil 1’de verilmektedir.



Şekil 1. Geliştirilen yöntemin blok şeması

Hiperspektral görüntüleme sistemleri, uzaktan algılama konusu içerisine dahil olmaktadır. Uzaktan algılama verilerinin elde edilme yöntemleri ve çalışma kapsamında kullanılacak hiperspektral veri kümeleri Bölüm 1’de anlatılmıştır. Yine aynı bölümde hiperspektral görüntülerin yüksek boyutluluk problemini çözmek için kullanılan boyut indirgeme yöntemlerine değinilmiştir. Aynı bölümde son olarak hiperspektral görüntü sınıflandırma ile ilgili literatürdeki yöntemler ve mevcut durumdaki hiperspektral görüntü sınıflandırma başarımları anlatılmıştır.

Bölüm 2’de yerel öznelik temelli özellik profilleri yöntemi ve süperpiksel bölütleme yöntemi anlatılmıştır. Yine aynı bölümde, aynı sınıfa ait bölgelerdeki

süperpiksellerin birleřtirilmesi stratejisi anlatılmıřtır. Son olarak farklı veri kümeleri ile elde edilen sonuçlar, literatürdeki benzer çalıřmalar ile karřılařtırılarak geliřtirilen yöntemin katkısı gösterilmiřtir.

Bölüm 3'te tez kapsamında yapılan çalıřmalar deęerlendirilerek elde edilen sonuçlar ve ileriki çalıřmalar için öneriler ele alınmıřtır.



1. HIPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

1.1. Giriş

Hiperspektral görüntülerin sınıflandırılmasında, uzamsal-spektral görüntü sınıflandırma yöntemleri kullanıldığında elde edilen sınıflandırma başarımı, sadece spektral bilgi kullanıldığında elde edilen sınıflandırma başarımına göre daha yüksek olmaktadır. Bunun sebebi, uzamsal boyutta çıkarılan özniteliklerin, nesnelerin birbirinden daha iyi ayırt edilebilmesini sağlamasıdır.

Hiperspektral görüntülerin sınıflandırılması temel olarak üç adımdan oluşmaktadır. İlk olarak hiperspektral görüntülerin spektral boyutu çok yüksek olduğu için daha düşük boyutlu bir alt uzaya dönüştürülür. Böylece hem hesapsal maliyet yükselir hem de sınıflandırma performansı iyileştirilir. Boyut azaltımı için temel bileşenler analizi, bant seçimi gibi farklı yöntemler kullanılabilir.

Hiperspektral görüntülerde boyut azaltımından sonra, uzamsal öznitelik çıkartma işlemi gerçekleştirilir. Elde edilen yerel ve/veya global öznitelikler ile birlikte farklı sınıfa ait bölgeleri birbirinden ayırt eden özellikler elde edilmiş olur. Sınıflandırmada kullanılacak öznitelik vektörü, yerel öznitelik veya yerel ve global özniteliklerin kombinasyonundan elde edilebilir. Tek başına global öznitelik kullanılması durumunda oldukça kötü sınıflandırma başarımları elde edilmektedir.


Son olarak sınıflandırma yöntemlerinden biri seçilerek sınıflandırma işlemi gerçekleştirilir. Günümüzde genel olarak sınıflandırma için 2 farklı yöntemden biri kullanılmaktadır. Bunlardan birincisi, makine öğrenmesi diğeri ise derin öğrenme yöntemidir. Hiperspektral görüntünün sınıflandırılmasında sınıflandırıcı yönteminin seçimi, problemden probleme göre değişmektedir.

1.2. Hiperspektral Görüntüleme

Yüzey materyallerinden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandında ölçümü hiperspektral görüntüleme olarak adlandırılır. Her bir yüzey

materyalinin kendisine özgü yansıtma özelliği olduğu için, bu yansıma değerleri yüzey materyallerinin ayırt edilmesini kolaylaştırmaktadır. Hiperspektral terimi kelime anlamı olarak, çok sayıda banttan oluştuğu anlamına gelmektedir. Hiperspektral görüntüler multispektral görüntülere göre çok daha fazla banda sahiptirler.


Hiperspektral görüntüleme, spektrometre ya da tayfölçer adı verilen cihazlarla gerçekleştirilir. Spektrometre içerisindeki optik bileşen, spektrometreye gelen ışığı dar ve bitişik çok sayıda dalga boyu bandına ayırır. Her bir bant için farklı dedektör kullanılarak yüzeyden gelen enerji ölçülür. Hiperspektral görüntüleme düzeneği Şekil 1.1'deki gibidir. Hiperspektral görüntüleme kullanılan spektrometreler dedektör sayısına bağlı olarak 0.01 mikrometre bant genişliğine kadar, 0.4 – 2.5µm dalga boyu aralığında bir ölçüm yapabilir [1].



Şekil 1.1. Hiperspektral görüntüleme düzeneği [1]

Hiperspektral görüntüler üç boyutlu veri içermektedirler ve bu özelliği sebebiyle hiperküp olarak adlandırılırlar. 3 boyutlu hiperspektral görüntü verisindeki ilk iki boyutu uzamsal çözünürlüğü ifade ederken, üçüncü boyut ise spektral bant sayısını ifade etmektedir.

Hiperspektral görüntüde her bir piksel için spektral boyutta elde edilen değerler, o pikselin bulunduğu bölgedeki nesne için ayırt edici özellik taşımaktadır. Bu sebeple her bir piksel için spektral boyuttaki değerler, o piksel için “spektral imza“ olarak adlandırılmaktadır. Hiperspektral imge küpü ve bir piksele ait spektral imza Şekil 1.2'deki gibidir.



Şekil 1.2. Hiperspektral görüntü, a) Hiperspektral imge küpü, b) Spektral imza [12]


Hiperspektral görüntüler her bir piksel için süreklilik gösteren spektrum elde edilmesine bağlı olarak, zengin bir spektral içerik sunarlar. Bu zengin spektral içerik nesnelerin ayırt edilmesinde oldukça faydalı olmaktadır. Hiperspektral görüntülerin dar ve bitişik birçok spektral bandın olmasının yanında en önemli dezavantajları düşük uzamsal çözünürlüğe sahip olmalarıdır. Düşük uzamsal çözünürlüğün sebebi görüntüleme sistemlerinde spektral ve uzamsal çözünürlük arasındaki teknik ödünleşimden kaynaklanmaktadır. Düşük uzamsal çözünürlük, görüntüdeki piksellerin birden fazla nesneyi içine alarak katışımli hale gelmesine neden olmaktadır [1]. Bu durum nesnelerin sınıflandırma performansını olumsuz yönde etkilemektedir.

1.3. Veri Kümeleri

Bu tez çalışması kapsamındaki yöntemlerin geliştirilmesi aşamasında Indian Pines, Salinas, Pavia Üniversitesi ve Pavia merkezi olmak üzere 4 farklı veri kümesi kullanılmıştır.

Indian Pines verisi, Temmuz 1992'de Indiana'nın kuzaybatısındaki Indian Pine bölgesinden alınmış hiperspektral görüntüdür. Indian Pines görüntüsü Şekil 1.3'deki gibidir. Indian Pines verisi 220 spektral bant içermektedir. 104-108, 150-163 arasındaki ve 220. bantlar su soğurma bölgesini kapsayan bantlar çıkartıldığında toplamda 200 adet spektral bant kalmaktadır. Her bir spektral bant görüntüsü 145x145 çözünürlüğündedir. Indian Pines verisi 16 adet sınıf içermektedir. Indian

Pines verisindeki sınıflara ait gerçek sınıf haritası görüntüsü Şekil 1.4'deki gibidir. Gerçek sınıf haritasındaki sınıfların eleman sayıları Tablo 1.1'deki gibidir.



Şekil 1.3. Indian Pines veri kümesi görüntüsü [2]

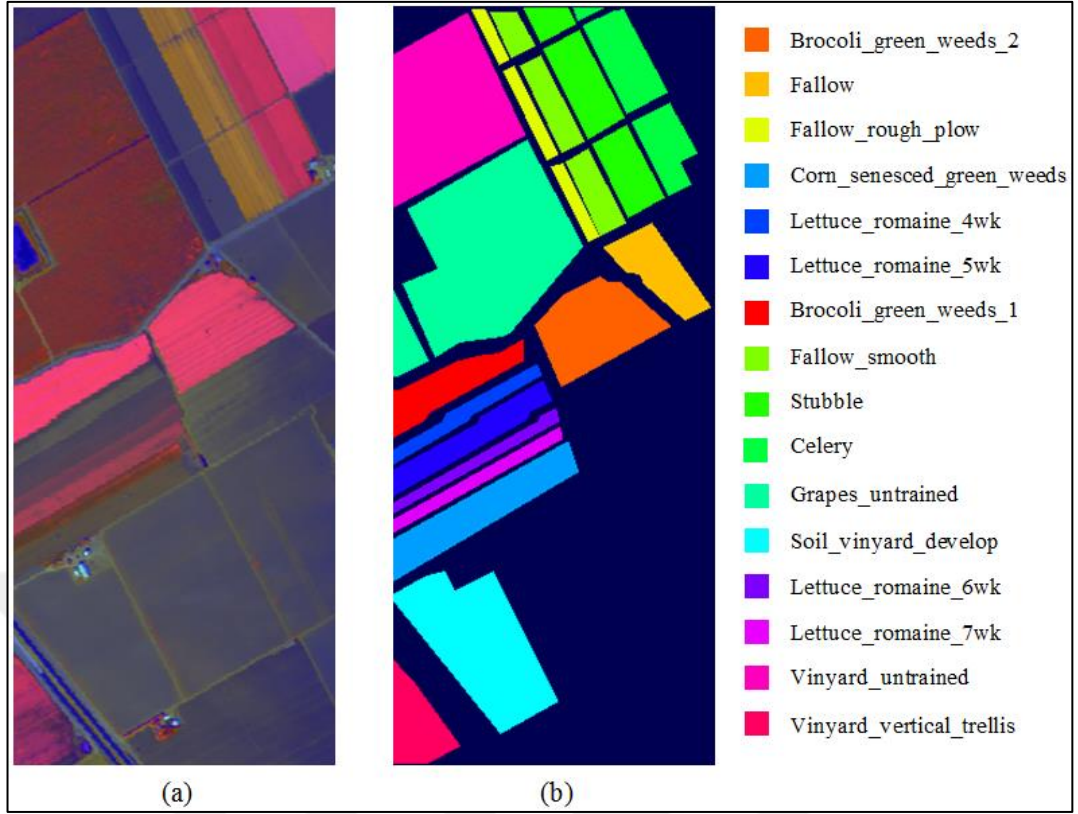


Şekil 1.4. Indian Pines veri kümesi gerçek sınıf haritası

Tablo 1.1. Indian Pines gerçek sınıf haritasındaki sınıfların eleman sayıları

#	Sınıf	Örnek Sayısı
1	Alfalfa	46
2	Corn-notill	1428
3	Corn-mintill	830
4	Corn	237
5	Grass-pasture	483
6	Grass-trees	730
7	Grass-pasture-mowed	28
8	Hay-windrowed	478
9	Oats	20
10	Soybean-notill	972
11	Soybean-mintill	2455
12	Soybean-clean	593
13	Wheat	205
14	Woods	1265
15	Buildings-Grass-Trees-Drives	386
16	Stone-Steel-Towers	93

Salinas verisi, 224 bant AVIRIS sensörüyle Salinas vadisi ve California'da toplanmıştır ve yüksek mekansal çözünürlükte karakterize edilmiştir. Salinas veri kümesinin sahte renklendirilmiş görüntüsü Şekil 1.5'de gösterildiği gibidir. Salinas verisi 224 spektral bant içermektedir. Indian Pines'da olduğu gibi Salinas veri kümesinde de 108-112, 54-167 arasındaki ve 224. bant olmak üzere toplamda 20 adet su soğurmalı bant atıldığında 204 adet spektral bant kalmaktadır. Salinas veri kümesinde her bir spektral bant görüntüsü 512x217 çözünürlüğüne sahiptir. Salinas gerçek sınıf haritası 16 adet sınıf içermektedir. Salinas görüntüsü, sebzeleri, çıplak toprakları ve bağ alanlarını içermektedir. Salinas verisindeki sınıflara ait gerçek sınıf haritası görüntüsü Şekil 1.5'deki gibidir. Gerçek sınıf haritasındaki sınıfların eleman sayıları Tablo 1.2'deki gibidir.

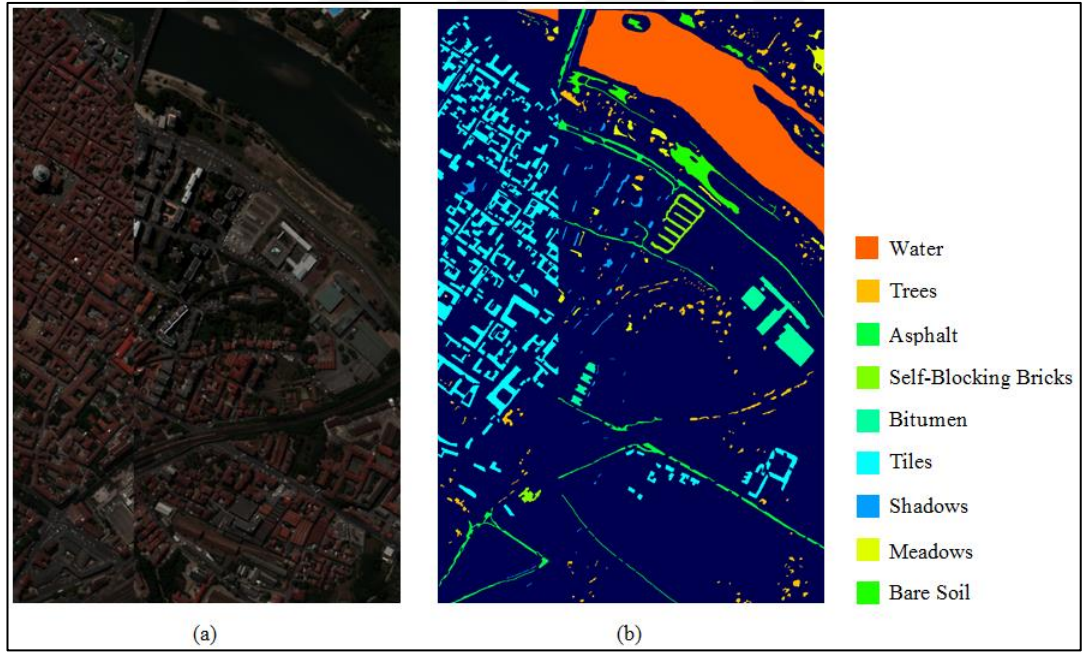


Şekil 1.5. Salinas veri kümesi görüntüsü, a) Salinas sahte renklendirilmiş görüntü, b) Salinas veri kümesi gerçek sınıf haritası

Tablo 1.2. Salinas gerçek sınıf haritasındaki sınıfların eleman sayıları

#	Sınıf	Örnek Sayısı
1	Brocoli_green_weeds_1	2009
2	Brocoli_green_weeds_2	3726
3	Fallow	1976
4	Fallow_rough_plow	1394
5	Fallow_smooth	2678
6	Stubble	3959
7	Celery	3579
8	Grapes_untrained	11271
9	Soil_vinyard_develop	6203
10	Corn_senesced_green_weeds	3278
11	Lettuce_romaine_4wk	1068
12	Lettuce_romaine_5wk	1927
13	Lettuce_romaine_6wk	916
14	Lettuce_romaine_7wk	1070
15	Vinyard_untrained	7268
16	Vinyard_vertical_trellis	1807


Pavia Üniversitesi ve merkezi, ROSIS sensörü tarafından İtalya'nın kuzeyindeki Pavia'ya yapılan bir uçuş kampanyası sırasında elde edilen iki farklı hiperspektral veri kümesidir. Pavia üniversitesi veri kümesi 103 spektral bant içerirken Pavia merkezi veri kümesi 102 spektral bant içermektedir. Pavia merkezi 1096x1096 uzamsal çözünürlüğe sahiptir. Örneklerin bazıları hiçbir bilgi içermemektedir. Analizden önce bu kısımlar atıldığında 1096x715 uzamsal çözünürlük elde edilmektedir. Pavia merkezi gerçek sınıf haritası 9 adet sınıf içermektedir. Pavia merkezi veri kümesi görüntüsü Şekil 1.6'daki gibidir. Gerçek sınıf haritasındaki sınıfların eleman sayıları Tablo 1.3'deki gibidir. Pavia Üniversitesi 610x610 uzamsal çözünürlüğe sahiptir. Benzer şekilde örneklerin bazıları hiçbir bilgi içermemektedir. Analizden önce bu kısımlar atıldığında 610x340 uzamsal çözünürlük elde edilmektedir. Pavia Üniversitesi gerçek sınıf haritası 9 adet sınıf içermektedir. Pavia Üniversitesi veri kümesi görüntüsü Şekil 1.7'deki gibidir. Gerçek sınıf haritasındaki sınıfların eleman sayıları Tablo 1.4'deki gibidir.



Şekil 1.6. Pavia merkezi veri kümesi görüntüsü, a) Pavia merkezi sahte renklendirilmiş görüntü, b) Pavia merkezi gerçek sınıf haritası

Tablo 1.3. Pavia merkezi gerçek sınıf haritasındaki sınıfların eleman sayıları

#	Sınıf	Örnek Sayısı
1	Water	65971
2	Trees	7598
3	Asphalt	9248
4	Self-Blocking Bricks	2685
5	Bitumen	7287
6	Tiles	42826
7	Shadows	2863
8	Meadows	3090
9	Bare Soil	6584



Şekil 1.7. Pavia Üniversitesi veri kümesi görüntüsü, a) Pavia Üniversitesi sahte renklendirilmiş görüntü, b) Pavia Üniversitesi gerçek sınıf haritası

Tablo 1.4. Pavia Üniversitesi gerçek sınıf haritasındaki sınıfların eleman sayıları

#	Sınıf	Örnek Sayısı
1	Asphalt	6631
2	Meadows	18649
3	Gravel	2099
4	Trees	3064
5	Painted metal sheets	1345
6	Bare Soil	5029
7	Bitumen	1330
8	Self-Blocking Bricks	3682
9	Shadows	947

1.4. Boyut Azaltımı

Hiperspektral görüntülerin yüksek spektral boyutluluğa sahip olması, hesapsal maliyete ve sınıflandırma başarımına etki etmektedir. Yüksek spektral boyutluluk, az sayıdaki eğitim örneği ile gerçekleştirilen sınıflandırmada, sınıflandırma başarımı olumsuz etkilenmektedir. Az sayıdaki eğitim örneği ve yüksek spektral boyutluluk ile gerçekleştirilen sınıflandırmada aşırı uydurma problemi oluşabilmektedir. Bu sebeple öznitelik çıkartma işleminden önce boyut azaltımı yöntemleri uygulanmaktadır. Boyut azaltımı ile orijinal veriyi en iyi temsil edecek düşük boyutlu bir alt uzaya geçilir. Boyut azaltımında orijinal verinin tamamen korunduğu bant seçimi yöntemleri veya orijinal verinin tamamının korunmadığı bant çıkarma yöntemlerinden biri kullanılmaktadır. Bant çıkarma yöntemlerinde veri doğrusal veya doğrusal olmayan yöntemle bir alt uzaya taşınır [3]. Hiperspektral görüntülerin boyut azaltımında kullanılan yöntemlerin başında temel bileşenler analizi (TBA) gelmektedir. Bu tez çalışması kapsamında, hiperspektral görüntüde boyut azaltımı için temel bileşenler analizi kullanılmıştır. Sınıflandırma başarımını karşılaştırmak amacıyla, doğrusal tahmin hatası (DTH) yöntemi de denenmiştir. Fakat TBA kullanıldığı zaman daha yüksek başarımlar elde edilmiştir.

1.4.1. Doğrusal tahmin hatası

Hiperspektral görüntüler, gereksiz bilgi içeren birçok banta sahiptir. Ayırt edici ve bilgilendirici özelliklere sahip alt spektral bant kümesi seçilerek yüksek boyut problemi çözülür. Bant seçiminde en çok kullanılan yöntemlerden birisi de doğrusal tahmin hatasıdır. DTH yöntemi uygulaması oldukça basit bir yöntemdir. İlk olarak hiperspektral veri kümesinde birbirine en az benzeyen iki bantın tespiti gerçekleştirilir. Birbirine en az benzeyen bantların bulunması Eşitlik (1.1, 1.2, 1.3, 1.4)'de verilmektedir;

$$X_1 = \frac{\sum_{i=0}^w \sum_{j=0}^h (I_1(i,j) I_2(i,j)) - \left(\left(\sum_{i=0}^w \sum_{j=0}^h (I_1(i,j)) \right) \left(\sum_{i=0}^w \sum_{j=0}^h (I_2(i,j)) \right) \right)}{\left(w \times h \times \left(\sum_{i=0}^w \sum_{j=0}^h I_1(i,j)^2 \right) \right) - \left(\left(\sum_{i=0}^w \sum_{j=0}^h I_2(i,j) \right)^2 \right)} \quad (1.1)$$

$$X_2 = \frac{\sum_{i=0}^w \sum_{j=0}^h I_2(i,j) - X_1 \left(\sum_{i=0}^w \sum_{j=0}^h I_1(i,j) \right)}{(w \times h)} \quad (1.2)$$

$$I_3 = X_2 + (X_1 I_1) \quad (1.3)$$

$$BO = \frac{\left(\sum_{i=0}^w \sum_{j=0}^h (I_3(i,j) - I_2(i,j))^2 \right)}{(w \times h)} \quad (1.4)$$

Buradaki I_1 ve I_2 benzerlik oranı hesaplanacak iki bantı, w ve h değerleri sırasıyla yatayda ve düşeyde görüntünün piksel sayısını, BO ise iki bant arasında hesaplanan benzerlik oranını ifade etmektedir. Tüm bantların birbiriyle arasındaki BO değeri hesaplanır ve en yüksek BO değerine sahip iki bant birbirine en az benzeyen iki bant olarak belirlenmiş olunur.

Birbirine en az benzeyen bantlar B_1 ve B_2 üzerinden bu iki banda en az benzeyen üçüncü bantın kestirimi için kullanılacak Eşitlik (1.5)'deki gibidir [4].

$$B' = a_0 + a_1 B_1 + a_2 B_2 \quad (1.5)$$

Buradaki B' , B_1 ve B_2 bantını kullanarak B bantının kestirimidir. a_0 , a_1 ve a_2 doğrusal tahmin hatasını minimize edebilecek parametrelerdir.

Parametre vektörü Eşitlik (1.6)'daki gibi ifade edilebilir [4].

$$a = [a_0 a_1 a_2]^T \quad (1.6)$$

Parametre vektörü en küçük kareler yöntemi ile Eşitlik (1.7)'deki gibi ifade edilebilmektedir [4].

$$a = (X^T X)^{-1} X^T y \quad (1.7)$$

Buradaki X, Nx3 boyutunda bir matristir. N, B1 veya B2 bandının tüm piksellerinin sayısını ifade etmektedir. Nx3 boyutundaki matrisin, ilk sütununun tamamı 1'dir. İkinci sütunu B1 bandının tüm piksellerini içerir. Üçüncü sütun ise B2 bandının tüm piksellerini içerir. y ise üçüncü bant olan B bandının tüm piksellerini içeren Nx1 boyutlu vektördür.

Doğrusal tahmin hatası, Eşitlik (1.8)'deki gibi ifade edilebilir [4].

$$e = \|B - B'\| \quad (1.8)$$

İlk iki bant ile diğer tüm bantlar kullanılarak elde edilen DTH değerlerinden en büyüğünün elde edildiği üçüncü bant, bu iki banda en az benzeyen banttır. Birbirine en az benzeyen üç banda en az benzeyen dördüncü bant ise benzer şekilde elde edilir. Tüm bu işlemler boyut azaltımı ile istenilen bant sayısına kadar tekrarlanır.

1.4.2. Temel bileşenler analizi (TBA)

Temel bileşenler analizi doğrusal ve denetimsiz istatistiksel bir boyut azaltımı yöntemidir. TBA verideki benzerlik ve farklılıkların daha iyi ifade edilmesini sağlamaktadır. TBA'nin en büyük avantajlarından biri orijinal verilerin az kayıplı sıkıştırılarak boyut azaltımı gerçekleştirmesidir.

TBA ile elde edilen m adet temel bileşen, d boyutlu orijinal verinin boyutundan daha küçük olacak şekilde elde edilir ($d > m$).

TBA, hiperspektral görüntülere uygulanırken, 3 boyutlu verinin (w,h,d) satır ve sütun elemanları tek bir boyutta ifade edilerek 2 boyutlu (w×h,d) olacak şekilde ifade edilebilmektedir. TBA yönteminde ilk olarak verinin değerlerinden, beklenen değerler çıkartılmaktadır.

Beklenen deęer, Eşitlik (1.9)'daki gibi hesaplanabilir;

$$\mu = E\{X\} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1.9)$$


Buradaki n, hiperspektral görüntünün toplam piksel sayısını vermektedir. Sonrasında, kovaryans matrisi Eşitlik (1.10)'daki gibi elde edilir. Kovaryans matrisi dxd boyutunda bir kare matristir;

$$\Sigma_x = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu) (x_i - \mu)^T \quad (1.10)$$

Kare matris olan kovaryans matrisinden d adet öz deęer ve öz vektör elde edilir. Boyut azaltımı için indirgenmesi istenilen m adet temel bileşen (TB) için dxm boyutundaki öz vektörden oluşan A iz düşüm matrisi kullanılarak elde edilen Nxm boyutlu Z matrisi Eşitlik (1.11)'deki gibi ifade edilebilir [3];

$$Z = A^T(Y - \mu) \quad (1.11)$$

Buradaki Y, orijinal verinin 3 boyuttan 2 boyuta dönüşümünden sonra elde edilen Nxd boyutlu matristir. Salinas veri kümesinden alınan 20. bant görüntüsü ve TBA kullanılarak elde edilen ilk üç temel bileşen görüntüsü Şekil 1.8'deki gibidir. Hiperspektral görüntülerde orijinal veriyi genel olarak ilk 3 veya 4 temel bileşen görüntüsü en iyi şekilde temsil etmektedir.



Şekil 1.8. a) Salinas 20. bant görüntüsü, b) 1.TB görüntüsü, c) 2.TB görüntüsü, d) 3.TB görüntüsü

1.5. Sınıflandırma

Hiperspektral görüntülerin sınıflandırılmasında, hem sınıflandırma başarımını iyileştirmek hem de hesapsal maliyeti azaltmak için boyut azaltımına gidilir. Sınıflandırma yapılan önce yapılan bir diğer işlem, uzamsal öznitelik çıkartımıdır. Uzamsal öznitelik çıkartımı sınıflandırma başarımını iyileştirir. Öznitelik çıkartımı yerelde ve globalde gerçekleştirilebilir. Literatürde sınıflandırma için yerel, global özniteliklerin veya ikisinin kombinasyonu kullanılarak gerçekleştirilen sınıflandırma çalışmaları mevcuttur. Uzamsal öznitelik çıkartılarak elde edilen sınıflandırma başarımı, ham veriyi kullanarak elde edilen sınıflandırma başarımına göre çok daha yüksektir. Hiperspektral görüntü sınıflandırmada temel işlem adımları aşağıdaki gibidir;

- Yüksek boyutlu hiperspektral görüntü üzerinde boyut azaltımı gerçekleştirilir.
- Elde edilen düşük boyutlu veri üzerinde öznitelik çıkartımı yöntemleri uygulanır.
- Çıkarılan öznitelik kullanılarak öznitelik vektörü oluşturulur.
- Öznitelik vektörü belirlenen eğitim oranı doğrultusunda sınıflandırıcı eğitilir.
- Test verisi, eğitilen sınıflandırıcıya giriş olarak verilerek sınıflandırıcıdan çıkış olarak elde edilen sınıf atamalarına bağlı olarak sınıflandırma başarımı elde edilir.

Bu tez çalışması kapsamında uzamsal öznitelik çıkartımı için yerel öznitelik temelli öznitelik profilleri yöntemi kullanılmıştır. Yerel öznitelik temelli özellik profilleri, özellik profilleri yöntemini temel olarak özellik profillerinden yerel özniteliklerin elde edilmesi ile elde edilir. Literatürdeki bazı çalışmalar için Salinas, Indian Pines ve Pavia Üniversitesi veri kümeleri kullanılarak elde edilen sınıflandırma sonuçları sırasıyla Tablo 1.5, Tablo 1.6 ve Tablo 1.7'deki gibidir. Spektral yöntemde bant görüntülerinin doğrudan piksel değerleri üzerinden SVM sınıflandırma yapılarak sonuçlar elde edilmiştir. Spektral yöntemi ile sınıflandırma başarımları oldukça düşüktür. LBP-SVM yönteminde yerel ikili görüntüler çıkartılarak elde edilen öznitelik vektörü üzerinden sınıflandırma işlemi gerçekleştirilir. LBP-SVM yöntemi kullanılarak elde edilen sınıflandırma başarımı Spektral'e göre daha yüksektir fakat öznitelik vektör boyutu çok yüksektir.

DF-ELM yöntemi ile, orijinal spektral imza, yerel ikili örüntüler ve gabor öznelikleri çıkartılarak, ayrı ayrı sınıflandırma işlemi gerçekleştirilir. DF-ELM yönteminde, nihai sınıf haritası 3 farklı sınıflandırıcıdan elde edilen sonuçlara göre elde edilir. DF-ELM yönteminde sınıflandırma başarımı yüksek olmasına rağmen 3 farklı sınıflandırma işlemi gerçekleştirilmiştir. Aynı zamanda öznelik vektör boyutu oldukça yüksektir.

LFAP (Local Feature-Based Attribute Profiles–Yerel öznelik temelli özellik profilleri) yönteminde özellik profillerinden yerel özneliklerin çıkartılması sonucunda elde edilen düşük boyutlu öznelik vektörü kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bu yöntemde düşük öznelik vektörüne rağmen yüksek sınıflandırma başarımı elde edilmiştir.

ULBP (Uniform Local Binary Pattern–Tek Düzey Yerel İkili Örüntüler) yönteminde tek düzey yerel ikili öznelikler çıkartılarak elde edilen öznelik vektörü kullanılarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma başarımı yüksek olmasına rağmen öznelik vektör boyutu çok yüksektir.

ULBP-SPG (Uniform Local Binary Pattern–Süperpiksel Guidance–Tek Düzey Yerel İkili Örüntüler–Süperpiksel Klavuzluk) yöntemi ile yüksek boyutlu öznelik vektörü kullanılarak elde edilen sınıf haritası, süperpiksel haritası ile düzeltilerek nihai sınıf haritası elde edilir. ULBP-SPG yöntemi ile aynı eğitim oranları için diğer yöntemlere göre daha yüksek sınıflandırma başarımı elde edilmiştir. ULBP-SPG yönteminin öznelik vektör boyutu, ULBP yöntemi ile aynıdır. Fakat diğer yöntemlere göre öznelik vektör boyutu çok yüksektir.

Tablo 1.5. Salinas veri seti için literatür sınıflandırma sonuçları

Yöntem	Vektör Boyutu	Eğitim Oranı	Sınıflandırma Başarımı
Spektral[10]	204	30 piksel/Sınıf	%89.48
LBP-SVM[10]	472	30 piksel/Sınıf	%97.53
DF-ELM[10]	472+204+64	30 piksel/Sınıf	%99.63
DF-ELM[10]	472+204+64	10 piksel/Sınıf	%94.00
LFAP[8]	72	10 piksel/Sınıf	%87.29
ULBP[11]	2040	10 piksel/Sınıf	%87.23
ULBP+SPG[11]	2040	10 piksel/Sınıf	%99.28

Tablo 1.6. Indian Pines veri seti için literatür sınıflandırma sonuçları

Yöntem	Vektör Boyutu	Eğitim Oranı	Sınıflandırma Başarımı
Spektral[10]	202	%3 (23 piksel/Sınıf)	%75.14
LBP-SVM[10]	413	%3 (23 piksel/Sınıf)	%90.63
DF-SVM[10]	413+202+56	%3 (23 piksel/Sınıf)	%92.21
DF-ELM[10]	413+202+56	%3 (23 piksel/Sınıf)	%93.58
LFAP[8]	72	10 piksel/Sınıf	%68.78
ULBP[11]	2040	10 piksel/Sınıf	%80.37
ULBP+SPG[11]	2040	10 piksel/Sınıf	%87.34

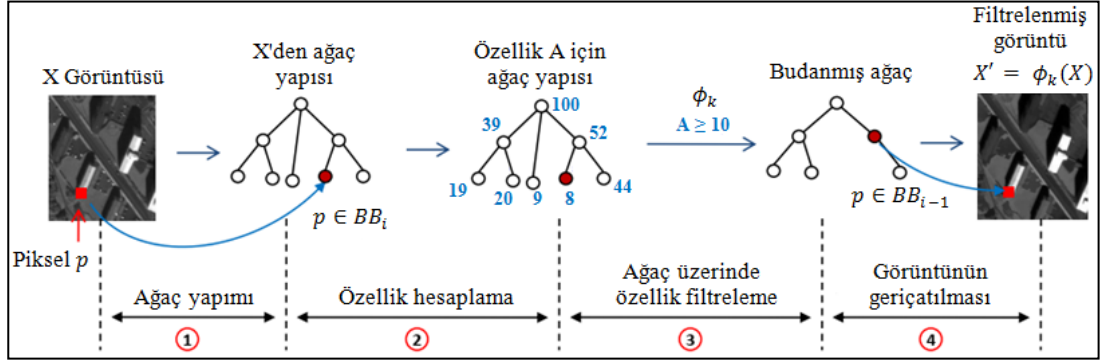
Tablo 1.7. Pavia Üniversitesi veri seti için literatür sınıflandırma sonuçları

Yöntem	Vektör Boyutu	Eğitim Oranı	Sınıflandırma Başarımı
Spektral[10]	103	30 piksel/Sınıf	%80.01
LBP-SVM[10]	413	30 piksel/Sınıf	%89.47
DF-ELM[10]	413+103+80	30 piksel/Sınıf	%99.25
DF-ELM[10]	413+103+80	10 piksel/Sınıf	%80.00
LFAP[8]	72	10 piksel/Sınıf	%84.44
ULBP[11]	1030	10 piksel/Sınıf	%76.89
ULBP+SPG[11]	1030	10 piksel/Sınıf	%90.12

1.5.1. Özellik profilleri

Morfolojik özellik profilleri, yakın geçmişte önerilen morfolojik profillerin genelleştirilmesi olarak tanımlanmaktadır. Özellik profilleri, yapısal bilgilerin farklı türlerini modellemek için kullanılabilir morfolojik özellik filtrelerinin sıralı uygulaması ile oluşturulan görüntünün çok seviyeli karakterizasyonunu sağlar [5]. Doğrudan piksel seviyesinde gerçekleştirilen normal görüntü filtreleme operetörünün aksine, morfolojik özellik filtreleri görüntü bağlantı kavramı temelli bağlı bileşen seviyesinde çalışır. Morfolojik özellik filtresi, görüntüdeki nesnelerin ve bölgelerin

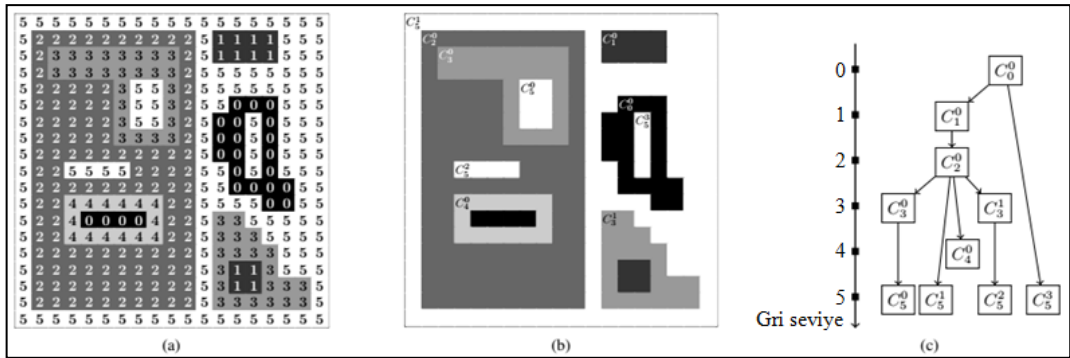
boyutunu, şeklini veya diğer özelliklerini karakterize eden belirli bir özellik ile ilgili olarak bağlı bileşenlere(BB) uygulanan bir filtreleme operatörüdür [6]. Morfolojik özellik profilleri, 4 adımda Şekil 1.9'daki gibi elde edilir.



Şekil 1.9. Morfolojik özellik profillerinin elde edilme adımları [6]

İlk olarak X görüntüsünden ağaç yapısı elde edilir. Görüntüyü kodlamak için, [7]'de bir minimum ağaç ve bir maksimum ağaç önerilmektedir. Örnek maximum-ağaç oluşturulma adımları Şekil 1.10'daki gibidir. Ağacın her bir düğümüne yani bağlı bileşene karşı gelen geometrik ve istatistiksel özellikleri tanımlayan nitelikler hesaplanır.

Uzaktan algılama görüntü sınıflandırmada genellikle alan, standart sapma, eylemsizlik momenti veya sınırlayıcı kutunun köşegen uzunluğu olmak üzere 4 farklı özellik kullanılmaktadır. Önceden tanımlanmış eşik değerleri ile bağlı bileşenler için elde edilen özellik değerleri karşılaştırılarak, bağlı bileşenler kaldırılır veya korunur. Filtrelenmiş ağaçtan görüntü çatılarak filtrelenmiş görüntü elde edilir.

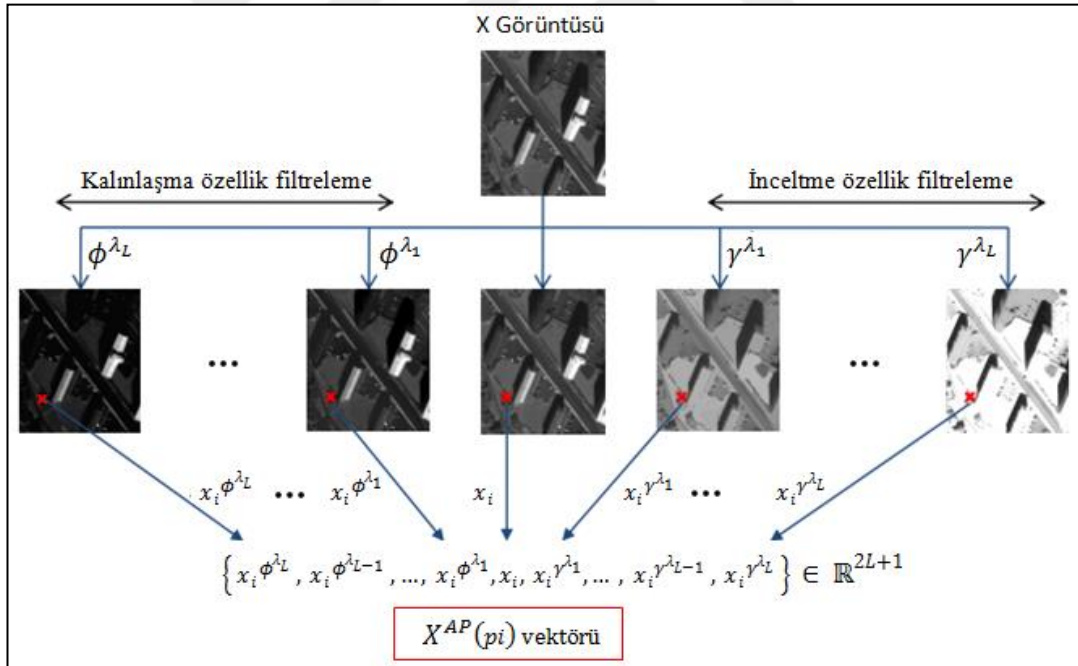


Şekil 1.10. Maksimum-ağaç oluşturulma adımları, a) Her piksel için gri değer gösterildiği görüntü, b) Bağlı bölgeleri temsil eden izo-seviyeli bölgeler, c) C bileşeninde görüntüyü tanımlayan maksimum ağaç yapısı [7]

X görüntüsü üzerinden özellik profilleri, bir dizi minimum ağaç (özellik kalınlaştırma operatörü $\{\phi^{\lambda_i}\}_{i=1}^L$) ve maksimum ağaç (özellik inceltme operatörü $\{\gamma^{\lambda_i}\}_{i=1}^L$) temelli morfolojik özellik filtreleri uygulanarak elde edilir. X görüntüsü üzerinden elde edilen özellik profilleri Eşitlik (2.12)'deki gibi ifade edilebilir.

$$AP(X) = \{ X^{\phi^{\lambda_L}}, X^{\phi^{\lambda_{L-1}}}, \dots, X^{\phi^{\lambda_1}}, X, X^{\gamma^{\lambda_1}}, \dots, X^{\gamma^{\lambda_{L-1}}}, X^{\gamma^{\lambda_L}} \} \quad (1.12)$$

Buradaki $X^{\phi^{\lambda_1}}$ ve $X^{\gamma^{\lambda_1}}$ eşik λ_1 ile ilgili sırasıyla kalınlaşma özelliğini (ϕ^λ) ve inceltme özelliğini (γ^λ) uygulayarak elde edilen filtrelenmiş görüntülerdir. Elde edilen $AP(X)$, X görüntüsünün, L adet inceltme profilini, L adet kalınlaşma profilini ve X orijinal görüntü olmak üzere $(2L+1)$ adet görüntü içeren özellik profilini ifade etmektedir. Şekil 1.11'de örnek bir görüntü için özellik profilleri ve bir piksel için özellik profillerinden elde edilen öznitelik vektör gösterimi verilmiştir.



Şekil 1.11. Örnek bir görüntünün özellik profilleri ve bir piksele ait öznitelik vektörü gösterimi [8]

1.5.2. Yerel ikili örüntüler

YİÖ operatörü, dokusal tanımlama için oldukça güçlü bir araçtır. YİÖ operatörü kullanılarak görüntüdeki merkez pikselle birlikte piksellerin komşularının

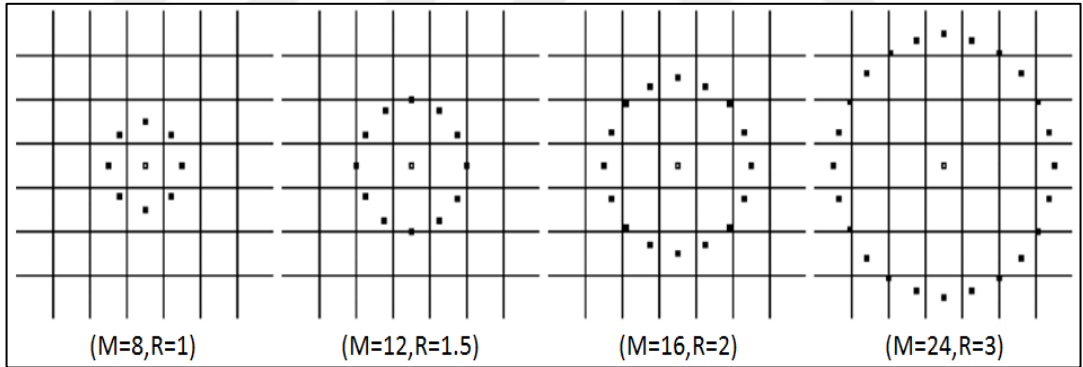
eşiklenmesi ile tüm pikseller kodlanır. YİÖ kodu dairesel komşuluk kullanılarak Eşitlik (1.13)'deki gibi ifade edilebilmektedir;

$$YİÖ_{M,R}(x,y) = \sum_{m=0}^{M-1} s(p_m - p_c)^2 \quad (1.13)$$


Buradaki (x,y) merkez pikselin konumunu, M YİÖ kodunun hesaplanmasında kullanılacak komşu piksel sayısını, p_c merkez pikselin değeri, p_m dairesel komşuluktaki m . pikselin değerini, R ise merkez pikselin komşu piksellere olan uzaklığını göstermektedir. M ve R değerlerine bağlı komşu piksel değişimi Şekil 1.12'deki gibidir. s fonksiyonu Eşitlik (1.14)'deki gibi tanımlanmaktadır.

$$s(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (1.14)$$

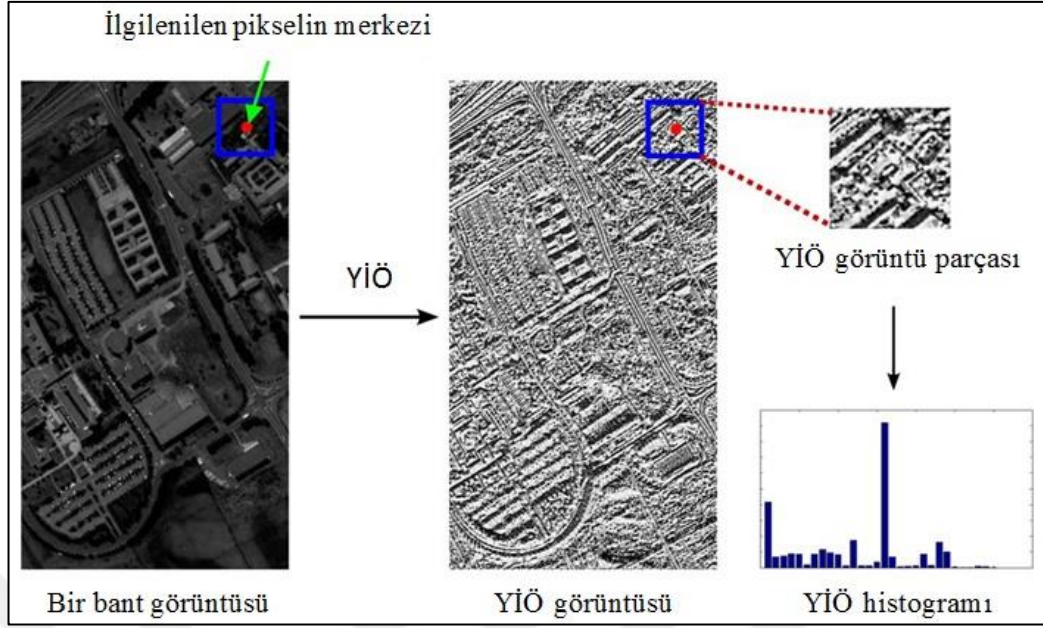
YİÖ kodu her bir piksel için ayrı ayrı hesaplanır. Örnek M ve R değerleri için bir pikselin YİÖ kodunun hesaplanması Şekil 1.13'deki gibidir. YİÖ görüntüsü ve YİÖ görüntüsünden öznitelik vektörünün elde edilmesi Şekil 1.14'deki gibidir.



Şekil 1.12. M ve R değerlerine bağlı komşu piksellerin görünümü [9]



Şekil 1.13. $M=8$ ve $R=3$ için YİÖ kodu hesaplaması



Şekil 1.14. YİÖ görüntüsü ve YİÖ görüntüsünden öznitelik çıkartılması [10]

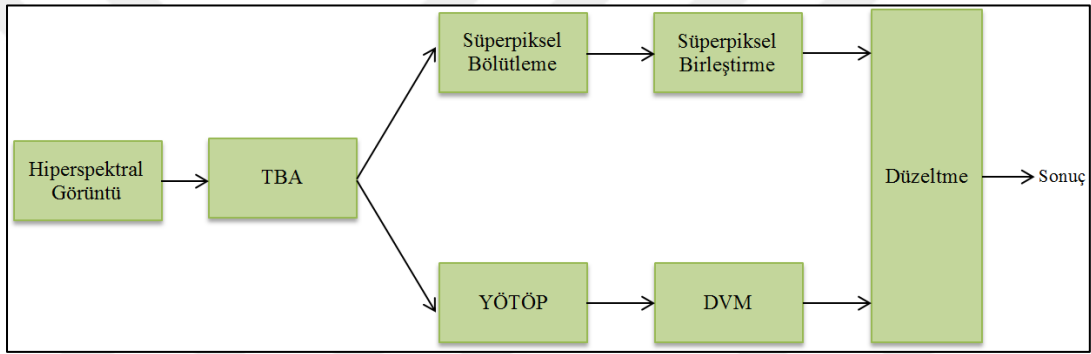
Öznitelik vektörü her bir piksel için YİÖ görüntüsünden ilgili pikselin belirli büyüklükteki penceresinin içerisinde bulunan piksellerin histogramından elde edilir. Pencere içerisindeki piksellerin değeri 0-255 arasında olduğundan 1 görüntüdeki her bir piksel için 256 boyutlu öznitelik vektörü elde edilmiş olunur. Bunu engellemek için histogram bini kullanılır.

Literatürde, YİÖ'nün kararsız yapısından dolayı tek düze YİÖ yöntemi de kullanılmaktadır. Tek düze YİÖ kullanılarak, YİÖ kodundaki ikili sayıların ardışık olarak değişimi kontrol edilir ve değişim sayısı 2'den fazla olması durumunda YİÖ piksel değeri $P+1$ olarak atanır. Örnek olarak, YİÖ kodu "01010101" olan bir pikselin değeri 85 olarak elde edilirken tek düze YİÖ yönteminde piksel değeri 9 olarak elde edilir. Bu şekilde YİÖ'nun kararsız yapısı giderilmiş olunur.

2. ÖNERİLEN SINIFLANDIRMA YÖNTEMİ

2.1. Giriş

Tez çalışmasının bu bölümünde hiperspektral görüntüden çıkartılan yerel öznitelikler kullanılarak gerçekleştirilen sınıflandırma sonucunda elde edilen sınıflandırma haritasının süperpiksel bölütleme ile elde edilen süperpiksel haritası ile düzeltilmesi üzerinde durulmuştur. Önerilen yönteme ait blok şeması Şekil 2.1'deki gibidir.



Şekil 2.1. Önerilen yönteme ait blok şema

Hiperspektral görüntülerin sınıflandırılmasında yüksek spektral çözünürlük hem hesapsal maliyet hem de başarıyı düşüren bir etkidir. Bu sebeple önerilen yöntemde ilk olarak hiperspektral görüntü üzerine temel bileşenler analizi (TBA) yöntemi uygulanmıştır. Böylece boyut azaltımı gerçekleştirilmiş olunur.

TBA ile elde edilen düşük boyutlu veri 2 farklı aşamada kullanılır. İlk olarak TBA ile elde edilen temel bileşenlerden ilk 4 temel bileşen görüntüsü üzerinden uzamsal öznitelik çıkartımı gerçekleştirilir. Uzamsal öznitelik çıkartımı için yerel öznitelik temelli özellik profilleri(LFAP) yöntemi kullanılmıştır. LFAP ile elde edilen öznitelik vektörü, görüntüdeki yerel öznitelikleri iyi bir şekilde tanımlayabilmesinin yanında düşük boyutluluğa sahiptir.

Öznitelik vektörünün düşük boyutlu olması sınıflandırmanın hesapsal yükünü azaltmaktadır. Sonrasında belirlenen eğitim oranı kadar pikselin öznitelik vektörü destek makinelerine(DVM) giriş olarak verilerek sınıflandırıcı eğitilir. Eğitilen

sınıflandırıcıya görüntüdeki tüm piksellerin öznitelik vektörü sisteme giriş olarak verilerek elde edilen piksel sınıf değerleri doğrultusunda sınıflandırma haritası elde edilir.

Elde edilen sınıflandırma haritası hatalı sınıf atamaları içermektedir. Hatalı sınıf atamalarını düzeltmek veya iyileştirmek için eğitim oranını veya öznitelik vektör boyutunu arttırmak sınıflandırma performansını belirli oranda iyileştirebilir fakat bu durumda hesapsal maliyet artmaktadır. Aynı öznitelik vektör boyutunda ve eğitim oranında kalınarak sınıflandırma haritasındaki hatalı sınıf atamalarını iyileştirmek için süperpiksel bölütleme yöntemi kullanılmıştır. Süperpiksel bölütleme işlemi, TBA ile elde edilen temel bileşenlerden ilk 3 temel bileşen kullanılarak oluşturulan sahte renklendirilmiş görüntü üzerinde uygulanır. Süperpiksel bölütleme için entropi oranı süperpiksel (EOS) yöntemi kullanılmıştır. Süperpiksel bölütleme işlemi sonrasında görüntüdeki aynı sınıfa ait bölgelerde birden fazla süperpiksel olabilmektedir. Bu durum düşük eğitim oranı kullanılarak elde edilen sınıflandırma haritasını, süperpiksel haritası ile düzeltme işleminde verimi düşürebilmektedir. Bu nedenle aynı sınıfa ait bölgelerdeki süperpiksellerin birleştirilmesi işlemi gerçekleştirilmiştir. Böylece süperpiksel haritası elde edilmiş olunur. Sınıflandırma haritası, süperpiksel birleştirme sonrasında oluşturulan süperpiksel haritası ile düzeltilmiştir.

2.2. Yerel Öznitelik Temelli Özellik Profilleri

Yerel öznitelik çıkartımı, doku analizi için yıllardır ana yaklaşımlardan biridir [13,16].Yerel parçadan çıkartılan ortalama, aralık, standart sapma gibi birinci dereceden öznitelikler, ilgili dokunun modellenmesinde yeterli olabilmektedir. Yerel öznitelik temelli özellik profilleri (LFAP) ile çoğunlukla homojen bölgelerden oluşan özellik profilleri görüntüleri kullanılarak yerel parçalardan elde edilen ortalama ve aralık öznitelikleri doku bilgisini etkili bir biçimde modellenenmektedir [8].

LFAP(YÖTÖP) öznitelik vektörünün elde edilmesi için ilk olarak hiperspektral görüntü üzerinde TBA yöntemi kullanılarak boyut azaltımı gerçekleştirilir. İlk 4 temel bileşen görüntüsünün her birinden özellik profilleri görüntüleri elde edilir.

Yerel öznitelik temelli özellik profilleri, her bir temel bileşen görüntüsünden elde edilen özellik profilleri görüntüleri kullanılarak, p_i pikseli için Eşitlik (2.1)'deki gibi ifade edilebilmektedir [8].

$$X^{YÖTÖP}(p_i) = \{X_{\mu}^{YÖTÖP}(p_i), X_r^{YÖTÖP}(p_i)\} \quad (2.1)$$

p_i pikselinin $X_{\mu}^{YÖTÖP}(p_i)$ vektörü, L adet eşik seviyesi için elde edilen filtrelenmiş özellik profilleri görüntüleri ve orijinal görüntünün her birinden ilgili p_i pikselinin belirli bir pencere alanı içerisindeki piksellerin ortalamalarından oluşmaktadır.

$X_{\mu}^{YÖTÖP}(p_i)$, Eşitlik (2.2)'deki gibi elde edilebilir. $X_r^{YÖTÖP}(p_i)$ vektörünün elde edilme adımları Şekil 2.2'deki gibidir.

$$X_{\mu}^{YÖTÖP}(p_i) = \left\{ \mu_i^{\phi^{\lambda L}}, \mu_i^{\phi^{\lambda L-1}}, \dots, \mu_i^{\phi^{\lambda 1}}, \mu_i, \mu_i^{\gamma^{\lambda 1}}, \dots, \mu_i^{\gamma^{\lambda L-1}}, \mu_i^{\gamma^{\lambda L}} \right\} \quad (2.2)$$

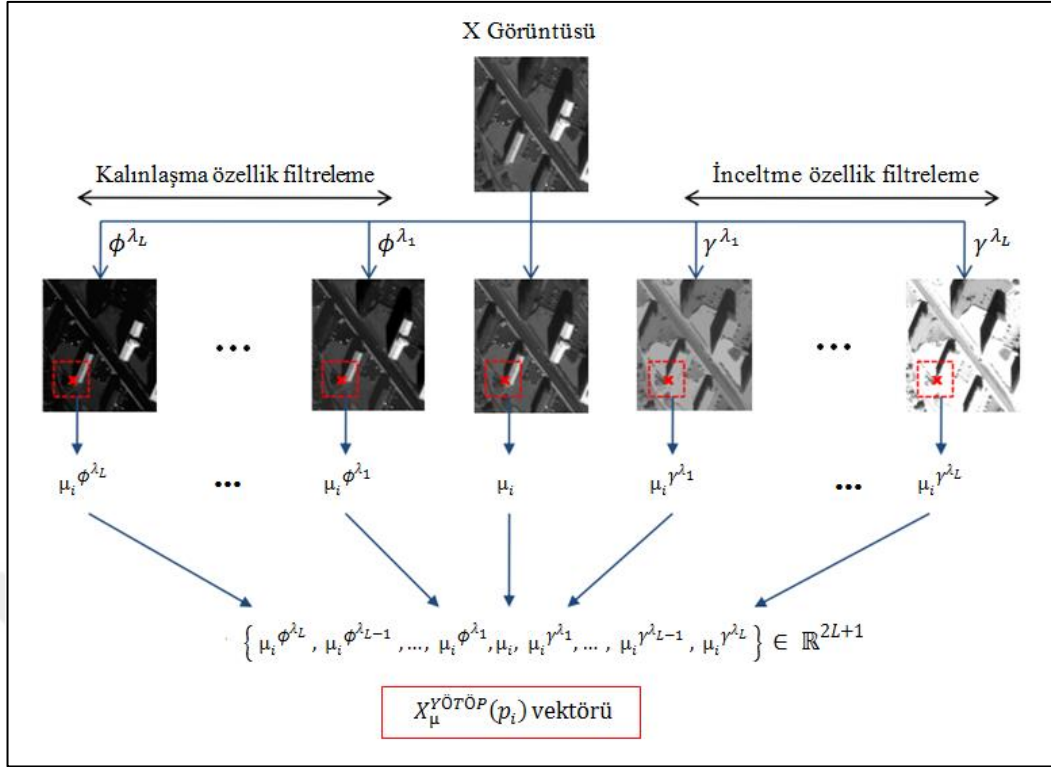
p_i pikselinin $X_r^{YÖTÖP}(p_i)$ vektörü, L adet eşik seviyesi için elde edilen filtrelenmiş özellik profilleri görüntüleri ve orijinal görüntünün her birinden ilgili p_i pikselinin belirli bir pencere alanı içerisindeki piksellerin en büyük piksel değerine sahip piksel değeri ile en küçük piksel değerine sahip piksel değeri arasındaki farklardan oluşmaktadır.

$X_r^{YÖTÖP}(p_i)$, Eşitlik (2.3)'deki gibi elde edilebilir. $X_r^{YÖTÖP}(p_i)$ vektörünün elde edilme adımları Şekil 2.3'deki gibidir.

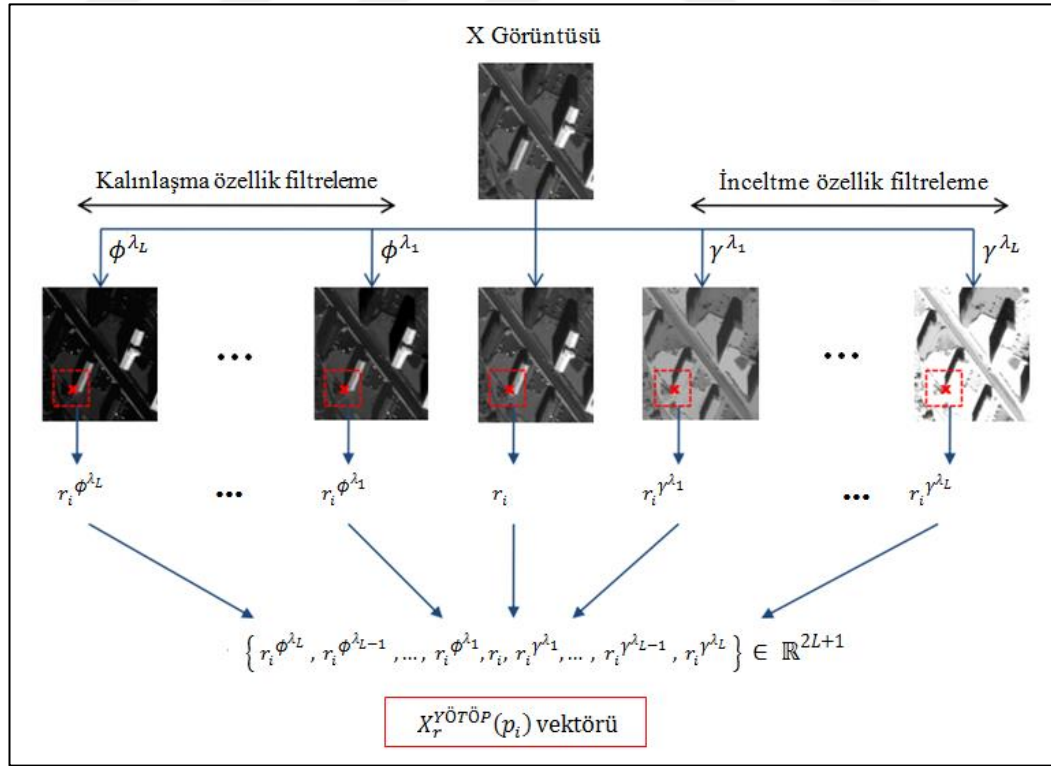
$$X_r^{YÖTÖP}(p_i) = \left\{ r_i^{\phi^{\lambda L}}, r_i^{\phi^{\lambda L-1}}, \dots, r_i^{\phi^{\lambda 1}}, r_i, r_i^{\gamma^{\lambda 1}}, \dots, r_i^{\gamma^{\lambda L-1}}, r_i^{\gamma^{\lambda L}} \right\} \quad (2.3)$$

Her bir p_i pikseli için, $(2L+1)$ boyutlu $X_{\mu}^{YÖTÖP}(p_i)$ ve $(2L+1)$ boyutlu $X_r^{YÖTÖP}(p_i)$ vektörleri ilk 4 temel bileşen görüntüsü kullanılarak ayrı ayrı çıkartıldığında $4 \times 2 \times (2L+1)$ boyutlu LFAP öznitelik vektörü elde edilir.

Belirlenen eğitim oranı kadar pikselin çıkartılan LFAP öznitelik vektörleri kullanılarak, DVM sınıflandırıcı eğitilir. Sonrasında test için kullanılacak piksellerin çıkartılan öznitelik vektörleri kullanılarak eğitilen sınıflandırıcı yardımıyla sınıflandırma haritası elde edilir.



Şekil 2.2. LFAP (YÖTÖP) ortalama vektörünün çıkartılması adımları [8]



Şekil 2.3. LFAP (YÖTÖP) aralık vektörünün çıkartılması adımları

2.3. Süperpiksel Bölütleme

Süperpiksel bölütleme nesne tanıma [17], görüntü bölütleme gibi birçok uygulama için önemli bir yöntemdir. Süperpiksel kullanmanın en büyük avantajlarından biri hesapsal verimliliktir [18].

Yerel öznitelik temelli özellik profilleri yöntemi ile elde edilen sınıflandırma haritasında hatalı sınıf atamaları mevcuttur. Özellikle çok düşük eğitim oranları kullanıldığında sınıflandırma başarımı oldukça düşük olmaktadır. Bu tez çalışması kapsamında, sınıflandırma haritasındaki hatalı sınıf atamalarını mümkün olduğunca düzelterek sınıflandırma başarımını arttırmak için süperpiksel bölütleme yöntemi kullanılmıştır.

İyi sınır uyumu ile düzensiz süperpikseller üretildiği için, entropi oranı süperpiksel (EOS) yöntemi tercih edilmiştir. Çekirdek genişliği σ , dengeleme parametresi λ ve elde edilmesi beklenen süperpiksel sayısı olmak üzere 3 farklı parametre kullanılarak birbiri ile örtüşmeyen birçok bölgeye sahip süperpiksel haritası elde edilir. Süperpikseller, hiperspektral görüntüye TBA uygulandıktan sonra ilk üç temel bileşenden elde edilen sahte renklendirilmiş görüntü üzerinden elde edilir. Aynı sınıfa ait bölgelerde birden fazla süperpiksel olabilmektedir. Bu sorunu mümkün olduğunca düzeltmek için süperpiksel birleştirme algoritması önerilmiştir [11]. Düşük sınıflandırma başarımına sahip sınıflandırma haritası, süperpiksel birleştirme işlemi yapılmadan doğrudan süperpiksel bölütleme ile elde edilen süperpiksel haritası ile düzeltilmeye çalışıldığında süperpiksel haritasının sınıflandırma başarımı üzerinde çok fazla etkisi olmayabilmektedir. Bunun yanısıra sınıflandırma başarımına olumsuz yönde de etki edebilmektedir. Bu tez çalışması kapsamında süperpikselleri mümkün olduğunca daha büyük homojen süperpiksellere dönüştürmek için süperpiksel birleştirme algoritması uygulanmıştır [11]. Salinas sahte renklendirilmiş görüntü kullanılarak elde edilen süperpiksel bölütleme ve süperpiksel birleştirme görüntüleri Şekil 2.4'deki gibidir.

Süperpiksel birleştirme için, m ve n iki komşu süperpiksel olmak üzere Eşitlik (2.4)'deki gibi G -istatistik değeri sahte renklendirilmiş görüntünün yerel ikili örüntü görüntüsü üzerinden hesaplanır.

$$G_{m,n} = \sum_{m,n} \sum_{i=0}^{t-1} f_i \log f_i + (\sum_{m,n} \sum_{i=0}^{t-1} f_i) \log(\sum_{m,n} \sum_{i=0}^{t-1} f_i) - \sum_{i=0}^{t-1} (\sum_{m,n} f_i) \log(\sum_{m,n} f_i) \quad (2.4)$$

Buradaki t , histogram aralığı sayısını ve f_i süperpiksel histogramını göstermektedir. m ve n süperpikselleri arası mesafe hesabı Eşitlik (2.5)'deki gibi ifade edilebilmektedir.

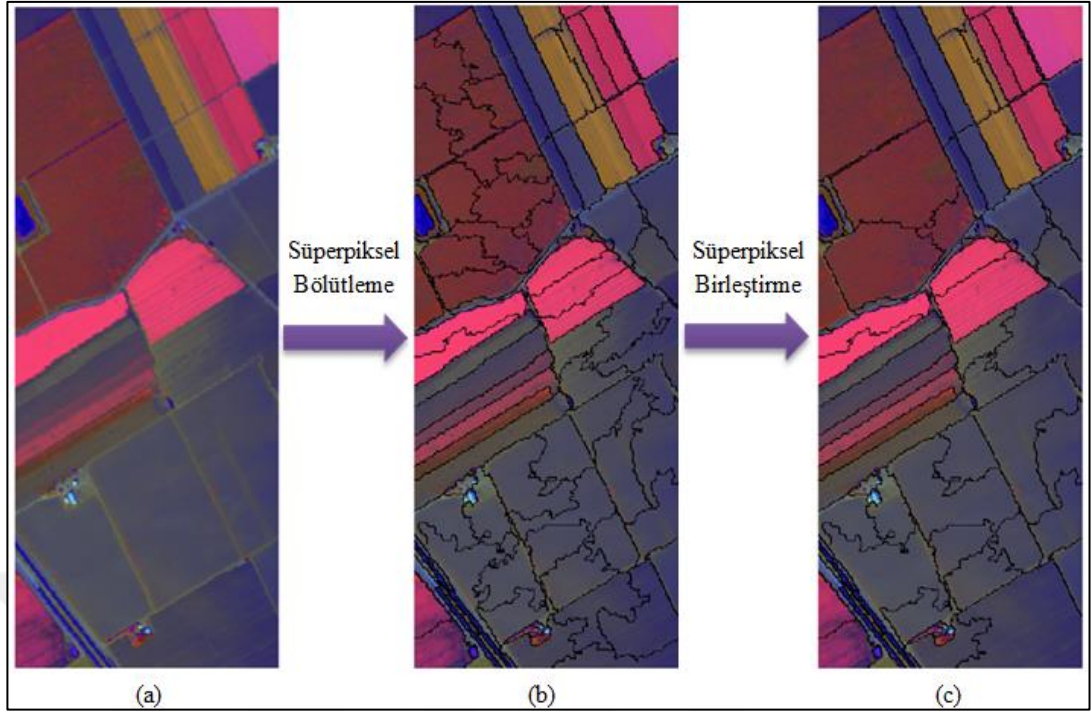
$$D_{m,n} = \frac{1}{\|L_{m,n}\|^\gamma} G_T \quad (2.5)$$

Buradaki $\|L_{m,n}\|$ iki komşu süperpiksel arasındaki sınır komşu piksel sayısını ifade etmektedir. γ ise iki süperpikselin sınır komşu piksel'inin etkisinin azaltıp artırılabilceği sabit bir sayıdır.

Eşitlik (2.6) kullanılarak iki süperpikselin birbirine benzerlik katsayısı elde edilir. Buradaki S_m , m süperpiksel bölgesi içindeki piksel sayısını, S_n ise n süperpiksel bölgesi içindeki piksel sayısını ifade etmektedir.

$$C_{m,n} = \frac{|S_m| \cdot |S_n|}{|S_m| + |S_n|} D_{m,n} \quad (2.6)$$

Süperpiksel'in tüm komşu süperpikselleri için $C_{m,n}$ değerleri elde edilerek en küçük $C_{m,n}$ değeri belirlenen eşik değerinden küçük ise iki komşu süperpiksel birleştirilir. Yapılan işlemler tüm süperpikseller üzerinde uygulanarak birleştirme işlemi tamamlanır. Birleştirme işlemi istenilen süperpiksel sayısı boyunca tekrarlanır. Böylece nihai süperpiksel haritası elde edilir. Yerel öznitelik temelli özellik profilleri kullanılarak elde edilen sınıflandırma haritası, nihai süperpiksel haritası ile düzeltilerek, düşük boyutlu LFAP öznitelik vektör boyutu değiştirilmeden sınıflandırma başarımlarını artırılmaktadır.



Şekil 2.4. Süperpiksel haritası elde etme adımları, a) Salinas sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme (100 adet süperpiksel) sonrasında süperpiksel haritası, c) Süperpiksel birleştirme sonrasında nihai süperpiksel haritası

2.4. Deneysel Sonuçlar

Deneysel sonuçlar, Indian Pines, Salinas, Pavia Üniversitesi ve Pavia merkezi hiperspektral veri kümeleri kullanılarak elde edilmiştir. Salinas hiperspektral veri kümesindeki su soğurmalı bantlar çıkartılarak 204 adet spektral bant kullanılmıştır. Salinas veri kümesinde her bir spektral bant görüntüsü 512x217 uzamsal çözünürlüğe sahiptir. Benzer şekilde Indian Pines hiperspektral veri kümesindeki su soğurmalı bantlar çıkartılarak 200 adet spektral bant kullanılmıştır. Salinas veri kümesinde her bir spektral bant görüntüsü 145x145 uzamsal çözünürlüğe sahiptir. Indian Pines ve Salinas veri kümeleri için sınıflandırmada kullanılan eğitim ve test piksel sayılarının bilgisi sırasıyla Tablo 2.1 ve Tablo 2.2’de verilmiştir. Pavia Üniversitesi için sınıflandırmada kullanılan eğitim ve test piksel sayılarının bilgisi Tablo 2.3’de verilmiştir. Aynı şekilde Pavia merkezi veri kümesi için sınıflandırmada kullanılan eğitim ve test piksel sayılarının bilgisi Tablo 2.4’de verilmiştir.

Tablo 2.1. Indian Pines veri kümesi eğitim ve test sayıları

#	Sınıf	Eğitim	Test
1	Alfalfa	10	46
2	Corn-notill	10	1428
3	Corn-mintill	10	830
4	Corn	10	237
5	Grass-pasture	10	483
6	Grass-trees	10	730
7	Grass-pasture-mowed	10	28
8	Hay-windrowed	10	478
9	Oats	10	20
10	Soybean-notill	10	972
11	Soybean-mintill	10	2455
12	Soybean-clean	10	593
13	Wheat	10	205
14	Woods	10	1265
15	Buildings-Grass-Trees-Drives	10	386
16	Stone-Steel-Towers	10	93
	Toplam	160	10242

Tablo 2.2. Salinas veri kümesi eğitim ve test sayıları

#	Sınıf	Eğitim	Test
1	Brocoli_green_weeds_1	10	2009
2	Brocoli_green_weeds_2	10	3726
3	Fallow	10	1976
4	Fallow_rough_plow	10	1394
5	Fallow_smooth	10	2678
6	Stubble	10	3959
7	Celery	10	3579
8	Grapes_untrained	10	11271
9	Soil_vinyard_develop	10	6203
10	Corn_senesced_green_weeds	10	3278
11	Lettuce_romaine_4wk	10	1068
12	Lettuce_romaine_5wk	10	1927
13	Lettuce_romaine_6wk	10	916
14	Lettuce_romaine_7wk	10	1070
15	Vinyard_untrained	10	7268
16	Vinyard_vertical_trellis	10	1807
	Toplam	160	54129

Tablo 2.3. Pavia Üniversitesi veri kümesi eğitim ve test sayıları

#	Sınıf	Eğitim	Test
1	Asphalt	10	6631
2	Meadows	10	18649
3	Gravel	10	2099
4	Trees	10	3064
5	Painted metal sheets	10	1345
6	Bare Soil	10	5029
7	Bitumen	10	1330
8	Self-Blocking Bricks	10	3682
9	Shadows	10	947
	Toplam	90	42776

Tablo 2.4. Pavia merkezi veri kümesi eğitim ve test sayıları

#	Sınıf	Eğitim	Test
1	Water	10	65971
2	Trees	10	7598
3	Asphalt	10	9248
4	Self-Blocking Bricks	10	2685
5	Bitumen	10	7287
6	Tiles	10	42826
7	Shadows	10	2863
8	Meadows	10	3090
9	Bare Soil	10	6584
	Toplam	90	148152

Yerel öznitelik temelli özellik profilleri kullanılarak elde edilen sınıflandırma başarısını etkileyen 4 temel parametre vardır. Salinas, Indian Pines, Pavia üniversitesi ve Pavia merkezi veri kümeleri için bu 4 parametre aynı olarak belirlenmiştir. Bu parametrelerden L, özellik profilleri elde edilirken kaç adet eşğin kullanılacağı ile ilgilidir. T parametresi, L adet eşğin her birinin seviyelerini ifade etmektedir. w parametresi, LFAP vektörü için ortalama ve aralık değerleri hesaplanırken merkez piksel için kullanılacak pencere boyutu ile ilgilidir. Son parametre olarak, kaç adet temel bileşen görüntüsü kullanılacağı ile ilgili 'tbs' parametresidir. Bu tez çalışması kapsamında L=4, T ise sırasıyla 100,500,100,5000 olarak belirlenmiştir. L parametresi aynı zamanda öznitelik vektör boyutunu etkilemektedir. Pencere boyutu w=7 olarak belirlenmiştir. Pencere boyutunun biraz artırılması veya biraz azaltılması sınıflandırma performansında küçük değişikliğe neden olmakla birlikte, w parametresinin belirlenmesi süperpiksel haritası ile

sınıflandırma haritası düzeltildiğinde elde edilen sınıflandırma başarımına bakılarak belirlenmelidir. Son olarak tbs parametresi 4 olarak belirlenmiştir. tbs değerinin artırılması veya azaltılması sınıflandırma sonucuna etki etmekle birlikte aynı zamanda öznitelik vektör boyutunu da arttırıp azaltmaktadır. Tüm bu parametreler kullanıldığında Salinas, Indian Pines, Pavia Üniversitesi ve Pavia merkezi veri kümelerinin tamamı için de öznitelik vektör boyutu 72 olarak elde edilir.

Süperpiksel haritasını elde ederken, süperpiksel haritasının başarısını etkileyen temel olarak 3 farklı parametre vardır. Bunlardan birincisi, veri kümesi için elde edilmesi istenilen süperpiksel sayısı S , ikinci olarak dengeleme parametresi λ , son olarak çekirdek genişliği σ 'dır. Salinas veri kümesi için $S=100$, $\lambda=0.4$, $\sigma=5$ olarak belirlenmiştir. Indian Pines veri kümesi için $S=150$, $\lambda=0.4$, $\sigma=12$ olarak belirlenmiştir. Pavia Üniversitesi veri kümesi için $S=200$, $\lambda=0.2$, $\sigma=3$ olarak belirlenmiştir. Pavia merkezi veri kümesi için $S=600$, $\lambda=0.2$, $\sigma=2$ olarak belirlenmiştir.

Farklı süperpiksel sayısına göre süperpiksel birleştirme yapılmadan önce elde edilen sınıflandırma başarımları 4 farklı veri kümesi için Tablo 2.5'deki gibidir. Süperpiksel sayısının az olması durumunda bir süperpikselin içerisinde farklı sınıflar olabileceği için ve süperpiksel sayısının fazla olması durumunda bir sınıf çok fazla süperpiksel içereceği için süperpiksel bölütlemenin sınıflandırma başarımına olumlu katkısı azalmaktadır.

Süperpiksel haritası elde edildikten sonra süperpiksel birleştirme ile elde edilecek nihai süperpiksel haritası için iki süperpikselin sınır komşu piksel'inin etkisinin azaltıp artırılabilmesi katsayı γ , histogramı aralığı sayısı t , süperpiksellerin birleştirilme eşik değeri α olmak üzere 3 farklı parametre kritik öneme sahiptir. Salinas veri kümesi için $\gamma=0.4$, $t=40$, $\alpha=0.2$, Indian Pines veri kümesi için $\gamma=0.3$, $t=40$, $\alpha=0.75$, Pavia Üniversitesi veri kümesi için $\gamma=0.4$, $t=40$, $\alpha=0.2$, Pavia merkezi veri kümesi için $\gamma=0.4$, $t=40$, $\alpha=0.15$ optimum parametreler olarak belirlenmiştir.

Indian Pines veri kümesi için süperpiksel birleştirme öncesindeki ve sonrasındaki sınıflandırma başarımları Tablo 2.6'daki gibidir. Süperpiksel birleştirme işlemi, sınıflandırma başarımını arttırıcı bir unsur olmuştur.

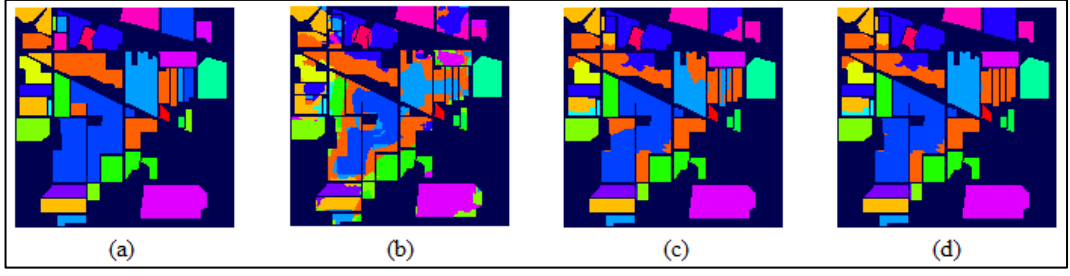
Tablo 2.5. Farklı süperpiksel sayıları için sınıflandırma başarımları

Veri Kümesi	Süperpiksel Sayısı	Sınıflandırma Başarımı(%)
Salinas	80	%91.14
	100	%94.39
	120	%94.38
Indian Pines	120	%79.42
	150	%80.55
	180	%80.31
Pavia Üniversitesi	80	%90.38
	200	%92.95
	250	%92.43
Pavia Merkezi	500	%94.67
	600	%95.13
	700	%94.37

Tablo 2.6. Indian Pines için sınıflandırılması aşamalarındaki sınıflandırma başarımları

İşlem	Sınıflandırma Başarımı
LFAP	%69.22
LFAP+Süperpiksel Bölütleme	%80.55
LFAP+Süperpiksel Bölütleme+Süperpiksel Birleştirme	%84.21

Indian Pines veri kümesi için Tablo 2.9’da elde edilen sonuçların sınıflandırma haritası görüntüleri Şekil 2.5’deki gibidir. Sınıflandırma haritalarına bakıldığında süperpiksel birleştirme işleminin sınıflandırma sonucuna olumlu yönde katkıda bulunduğu görülmektedir.



Şekil 2.5. Indian Pines veri kümesinin sınıflandırma aşamalarındaki sınıflandırma haritaları, a) Gerçek sınıf haritası, b) LFAP sınıflandırma haritası, c) Süperpiksel birleştirme öncesindeki sınıflandırma haritası, d) Süperpiksel birleştirme sonrasındaki sınıflandırma haritası

Önerilen yöntemin(LFAP-SPG) Indian Pines, Salinas, Pavia Üniversitesi ve Pavia merkezi görüntüsüne uygulanması aşamaları ve elde edilen sınıf haritaları ile LFAP yönteminin sınıf haritası karşılaştırma amacı ile sırasıyla Şekil 2.6, Şekil 2.7, Şekil 2.8 ve Şekil 2.9’da verilmektedir. Burada yerel öznitelik temelli özellik profilleri ile elde edilen LFAP sınıflandırma haritası, süperpiksel bilgisi ile birleştirilmiştir. Sonrasında nihai sınıflandırma haritası elde edilmiştir. Nihai sınıflandırma haritasının gerçek sınıf haritasına, LFAP sınıflandırma haritasına göre daha benzer olduğu yani başarının arttırıldığı söylenebilmektedir. Salinas, Indian Pines, Pavia Üniversitesi ve Pavia merkezi veri kümeleri için elde edilen sınıflandırma başarımları sırasıyla Tablo 2.7, Tablo 2.8, Tablo 2.9 ve Tablo 2.10’da verilmektedir.

Salinas veri kümesi için [11]’deki tek düze yerel ikili örüntüler(ULBP) yöntemi ile (2040 boyutlu öznitelik vektörü) %87’lik sınıflandırma başarımları elde edilmiştir. Aynı çalışmada ULBP yöntemine süperpiksel bölütleme eklenince (ULBP-SPG) aynı vektör boyutu ile %99’luk sınıflandırma başarımları elde edilmiştir. [8]’deki LFAP (YÖTÖP-72 boyutlu öznitelik vektörü) ile %87’lik sınıflandırma başarımları elde edilmiştir. Önerilen yöntem(LFAP-SPG) ile aynı eğitim oranı ve vektör boyutunda kalınarak (72 boyutlu öznitelik vektörü), LFAP(YÖTÖP) metodu ile süperpiksel bölütleme kullanılarak %98’lik sınıflandırma başarımları elde edilmiştir. Böylece önerilen LFAP-SPG yöntemi ile aynı eğitim oranı ve daha düşük boyutlu vektör kullanılarak ULBP-SPG yönteminin başarımlarına yakın sonuçlar elde edilmiştir.

Indian Pines veri kümesi için tek düze yerel ikili örüntüler(ULBP) (2000 boyutlu giriş vektörü) ile yaklaşık olarak %80’lik sınıflandırma başarımları elde edilmiştir. Aynı çalışmada (ULBP-SPG) ile %87’lik sınıflandırma başarımları elde edilmiştir.

LFAP(YÖTÖP) kullanılarak 72 boyutlu özellik vektörü ile %69'luk; Önerilen LFAP-SPG ile aynı eğitim oranı ve vektör boyutunda kalınarak %84'lük sınıflandırma başarımı elde edilmiştir. Böylece önerilen LFAP-SPG yöntemi ile aynı eğitim oranı ve daha düşük boyutlu vektör kullanılarak ULBP-SPG yöntemine yakın sınıflandırma başarımı bu veri kümesi için de elde edilmiştir.


Pavia Üniversitesi veri kümesi için tek düze yerel ikili örüntüler(ULBP) (1030 boyutlu giriş vektörü) ile yaklaşık olarak %77'lik sınıflandırma başarımı elde edilmiştir. Aynı çalışmada (ULBP-SPG) ile %90'lık sınıflandırma başarımı elde edilmiştir. LFAP(YÖTÖP) kullanılarak 72 boyutlu özellik vektörü ile %84'lük; Önerilen LFAP-SPG ile aynı eğitim oranı ve vektör boyutunda kalınarak %93'lük sınıflandırma başarımı elde edilmiştir. Böylece önerilen LFAP-SPG yöntemi ile aynı eğitim oranı ve daha düşük boyutlu vektör kullanılarak ULBP-SPG yöntemine yakın sınıflandırma başarımı bu veri kümesi için de elde edilmiştir.

Pavia merkezi veri kümesi için tek düze yerel ikili örüntüler(ULBP) (1020 boyutlu giriş vektörü) ile yaklaşık olarak %83'lük sınıflandırma başarımı elde edilmiştir. Aynı çalışmada (ULBP-SPG) ile %87'lik sınıflandırma başarımı elde edilmiştir. LFAP(YÖTÖP) kullanılarak 72 boyutlu özellik vektörü ile %89'luk; Önerilen LFAP-SPG ile aynı eğitim oranı ve vektör boyutunda kalınarak %95'lik sınıflandırma başarımı elde edilmiştir. Böylece önerilen LFAP-SPG yöntemi ile aynı eğitim oranı ve daha düşük boyutlu vektör kullanılarak ULBP-SPG yöntemine yakın sınıflandırma başarımı bu veri kümesi için de elde edilmiştir.

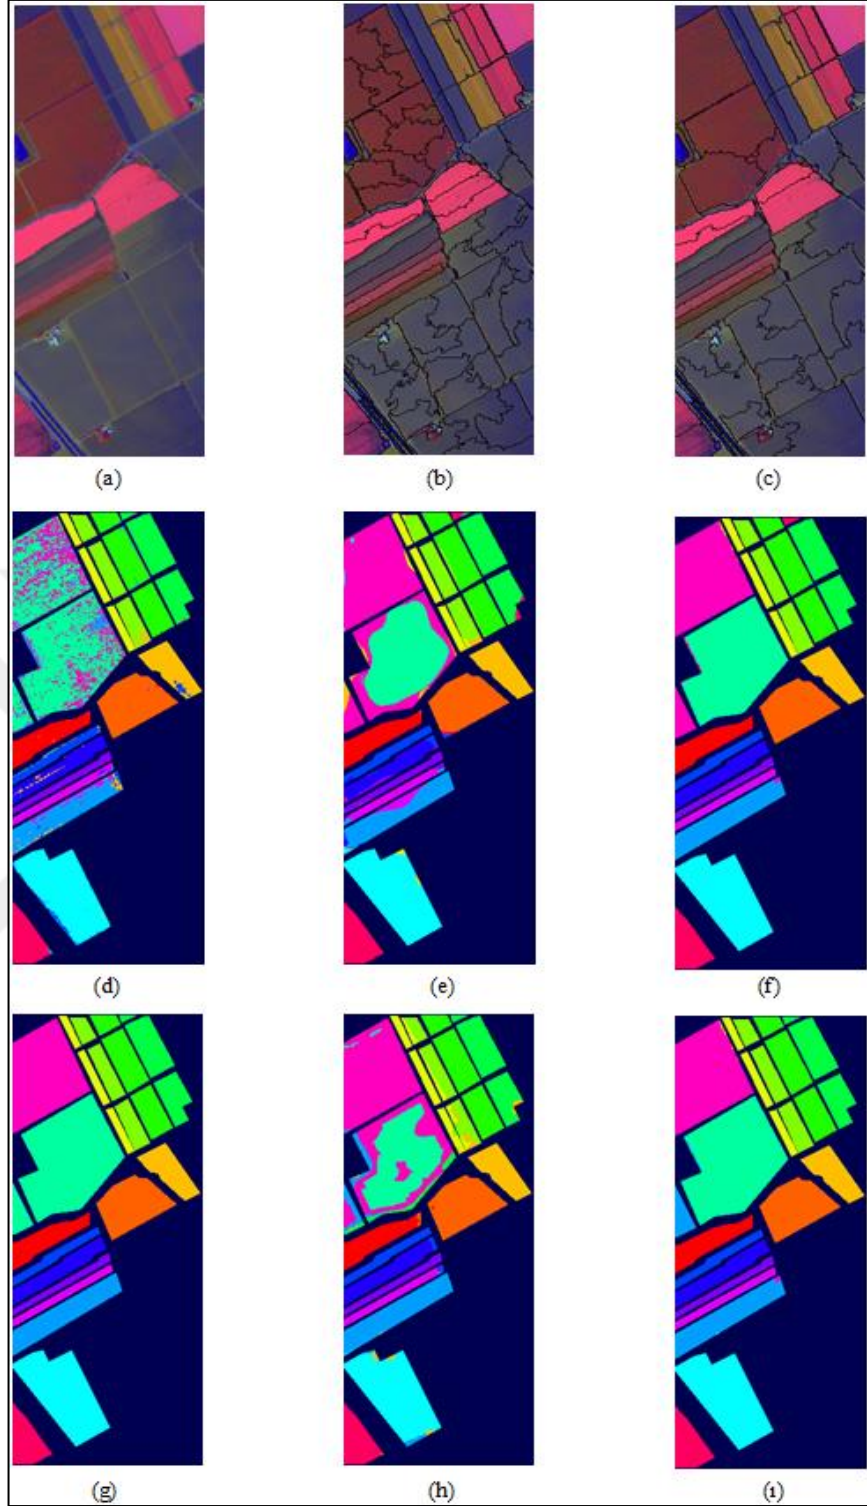
ULBP ile ULBP-SPG arasında Salinas veri kümesinde %7, Indian Pines veri kümesinde %12, Pavia Üniversitesi veri kümesinde %13, Pavia merkezi veri kümesinde %3'lük bir artış yakalanmaktadır. LFAP ile LFAP-SPG arasında ise bu fark sırası ile %15, %11, %9 ve %6 şeklindedir. Düşük vektör boyutlu olması da göz önüne alındığında, LFAP-SPG yönteminin ciddi şekilde sınıflandırma başarımını arttırdığı görülmektedir.

Yüksek boyutlu öznitelik vektörü kullanıldığında eğitilen sınıflandırıcının karmaşıklığı artmakla birlikte, eğitim ve test aşamalarının süresi 1 piksel için artmaktadır. Tablo 2.11'de Salinas, Tablo 2.12'de Indian Pines, Tablo 2.13'de Pavia Üniversitesi ve Tablo 2.14'de Pavia merkezi veri kümelerinin 1 piksel için farklı


yöntemler kullanılarak elde edilen ortalama sınıflandırma süreleri gösterilmektedir. Önerilen yöntemin eğitim ve test süreleri, sadece spektral bilgi kullanılarak sınıflandırma işleminin gerçekleştirildiği yöntemin eğitim ve test süreleri birbirine yakındır. Önerilen yöntemin eğitim ve test süreleri, yüksek boyutlu öznitelik vektörü kullanılarak sınıflandırılması gerçekleştirilen ULBP-SPG yönteminin eğitim ve test sürelerine göre oldukça düşüktür. 1 piksel için test süresini etkileyen temelde 2 parametre bulunmaktadır. Bunlardan birincisi dektek vektörü sayısı ve öznitelik vektör boyutudur. Tablo 2.15’de LFAP ve ULBP yöntemleri için elde edilen destek vektörü sayıları ve buna bağlı olarak hesapsal karmaşıklık gösterilmektedir.




Şekil 2.6. Indian Pines veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, i) Nihai sınıflandırma haritası



Şekil 2.7. Salinas veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası



Şekil 2.8. Pavia Üniversitesi veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, i) Nihai sınıflandırma haritası



Şekil 2.9. Pavia merkezi veri kümesi için önerilen yöntem görüntüleri, a) Sahte renklendirilmiş görüntü, b) Süperpiksel bölütleme sonrasında süperpiksel haritası, c) Nihai süperpiksel haritası, d) Spektral-SVM sınıflandırma haritası, e) ULBP sınıflandırma haritası, f) ULBP-SPG sınıflandırma haritası, g) Gerçek sınıf haritası, h) LFAP sınıflandırma haritası, ı) Nihai sınıflandırma haritası

Tablo 2.7. Salinas veri seti sınıflandırma sonucu karşılaştırma tablosu

Yöntem	Spektral	ULBP	LFAP	ULBP-SPG	LFAP-SPG
Vektör Boyutu	204	2040	72	2040	72
Sınıflandırma Başarımı(%)	%84	%87	%87	%99	%98

Tablo 2.8. Indian Pines veri seti sınıflandırma sonucu karşılaştırma tablosu

Yöntem	Spektral	ULBP	LFAP	ULBP-SPG	LFAP-SPG
Vektör Boyutu	200	2000	72	2000	72
Sınıflandırma Başarımı(%)	%51	%80	%69	%87	%84

Tablo 2.9. Pavia Üniversitesi'nin sınıflandırma sonucu karşılaştırma tablosu

Yöntem	Spektral	ULBP	LFAP	ULBP-SPG	LFAP-SPG
Vektör Boyutu	103	1030	72	1030	72
Sınıflandırma Başarımı(%)	%61	%77	%84	%90	%93

Tablo 2.10. Pavia merkezinin sınıflandırma sonucu karşılaştırma tablosu

Yöntem	Spektral	ULBP	LFAP	ULBP-SPG	LFAP-SPG
Vektör Boyutu	102	1020	72	1020	72
Sınıflandırma Başarımı(%)	%91	%83	%89	%87	%95

Tablo 2.11. Salinas'ın bir piksel için ortalama sınıflandırma süreleri

Yöntem	Öznitelik Çıkartma Süresi(ms)	Eğitim Süresi (ms)	Test Süresi (ms)	Süperpiksel Bölütleme Süresi(ms)	Toplam Süre(ms)
ULBP	0,1611	99,725	6,4030	NA	106,2891
LFAP	0,0990	31,6375	0,0538	NA	31,7903
ULBP+SPG	0,1611	99,725	6,4030	0,1082	106,3973
LFAP+SPG	0,0990	31,6375	0,0538	0,1082	31,8985
Spektral SVM	NA	33,0006	0,1560	NA	33,1566

Tablo 2.12. Indian Pines'ın bir piksel için ortalama sınıflandırma süreleri

Yöntem	Öznitelik Çıkartma Süresi(ms)	Eğitim Süresi (ms)	Test Süresi (ms)	Süperpiksel Bölütleme Süresi(ms)	Toplam Süre(ms)
ULBP	0,7770	86,25	6,0484	NA	93,0754
LFAP	0,1015	31,06	0,0531	NA	31,2146
ULBP+SPG	0,7770	86,25	6,0484	0,3951	93,4705
LFAP+SPG	0,1015	31,06	0,0531	0,3951	31,6097
Spektral SVM	NA	33,35	0,1342	NA	33,4842

Tablo 2.13. Pavia Üniversitesi'nin bir piksel için ortalama sınıflandırma süreleri

Yöntem	Öznitelik Çıkartma Süresi(ms)	Eğitim Süresi (ms)	Test Süresi (ms)	Süperpiksel Bölütleme Süresi(ms)	Toplam Süre(ms)
ULBP	0,0437	59,0566	1,0430	NA	60,1433
LFAP	0,0937	32,9022	0,0176	NA	33,0135
ULBP+SPG	0,0437	59,0566	1,0430	0,0717	60,215
LFAP+SPG	0,0937	32,9022	0,0176	0,0717	33,0852
Spektral SVM	NA	28,4444	0,0226	NA	28,467

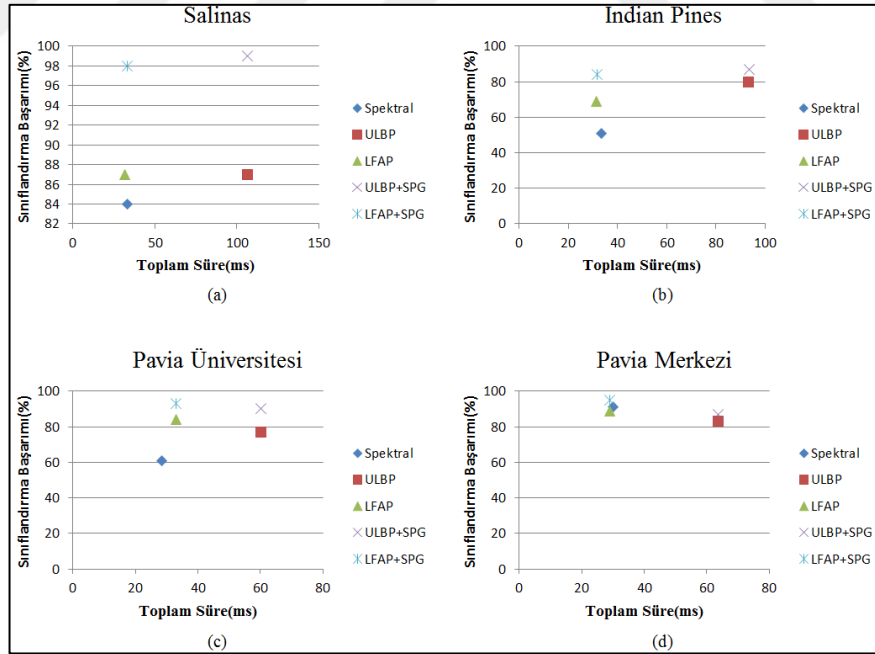
Tablo 2.14. Pavia merkezinin bir piksel için ortalama sınıflandırma süreleri

Yöntem	Öznitelik Çıkartma Süresi(ms)	Eğitim Süresi (ms)	Test Süresi (ms)	Süperpiksel Bölütleme Süresi(ms)	Toplam Süre(ms)
ULBP	0,0164	62,6155	1,0387	NA	63,6706
LFAP	0,0973	28,9155	0,0188	NA	29,0316
ULBP+SPG	0,0164	62,6155	1,0387	0,0774	63,748
LFAP+SPG	0,0973	28,9155	0,0188	0,0774	29,109
Spektral SVM	NA	30,0211	0,0254	NA	30,0465

Tablo 2.15. LFAP ve ULBP'nin destek vektörü sayıları ve hesapsal karmaşıklık

Veri Kümesi	LFAP			ULBP			Hesapsal Karmaşıklık	
	Destek Vektörü Sayısı	Skaler Çarpma Sayısı	Toplama/Çıkarma Sayısı	Destek Vektörü Sayısı	Skaler Çarpma Sayısı	Toplama/Çıkarma Sayısı	ULBP/LFAP Destek Vektörü Oranı	ULBP/LFAP Toplama ve Çarpma Oranı
Salinas	1286	185184	277776	1719	7013520	10520280	1,33	37,87
Indian Pines	1587	228528	342792	1566	6264000	9396000	0,98	27,41
Pavia Üniversitesi	524	75456	113184	558	1149480	1724220	1,06	15,23
Pavia Merkezi	527	75888	113832	636	1297440	1946160	1,20	17,09

Şekil 2.10'da yöntemlerin sınıflandırma başarımları ve toplam süreleri gösterilmektedir. Önerilen yöntemin (LFAP-SPG) eğitim ve test süreleri, spektral bilgi kullanıldığında elde edilen eğitim ve test sürelerine yakın olmasına rağmen önerilen yöntemin sınıflandırma başarımları spektral bilgi kullanıldığı zaman elde edilen sınıflandırma başarımlarından çok daha yüksektir. Önerilen yöntem kullanılarak, ULBP-SPG yönteminden çok daha hızlı eğitim ve test işlemi gerçekleştirilmesinin yanında benzer sınıflandırma başarımları elde edilmektedir.



Şekil 2.10. Yöntemlerin toplam süre ve sınıflandırma başarımları gösterimleri, a) Salinas veri kümesi sınıflandırma başarımları-toplam süre gösterimi, b) Indian Pines veri kümesi sınıflandırma başarımları-toplam süre gösterimi, c) Pavia Üniversitesi veri kümesi sınıflandırma başarımları-toplam süre gösterimi, d) Pavia merkezi veri kümesi sınıflandırma başarımları-toplam süre gösterimi

3. SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında, kullanılan hiperspektral görüntüler tanıtılmış ve hiperspektral görüntülerin eğitilmiş sınıflandırılmasına yönelik geliştirilen yöntem anlatılmıştır.

Tez çalışmasında, yerel öznitelik temelli özellik profilleri kullanılarak sınıflandırma haritası elde edilmektedir. Yüksek boyutlu hiperspektral görüntüye TBA uygulanarak elde edilen temel bileşenler üzerinden özellik profilleri elde edilir ve özellik profilleri görüntülerinden yerel öznitelik olarak birinci dereceden öznitelikler olan ortalama ve aralık değerleri elde edilmektedir. Elde edilen LFAP öznitelik vektör boyutu oldukça düşük boyutludur. Düşük boyutlu LFAP öznitelik vektörü kullanılarak DVM ile sınıflandırma yapılmaktadır.

Elde edilen sınıflandırma haritasında hatalı sınıf atamaları mevcuttur. Bu sorunu düzeltmek için süperpiksel bölütleme yöntemi kullanılmaktadır. Süperpikseller, hiperspektral görüntüye TBA uygulandıktan sonra ilk üç temel bileşenden elde edilen sahte renklendirilmiş görüntü üzerinden elde edilmektedir. Süperpikseller bölütleme sonrasında aynı sınıfa ait bölgelerde birden fazla süperpiksel olduğu için süperpiksel birleştirme işlemi uygulanmaktadır. Süperpiksel birleştirme işlemi sonrasında nihai süperpiksel haritası elde edilmektedir. Düşük eğitim oranları ile elde edilen düşük sınıflandırma başarımına sahip sınıflandırma haritası, süperpiksel birleştirme işlemi yapılmadan doğrudan süperpiksel bölütleme ile elde edilen süperpiksel haritası ile düzeltildiğinde sınıflandırma başarımı çok fazla iyileştirilemediği gibi sınıflandırma başarımı olumsuz yönde etkilenebilmektedir. Bu yüzden süperpiksel birleştirme ile birbirine benzeyen süperpikseller birleştirilerek aynı sınıfa ait bölgelerde mümkün olduğunca daha az sayıda ve büyük homojen süperpikselle dönüşürmek amaçlanmıştır.

Son olarak sınıflandırma haritası, elde edilen nihai süperpiksel haritası ile birleştirilerek sınıflandırma haritası düzeltilmektedir.

Sonuç olarak düşük boyutlu LFAP öznitelik vektörü üzerinden DVM ile elde edilen sınıflandırma haritası, süperpiksel haritası ile düzeltilerek sınıflandırma başarımının iyileştirilmesi hedeflenmektedir. Önerilen LFAP-SPG yönteminin düşük boyutlu öznitelik vektörü ile yüksek sınıflandırma başarımı elde edebildiği, süperpiksel temelli son işlemin sınıflandırma başarımında ciddi şekilde iyileştirme sağladığı gösterilmektedir. Böylece hem LFAP öznitelik vektör boyutu değiştirilmeden bu yöntemin başarımı iyileştirilmiş hem de çok yüksek vektör boyutlu ULBP-SPG yöntemine yakın sınıflandırma başarımı elde edilmektedir. Süperpiksel temelli sınıf haritası düzeltme son işleminin farklı sınıflandırıcılar için de başarımları artırıcı unsur oluşturacağı değerlendirilmektedir.



KAYNAKÇA

- [1] Gerçek D., Çeşmeci D., Güllü M. K., Ertürk A., Ertürk S., Hiperpektral Görüntüleme ve Görüntü İşlemenin Bugünü, Yakın Geleceği ve Mevcut Araştırma Eğilimleri, *XYZ Dergi* 18, 2013
- [2] Çeşmeci D., Hiperpektral Görüntü Sınıflandırmada Faz Korelasyonu ve 1-bit Temelli Yaklaşımlar, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 2009, 259493
- [3] Tekcan F. M., Makine Öğrenmesi ile Hiperpektral Görüntü Sınıflandırma, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 2018, 523234
- [4] Q. Du, H. Yang, Similarity-based unsupervised band selection for hyperspectral image analysis, *IEEE Geoscience Remote Sensing Letters*, 2008, 564–568
- [5] Mauro Dalla Mur, Jón Atli Benediktsson, Björn Waske, Lorenzo Bruzzone, Morphological Attribute Profiles for the Analysis of Very High Resolution Images, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 3747-3762
- [6] Minh-Tan Pham, Sebastien Lefevre, Erchan Aptoula, Lorenzo Bruzzone, Recent Developments from Attribute Profiles for Remote Sensing Image Classification, *Computer Vision and Pattern Recognition*, 2018
- [7] Gabriele Cavallaro, Nicola Falco, Mauro Dalla Mura, Jón Benediktsson, Automatic Attribute Profiles, *IEEE Transactions on Image Processing*, Institute of Electrical and Electronics Engineers, 2017, 26(4), 1859-1872
- [8] Minh-Tan Pham, Sébastien Lefèvre, Erchan Aptoula, Local Feature-Based Attribute Profiles for Optical Remote Sensing Image Classification, 2017, 1199 - 1212
- [9] Timo Ojala, Matti Pietikainen, Senior Member, IEEE, and Topi Maenpaa, Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns, *IEEE, Transactions on Pattern Analysis and Machine Intelligence*, 2002, 971–987
- [10] Wei Li, Chen Chen, Hongjun Su, Qian Du, Local Binary Pattern and Extreme Learning Machine for Hyperspectral Imagery Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 3681 - 3693

- [11] Sen Jia, Bin Deng, Jiasong Zhu, Xiuping Jia, Qingquan Li, Local Binary Pattern-Based Hyperspectral Image Classification with Superpixel Guidance, *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 749 - 759
- [12] University of Dayton, Hyperspectral Image Processing, https://www.udayton.edu/engineering/research/centers/vision_lab/research/was_data_analysis_and_processing/hyperspectral_data_processing.php (Ziyaret tarihi: 8 Haziran 2019)
- [13] A.Materka, Texture analysis methods-A review, Technical University of Lodz, Institute of Electronics, COST B11 report, 1998, 9 – 11
- [14] D. ping Tian, A review on image feature extraction and representation techniques, *International Journal of Multimedia and Ubiquitous Engineering*, 2013, 385–396
- [15] F. Tomita and S. Tsuji, *Computer Analysis of Visual Textures*, Springer, The Netherlands, 2013
- [16] J. Tang, S. Alelyani, and H. Liu, Feature selection for classification: A review, *Data Classification: Algorithms and Applications*, 2014, 37 – 64
- [17] G. Mori, X. Ren, A. A. Efros, and J. Malik. Recovering human body configurations: Combining segmentation and recognition, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2004
- [18] M.-Y. Liu, O. Tuzel, S. Ramalingam, and R. Chellappa, Entropy rate superpixel segmentation, *IEEE Computer Vision & Pattern Recognition (CVPR)*, 2011, 2097 – 2104

KİŞİSEL YAYIN VE ESERLER

- [1] Deveci Ç., Güllü K., Yerel Öznitelik Temelli Özellik Profilleri ve Süperpiksel Bölütleme Kullanılarak Hiperspektral Görüntü Sınıflandırma, 27.Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Gebze Teknik Üniversitesi - Sivas Cumhuriyet Üniversitesi, Sivas, 24-26 Nisan 2019.



ÖZGEÇMİŞ

1992 yılında Aydın'ın Nazilli ilçesinde doğdu. İlk ve orta öğrenimini Aydın'ın Buharkent ilçesinde, lise öğrenimini Nazilli'de tamamladı. 2010 yılında girdiği Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden 2015 yılında Elektronik ve Haberleşme Mühendisi olarak mezun oldu. 2015 yılından beri Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda Yüksek Lisans öğrenimine devam etmektedir. 2015-2016 yılları arasında 11 ay Formulsoft şirketinde görev yapmış olup, 2016 yılından beri Atmaca Elektronik AŞ'de Yazılım Mühendisi olarak görev yapmaktadır.