



A modified SLIC-based superpixel segmentation for hyperspectral images

İbrahim Onur Sığırcı¹, Gökhan Bilgin*²

Department of Computer Engineering, Faculty of Electrical and Electronics Engineering, Yıldız Technical University, 34220, Istanbul, Türkiye

Highlights:

- Modified SLIC algorithm for hyperspectral images
- Merge superpixels using DBSCAN
- Introduced the spectral similarity index for spectral distance

Keywords:

- Superpixel segmentation
- Hyperspectral classification
- Hyper-SLIC
- Spectral-spatial
- Spectral similarity index

Article Info:

Research Article
Received: 04.12.2020
Accepted: 11.02.2022

DOI:

10.17341/gazimmfd.835846

Correspondence:

Author: Gökhan Bilgin
e-mail:
gbilgin@yildiz.edu.tr
phone: +90 212 383 5731

Graphical/Tabular Abstract

In this study, the SLIC superpixel algorithm is modified for hyperspectral images. The segmentation maps obtained with the SLIC algorithms are combined with the classification map via majority voting. The performance of the obtained classification map is evaluated. The flowchart of the proposed system is shown in Figure A.

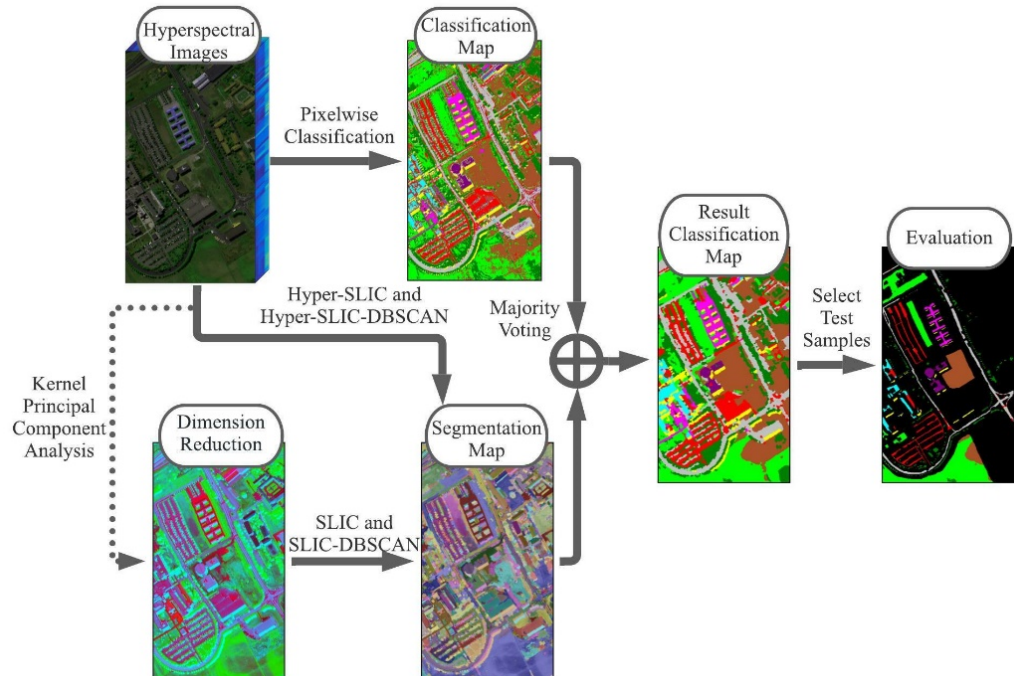


Figure A. Flowchart of the proposed method

Purpose: The purpose of this study is to investigate how the modified SLIC superpixel algorithm according to the hyperspectral image format, superpixels merged with DBSCAN and the spectral similarity index impact classification accuracy.

Theory and Methods: Formulations in the SLIC superpixel algorithm are updated according to the hyperspectral image format. The method is called Hyper-SLIC. Image quality index is used for distance calculations. The superpixels obtained are merged according to their similarities with the DBSCAN algorithm. These approaches are called SLIC-DBSCAN and Hyper-SLIC-DBSCAN. The classification map obtained using the SVM algorithm and the segmentation map obtained with the proposed method are combined via majority voting method.

Results: The performance of the proposed method is compared with the traditional SLIC algorithm. Pavia University and Indian Pines datasets were used in the experiments. The spatial resolutions of the datasets are different. Hyper-SLIC-DBSCAN algorithm gave the most successful results in both data sets.

Conclusion: Modified-SLIC methods give better performance than traditional SLIC methods. The information loss caused by the steps in traditional SLIC methods using hyperspectral images is eliminated.



Hiperspektral görüntüler için değiştirilmiş SLIC tabanlı süperpiksel bölütleme

İbrahim Onur Sığırcı¹, Gökhan Bilgin*²

Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34220, İstanbul, Türkiye

ÖNEÇIKANLAR

- Hiperspektral görüntüler için modifiye edilmiş SLIC algoritması
- DBSCAN kullanılarak süperpikselerin birleştirilmesi
- Spektral uzaklık için spektral benzerlik indeksinin sunulması

Makale Bilgileri

Araştırma Makalesi
Geliş: 04.12.2020
Kabul: 11.02.2022

DOI:

10.17341/gazimmfd.835846

Anahtar Kelimeler:

Süperpiksel bölütleme,
hiperspektral sınıflandırma,
Hyper-SLIC,
spektral-uzamsal,
spektral benzerlik indeksi

ÖZ

SLIC (basit doğrusal iteratif kümeleme) süperpiksel algoritması, bölütleme için verimli ve hızlı bir algoritmadır. Bu algoritma doğası gereği üç bantlı renkli görüntüler için tasarlanmıştır. Uzaktan algılamada yeni bir teknoloji olan hiperspektral görüntüleme, zengin spektral ve uzamsal bilgi taşıyan yüzlerce bant içermektedir. Bu çalışmada, SLIC algoritması hiperspektral görüntülerin yapısına göre modifiye edilmiştir. Buna ek olarak, benzer süperpikseller DBSCAN (gürültülü uygulamaların yoğunluk tabanlı uzamsal kümelemesi) algoritması ile birleştirilmiştir. Esinlenen yeni bir yaklaşımla süperpikseller arasındaki spektral benzerlik indeksi, evrensel görüntü kalitesi indeksine göre hesaplanmıştır. Elde edilen bölütleme haritalarının sınıflandırma performansına katkısı karşılaştırılmalı olarak sunulmuştur. Çalışmada sunulan yaklaşımlarla, Pavia Üniversitesi veri kümesinin doğruluğu boyut indirgeme yapılarak kullanılan SLIC algoritması ile %86,85'ten %96,66'ya yükseltilmiştir. Indian Pines veri kümesinde, geleneksel SLIC yaklaşımı sınıflandırmaya %89,06 katkı sağlarken, önerilen yaklaşım %97,26 katkı sağlamıştır.

A modified SLIC-based superpixel segmentation for hyperspectral images

HIGHLIGHTS

- Modified SLIC algorithm for hyperspectral images
- Merge superpixels using DBSCAN
- Introduced the spectral similarity index for spectral distance

Article Info

Research Article
Received: 04.12.2020
Accepted: 11.02.2022

DOI:

10.17341/gazimmfd.835846

Keywords:

Superpixel segmentation,
hyperspectral classification,
Hyper-SLIC,
spectral-spatial,
spectral similarity index

ABSTRACT

The SLIC (simple linear iterative clustering) superpixel algorithm is an efficient and fast algorithm for segmentation. The algorithm is inherently designed on three band color images. Hyperspectral imaging, which is a relatively new remote sensing technology, contains hundreds of bands which carry rich spectral and spatial information. In this study, the SLIC algorithm is modified according to the structure of hyperspectral images. In addition to that, the similar superpixels are merged with the DBSCAN (density-based spatial clustering of applications with noise) algorithm. As a novel inspired approach, the spectral similarity index between the superpixels are computed based on the universal image quality index. The contribution of the obtained segmentation maps to the classification performance is presented comparatively. With the approaches presented in the study, the accuracy of the Pavia University dataset was increased from 86.85% to 96.66% using the SLIC algorithm by performing dimension reduction. In the Indian Pines dataset, the traditional SLIC approach contributed 89.06% to the classification, while the proposed approach contributed 97.26%.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : onursigirci@gmail.com, *gbilgin@yildiz.edu.tr / Tel: +90 212 383 5731

1. Giriş (Introduction)

Hiperspektral uzaktan algılayıcılar, elektromanyetik spektrum üzerinde optik alan olarak adlandırılan bölümdeki görünür ve yakın kızılötesi dalgaboyları üzerinde çalışmaktadırlar. Hiperspektral sensörler aracılığıyla, hiperspektral görüntülerin katmanlarını oluşturan yüzlerce spektral bant elde edilmektedir. Farklı maddeler, hiperspektral sensörler aracılığıyla gönderilen ışınları madde yapılarına göre yansıtmaktadırlar. Yüzlerce banttan oluşan hiperspektral görüntüler üzerinde; her bir bantta bir piksele karşılık gelen değerler bir araya geldiklerinde spektral imza olarak isimlendirilen sinyali oluştururlar. Bu sinyal üzerindeki değerler; maddelerin ışınları yansıtma miktarlarına göre oluştuğundan, spektral imzalar sınıflandırmada ayırt edici özellik olarak kullanılmaktadır. Hiperspektral görüntülerin bu anlamdaki güçlü yanından ötürü yer bilimleri, şehir planlama, biyomedikal görüntüleme, tarım, gıda, savunma ve güvenlik gibi birçok alanda kullanılmaktadır.

Hiperspektral görüntü sınıflandırmanın ilk yıllarında sadece spektral imza kullanılmıştır. Piksel-bazlı sınıflandırma olarak adlandırılan bu yaklaşımda sınıflandırıcı olarak rasgele ormanlar [1], yapay sinir ağları [2], adaboost [3], destek vektör makineleri [4] ve aktif öğrenme [5] yöntemleri kullanılmıştır. Kullanılan geleneksel sınıflandırıcılar içerisinde Gaussian radyal tabanlı çekirdek (RBF) kullanılarak uygulanan destek vektör makinelerinin en başarılı sonucu verdiği gösterilmiştir [6]. Bu yüzden; az sayıda eğitim verisi üzerinde yüksek performans gösteren RBF tabanlı destek vektör makineleri, hiperspektral görüntü sınıflandırmada sıklıkla kullanılmaktadır. Hiperspektral görüntülerinde etiketleme önemli sorunlardan birini oluşturmaktadır. Bir pikselin temsil ettiği alanın genişliği, bu alandaki madde çeşitliliği etiketlemeyi zorlaştırmasının yanında; atmosferik etkiler, gölge gibi durumlarla birlikte spektral imzanın ayırt ediciliği bozulmaktadır. Bu sebepler; etiketli verilerin az olmasına dolayısıyla sınıflandırma başarımının düşmesine yol açmaktadır.

Hiperspektral görüntü sınıflandırmanın ilerleyen yıllarında, sınıflandırma başarımını arttırmak için spektral imzalarında yanında komşuluk bilgilerinin temsil edecek uzamsal bilgi de yapılan çalışmalarda kullanılmıştır. Bu kapsamda yapılan çalışmalarda, uzamsal bilginin nasıl elde edileceği ve tasarlanan sistemin hangi aşamasında dahil edileceği üzerine sorular sorulmuştur. Uzamsal bilgi kullanımında Hanbay [7], iki boyutlu karmaşık Gabor dönüşümü kullanmışlardır. Bir başka çalışmada Hong vd. [8], graf tabanlı evrişimsel ağ kullanarak uzamsal bilgiyi sınıflandırma sistemlerine dahil etmişlerdir. Bu alanda çalışmalarıyla bilinen Yuliyeva vd. uzamsal bilgi için bölütleme haritalarını kullanmışlardır [9]. Bölütleme haritasıyla elde ettikleri uzamsal bilgileri, eğitici öğrenme yaklaşımlarıyla elde ettikleri sınıf bilgileri ile çoğulcu oylama yöntemiyle birleştirmişlerdir.

Süperpiksel yaklaşımları; görüntü işleme ve bilgisayarlı görünüm bölütleme [10], nesne tespiti [11], nesne takibi [12] gibi alanlarında kullanılan güncel yaklaşımlardandır. Süperpikseller, temsil ettikleri küçük bölgelere şekil ve boyut anlamında sağladıkları uyum neticesinde yüksek miktarda uzamsal bilgi içermektedir. Bu özelliklerinden ötürü çeşitli çalışmalarda bölütleme amacıyla kullanılmıştır. Karaca vd. [13], yaptıkları çalışmada orman yangınlarından sonra hasar tespiti, arazi tespiti ve planlamanın yapılabilmesi için kullandıkları multispektral görüntüler üzerinde süperpiksel yaklaşımları kullanarak bölütleme yapmışlardır. Literatürde süperpiksel yaklaşımları içeren bazı yöntemler önerilmiştir: Felzenszwalb'in çizge tabanlı bölütleme algoritması [14], hızlı kaydırma bölütleme algoritması [15] ve basit doğrusal iteratif kümeleme (simple linear iterative clustering, SLIC) [16] algoritması. Süperpiksel yaklaşımları; sunduğu faydalar sebebiyle

hiperspektral görüntü sınıflandırma çalışmalarında kullanılmıştır ve yüksek performans alındığı gözlemlenmiştir. Huang vd. [17] yaptıkları çalışmada, süperpiksel bölütlemeye elde ettikleri sonuçları yerel ikili örüntüler ile çoklu-çekirdek yöntemi ile kullanmışlardır. Zhang vd. [18], arazi görüntülerinin sınıflandırılmasında süperpiksel yaklaşımları kullanarak aşırı öğrenme makineleri ile sınıflandırma yapmışlardır. SLIC algoritmasının kullanımı diğerlerine göre daha kolaydır ve algoritma hızlı çalışmaktadır [19]. Bu amaçla Zhang vd. [20] yaptıkları diğer çalışmada SLIC algoritması sonucunda elde edilen bölütleme haritasını yarı eğitici yaklaşımlarla kullanarak sınıflandırmasını yapmışlardır. Zhang vd. [21] yaptıkları çalışma ile hiperspektral görüntülerin boyut indirgemesinde SLIC algoritmasını kullanmışlardır. Bölütleme sonucunda çıkan benzerlik bilgisi çeşitli yöntemlere entegre edilerek hızlı ve gürbüz sonuçlar almışlardır. Zhao vd. [22] yaptıkları çalışma ile SLIC ve aktif öğrenmeye dayalı yeni bir sınıflandırma yöntemi önermişlerdir. SLIC algoritmasına girdi olarak hiperspektral görüntü boyut indirgemesi yapılarak üç bant olacak şekilde verilmiştir.

Bu makalenin odak noktalarından birisi, uzamsal bilgi için kullanılacak bölütleme haritasının elde edilmesinde SLIC yaklaşımının kullanılmasıdır. Buradaki tercih sebebi; SLIC algoritmasının kullanımın diğerlerine göre daha kolay olması ve hızlı çalışmasıdır [16]. Literatürde kullanılan SLIC algoritması üç-bantlı renkli görüntüler üzerine kurgulanmıştır. Dolayısıyla hiperspektral görüntü sınıflandırmada görüntüler yüzlerce bantta sahip iken üç bantta indirgenerek kullanılmaktadır [16]. Üç bant gerekliliği boyut indirgeme maliyetini ve bilgi kayıplarını beraberinde getirmektedir.

Bu çalışmada yüzlerce bant içeren hiperspektral görüntüler kullanılmaktadır. SLIC algoritması ise doğası gereği üç bantlı RGB görüntüleri girdi olarak kabul etmekte ve CIELAB uzayına çevirmektedir. Hiperspektral görüntülerin SLIC algoritmasında kullanılması için boyut indirgeme yöntemleri yardımıyla yüzlerce banttan üç bantta indirmesi yapılmaktadır. Elde edilen üç bant RGB olarak kabul edilip SLIC algoritması tarafından CIELAB uzayına çevirmektedir. Bu durum zaman maliyeti getirmesinin yanında bilgi kayıplarına yol açtığından sınıflandırma başarımları düşük olmaktadır. Bu çalışmadaki ana motivasyon, SLIC algoritmasının yüzlerce bant içeren hiperspektral görüntülerin yapısına uygun olarak değiştirilip uzamsal bilgi olarak kullanılarak sınıflandırmaya katkısının incelenmesi üzerinedir. Bununla birlikte benzer süperpiksel bölgelerin bir araya gelerek oluşturdukları bölütlerin anlamlı katkısı incelenmektedir.

Çalışmanın takip eden kısımları şu şekilde organize edilmiştir. İkinci bölümde; SLIC algoritmasının yapısı anlatılarak hiperspektral görüntüler için yeniden kurgulanması anlatılmıştır. Ayrıca benzer süperpikselleri bir araya getirecek SLIC-DBSCAN yönteminden bahsedilmiştir. Bunlarla birlikte kurulan sınıflandırma akışı içerisinde spektral bilgiden elde edilen sınıflandırma haritası ile uzamsal bilgiden elde edilen bölütleme haritasının çoğulcu oylama yöntemiyle birleştirilmesi anlatılmıştır. Üçüncü bölümde, kullanılan veri setleri ve sınıflandırma akışı anlatılarak sonuçlar tablo ve şekiller yardımıyla sunulmuştur. Dördüncü bölümde, çalışmada kullanılan simgeler listelenmiştir. Son bölümde ise çalışmanın nihai çıktıları değerlendirilmiş ve gelecek çalışmalardan bahsedilmiştir.

2. Teorik Metot (Theoretical Method)

2.1. SLIC Algoritması (SLIC Algorithm)

SLIC süperpiksel algoritması; (x,y) konumunda bulunan bir pikselin CIELab uzayındaki değeri ile konum bilgisinin kullanıldığı k-ortalamlar temelli bir algoritmadır [16]. Algoritma, basit temeller

üzerine kurgulanmasına rağmen görüntü bölütlemeye çok verimlidir. K-ortalamalar tabanlı bu yaklaşımın, k-ortalamalar algoritmasından ilk farkı; piksellerin tüm merkezlere uzaklıkları değil belirli bir alandaki merkezlere olan uzaklıklarının hesaplanmasıdır. İkinci farkı ise, renk özellikleriyle süperpikselin uyumluluğu artırılırken piksellerin konum özelliklerinin uzaklık hesaplamada kullanılmasıyla bölgeye adaptasyon artırılmaktadır [16].

SLIC tabanlı süperpiksel algoritmasının kaba kodu Algoritma 1'de sunulmuştur. C_k küme merkezleri süperpiksel merkezlerini temsil etmektedir.

Algoritma 1. SLIC süperpiksel bölütleme

/* İlk Atamalar */

1. $S \leftarrow \sqrt{N/k}$
2. S adımıyla gridlerden oluşan her bir piksel grubu, değeri ve pozisyonu ile birlikte $C_k \leftarrow [x_k, y_k, l_k, a_k, b_k]$ küme merkezi olacak şekilde atanır.
3. Her bir piksel t için bulunduğu kümeyi gösteren $L(t) = -1$ olarak atanır.
4. Her bir piksel t için bulunduğu süperpiksele olan uzaklığı gösteren $D(t) = \infty$ olarak atanır.

repeat

/* Atamalar */

for Her bir C_k **do**

for C_k 'nin merkezde olduğu $2S \times 2S$ 'lik bölge içerisindeki piksel t için **do**

C_k ve t arasındaki uzaklık d olarak hesaplanır.

if $d < D(t)$ **then**

$D(t) = d$

$L(t) = k$

end if

end for

end for

/* Güncellemeler */

Yeni küme merkezleri hesaplanır.

Hata E olacak şekilde hesaplanır.

until $E \leq$ eşik değeri

Kaba kodu verilen SLIC algoritmasında önemli noktalardan biri piksel ile küme merkezi arasındaki uzaklık hesaplamasının yapılış şeklidir; çünkü kullanılan veri hem pikselin CIELab uzayındaki değerlerini hem de resim üzerindeki konumunu içermektedir. Sayıların birbirlerine olan baskısını dengelemek için uzaklık hesaplamasının doğru yapılması gerekmektedir. Bu hesaplama için konumlar ve piksel değerlerinin kendi içlerinde uzaklıkları hesaplanır. i ve j birer pikseli temsil etmek üzere Eş. 1 bu piksellerinin konumları arasındaki uzaklığı, Eş. 2 ise bu piksellerin CIELab uzayındaki değerleri arasındaki uzaklığın nasıl hesaplandığını göstermektedir.

$$dist_s \leftarrow \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (1)$$

$$dist_c \leftarrow \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2} \quad (2)$$

$dist_s$ ve $dist_c$ değerlerinin birbirlerine olumsuz etkilerini kırmak için her ikisinin de normalize edilmesi gerekmektedir. S değeri $dist_s$ değerini normalize etmek için kullanılmaktadır; çünkü $2S \times 2S$ 'lik bölge içerisindeki bir pikselin merkeze olan uzaklığı en fazla $S\sqrt{2}$ büyüklüğünde olacaktır. Hesaplamaları kolaylaştırmak adına S değeri

kullanılmaktadır. m değeri ise $dist_c$ değerini normalize etmek için kullanılmaktadır. Bu değer ise deneysel olarak [1, 10] aralığında seçilmektedir. Bu durumda iki piksel arasındaki uzaklık gerekli normalizasyon işlemleri ile birlikte Eş. 3'te gösterildiği gibi hesaplanacaktır.

$$dist_{ij} \leftarrow \sqrt{\left(\frac{dist_c}{m}\right)^2 + \left(\frac{dist_s}{s}\right)^2} \equiv \sqrt{dist_c^2 + \left(\frac{dist_s}{s} \cdot m\right)^2} \quad (3)$$

2.2. Değiştirilmiş SLIC Algoritması (Modified SLIC Algorithm)

Hiperspektral görüntülerde CIELab uzayında olduğu gibi üç bant yerine yüzlerce bant bulunmaktadır. Dolayısıyla uzaklık hesaplamasının ve m değerinin yeniden belirlenmesi gerekmektedir. d adet bant içeren bir pikselin spektral imzası $p_i = [p_{i1}, p_{i2}, \dots, p_{id}]$ şeklinde ifade edildiği düşünüldüğünde; iki spektral imza arasındaki uzaklık hesaplamasında konum uzaklıkları için Eş. 1 geçerli olurken değersel uzaklıkta Eş. 2 yerine artık Eş. 4 kullanılır:

$$dist_c \leftarrow \sqrt{(p_{i1} - p_{j1})^2 + (p_{j2} - p_{j2})^2 + \dots + (p_{id} - p_{jd})^2} \quad (4)$$

Eş. 1 tekrar kullanıldığı için S değeri $dist_s$ uzaklığını normalize etmek için kullanılmaktadır. Burada m değerinin yeniden belirlenmesi gerekmektedir. $1 \leq k \leq d$ olmak üzere $0 \leq p_{ik} \leq 255$ değerlerini almaktadır. Buradan iki değer arasındaki fark $0 \leq (p_{ik} - p_{jk})^2 \leq 255^2$ olmaktadır. Normalizasyon için kullanılacak m değerini belirleyen ve $dist_c$ 'nin alabileceği en büyük değer formül Eş. 5 ile gösterilmiştir.

$$0 \leq dist_c \leq 255\sqrt{d} = m \quad (5)$$

Tüm bu değerler ışığında Eş. 3 hiperspektral görüntüler için yeniden yazıldığında Eş. 6'daki eşitlik elde edilmektedir.

$$dist \leftarrow \sqrt{\left(\frac{dist_c}{255\sqrt{d}}\right)^2 + \left(\frac{dist_s}{s}\right)^2} \equiv \sqrt{dist_c^2 + dist_s^2 \cdot \left(\frac{255\sqrt{d}}{s}\right)^2} \quad (6)$$

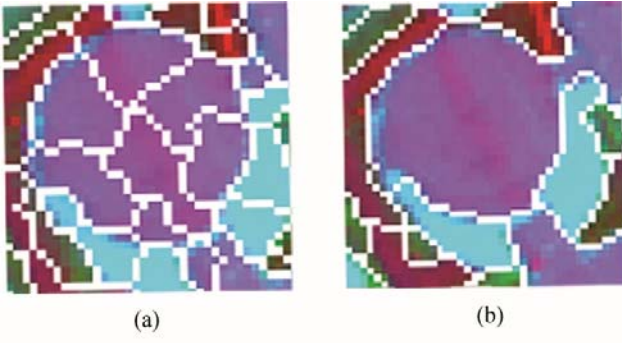
Elde edilen eşitlikler kullanılarak hiperspektral görüntüler üzerinde SLIC algoritması çalıştırılabilmektedir. Çalışmanın ilerleyen kısımlarında bu yaklaşım *Hyper-SLIC* olarak adlandırılacaktır.

2.3. SLIC-DBSCAN Algoritması (SLIC-DBSCAN Algorithm)

Süperpikseller, anlamlı küçük bölgelerden oluşmaktadırlar. Birbirine benzer bölgelerin birleştirilmesi hiyerarşik kümeleme yaklaşımlarını andırmaktadır. Bu kapsamda SLIC algoritması ile elde edilen süperpiksel bölgeleri DBSCAN [23] algoritması ile birleştirilmektedir. Böylelikle daha büyük bölütler elde edilmektedir. Şekil 1a hiperspektral bir görüntü üzerinde süperpiksel bölütlerini gösterirken, Şekil 1b bu bölütlerin DBSCAN yaklaşımıyla birleştirildiği durumdaki yeni bölütleri göstermektedir.

DBSCAN algoritması yardımıyla süperpikseller belirli uzaklıktaki komşu süperpikseller ile birleştirilmektedir. Burada uzaklık hesaplaması yapılırken sadece değer bilgisi kullanılmıştır, konum bilgisi kullanılmamıştır. Elde edilen yeni bölütleme haritası SLIC-DBSCAN olarak adlandırılmıştır.

Literatürde SLIC-DBSCAN olarak adlandırdığımız yöntem üç bantlı görüntüler içeren baskı endüstrisi [24], histopatolojik görüntü bölütleme [25], SAR görüntüleri [26] gibi farklı alanlarda kullanılmıştır.



Şekil 1. Süperpiksel bölütleme sonuçları (a) SLIC süperpiksel bölütleme sonucu (b) SLIC-DBSCAN süperpiksel bölütleme sonucu (Superpixel segmentation results (a) SLIC superpixel segmentation result (b) SLIC-DBSCAN superpixel segmentation result)

2.4. Hyper-SLIC-DBSCAN Algoritması (Hyper-SLIC-DBSCAN Algorithm)

Hyper-SLIC algoritması ile elde edilen bölütleme haritası DBSCAN algoritması ile yenilendiğinde ismi Hyper-SLIC-DBSCAN olarak isimlendirilmiştir. Burada uzaklık hesaplaması yapılırken iki spektral imza arasındaki benzerlik için spektral benzerlik indeksi olarak isimlendirilen yaklaşım kullanılmıştır. Bu yaklaşım iki resim arasındaki benzerliği ölçmeyi hedefleyen evrensel görüntü kalite indeksinin [27] hiperspektral görüntülere uyarlanmasıyla elde edilmiştir. x ve y süperpikselleri için spektral benzerlik hesaplaması Eş. 7 ile gösterilmiştir:

$$sim_{ssi} = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma_x^2 + \sigma_y^2)(\bar{x}^2 + \bar{y}^2)} = \frac{\sigma_{xy}}{\sigma_x\sigma_y} \cdot \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \cdot \frac{2\sigma_x\sigma_y}{\sigma_x^2 + \sigma_y^2} \quad (7)$$

Eş. 7 ile gösterilen eşitlikte \bar{x} ve \bar{y} piksellerin spektral imzalarının ortalamasını gösterirken σ_x^2 ve σ_y^2 varyansları göstermektedir. σ_{xy} ise piksellerin kovaryanslarını temsil etmektedir. Hesaplamanın kendi içinde benzer üç kesir ile ifade edilebilmesi için σ_x ve σ_y standart sapmaları ile genişletilmesi yapılmıştır. Görüntü benzerliğinde ilk kesir x ve y arasındaki korelasyonu temsil etmektedir. İkinci kesir, x ve y arasındaki ortalama ışımaya (yansıma, lüminans) benzerliğini ifade etmektedir. Son kesirde ise x ve y arasındaki zıtlık (kontrast) benzerliği dikkate alınmıştır.


2.5. Çoğulcu Oylama (Majority Voting)

Çoğulcu oylama, spektral bilgiden elde edilen sınıflandırma haritası ile uzamsal bilgiden elde edilen bölütleme haritasının birleştirilme yöntemini ifade etmektedir [28]. Bölütleme haritaları eğitici olarak tüm pikseller değerlendirilerek elde edilirken, sınıflandırma haritaları eğitici olarak eğitim verileri üzerindeki bilgi ile pikseller anlamlandırılmaktadır.

Çoğulcu oylama yaklaşımının temelinde, bölütleme haritasında yer alan bir bölgedeki piksellerin birbirine benzer olduğu varsayımı vardır. Piksellerin birbirine benzer olmasına karşın hangi sınıfta olduğu bilgisi bilinmemektedir. Bunun için bu bölgenin sınıflandırma haritası üzerindeki sonuçlarına bakılır. Pikseller için en çok geçerli sınıf bölgenin sınıfını temsil etmektedir.

Şekil 2, çoğulcu oylama yönteminin örneğini içermektedir. Şekil 2a sınıflandırma haritası, Şekil 2b ise bölütleme haritasını temsil etmektedir. Şekil 2b'de yer alan iki numaralı bölge içerisindeki pikseller birbirlerine benzerdir. Bu bölgenin sınıflandırma haritasındaki karşılığına bakıldığında en çok geçen renk mavidir. Dolayısıyla Şekil 2b'de yer alan benzer piksellerin hepsinin sınıfının

mavi olduğu sonucuna varılır. Bu durumda Şekil 2c'deki birleştirilmiş harita elde edilmiş olur.

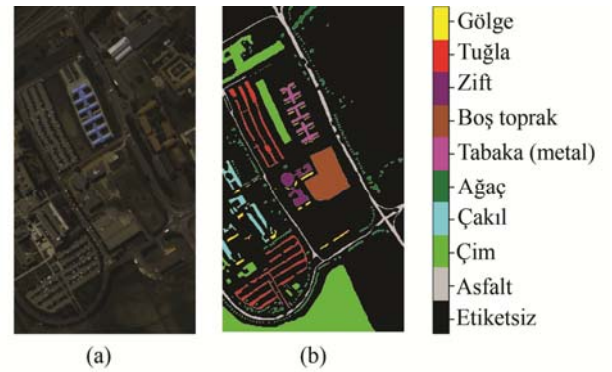


Şekil 2. Çoğulcu oylama yöntemi örneği (a) sınıflandırma haritası (b) bölütleme haritası (c) çoğulcu oylama sonucunda elde edilen sonuç sınıflandırma haritası (Majority voting method example (a) classification map (b) segmentation map (c) classification map obtained as a result of majority voting)

3. Sonuçlar ve Tartışmalar (Results and Discussions)

3.1. Veri Kümeleri (Data sets)

Bu çalışmada sunulan yaklaşımlar hiperspektral görüntü sınıflandırmada genel geçer kabul edilmiş iki veri kümesi ile sınımlanmıştır. Kullanılan veri kümeleri Pavia Üniversitesi [29, 30] ve Indian Pines [31] isimleri ile anılmaktadır. Pavia Üniversitesi veri kümesi, İtalya'nın Pavia bölgesinde yer alan Pavia Üniversitesi'nin ROSIS-03 optik sensörüyle 430nm ile 860nm arasındaki dalgalı boylarından alınan 115 spektral banttan oluşmaktadır. Sahnede 610 satır ve 340 sütun yer almaktadır. Atmosferik etkilerin olduğu ve gürültü olan bantların çıkarılmasıyla 103 banttan oluşan veri kümesi 1.3m uzamsal çözünürlüğe sahiptir. Toplamda dokuz farklı sınıf yer almaktadır. Veri kümesi içerisinde eğitim verisi olarak etiketlenmiş 3921, test verisi olarak etiketlenmiş 42776 adet piksel bulunmaktadır. Veri kümesinin üç bantlı renkli görüntüsü, eğitim verileri ve test verileri Şekil 3 ile gösterilmiştir. Ayrıca Tablo 1, veri kümesindeki etiketli verilerin sınıflara dağılımını göstermektedir.



Şekil 3. Pavia Üniversitesi veri kümesine ait bilgiler (a) yapay renkli görüntü (b) etiketli veri haritası (Pavia University dataset information (a) false color image (b) ground truth map)


Indian Pines veri kümesi, 1992 yılında Northwest Indiana bölgesinde AVIRIS optik sensörleriyle 0.4µm ile 2.5µm arasındaki dalgalı boylarından alınan 224 spektral banttan oluşmaktadır. Sahnede 145 satır ve 145 sütun yer almaktadır. Atmosferik etkilerin olduğu ve gürültü olan bantların çıkarılmasıyla 200 banttan oluşan veri kümesi 20m uzamsal çözünürlüğe sahiptir. Toplamda 16 farklı sınıf yer almaktadır. Veri kümesi içerisinde 10249 veri etiketlenmiştir; ancak etiketli veriler eğitim ve test verisi olarak ayrılmamıştır. Bu çalışmada

verilerin %10'u eğitim verisi olarak seçilmiştir. Veri kümesinin üç bantlı renkli görüntüsü, eğitim verileri ve test verileri Şekil 4 ile

gösterilmiştir. Ayrıca Tablo 2, veri kümesindeki etiketli verilerin sınıflara dağılımını göstermektedir.

Tablo 1. Pavia Üniversitesi veri kümesinin etiket isimleri, eğitim ve test verilerinin miktarları
(Label names, number of train and test samples of Pavia University dataset)

Etiket Numarası	Etiket İsmi	Toplam Örnek Sayısı	Eğitim Örnek Sayısı	Test Örnek Sayısı
1	Asfalt	6631	548	6631
2	Çim	18649	540	18649
3	Çakıl	2099	392	2099
4	Ağaç	3064	524	3064
5	Tabaka (metal)	1345	265	1345
6	Boş toprak	5029	532	5029
7	Zift	1330	375	1330
8	Tuğla	3682	514	3682
9	Gölge	947	231	947
Toplam		42776	3921	42776



Şekil 4. Indian Pines veri kümesine ait bilgiler (a) yapay renkli görüntü (b) etiketli veri haritası
(Indian Pines dataset information (a) false color image (b) groundtruth map)

Tablo 2. Indian Pines veri kümesinin etiket isimleri, eğitim ve test verilerinin miktarları
(Label names, number of train and test samples of Indian Pines dataset)

Etiket Numarası	Etiket İsmi	Toplam Örnek Sayısı	Eğitim Örnek Sayısı	Test Örnek Sayısı
1	Yonca	46	4	42
2	Mısır – işlenmemiş toprak	1428	156	1272
3	Mısır – az işlenmiş toprak	830	81	749
4	Mısır	237	21	216
5	Çayır / otlak	483	51	432
6	Çayır / ağaç	730	70	660
7	Çayır / biçilmiş otlak	28	4	24
8	Saman	478	38	440
9	Yulaf	20	1	19
10	Soya fasulyesi – işlenmemiş toprak	972	105	867
11	Soya fasulyesi – az işlenmiş toprak	2455	223	2232
12	Soya fasulyesi	593	57	536
13	Buğday	205	18	187
14	Ormanlık alan	1265	140	1125
15	Binalar-çayır-ağaç	386	46	340
16	Taş-çelik kuleler	93	9	84
Toplam		10249	1024	9225

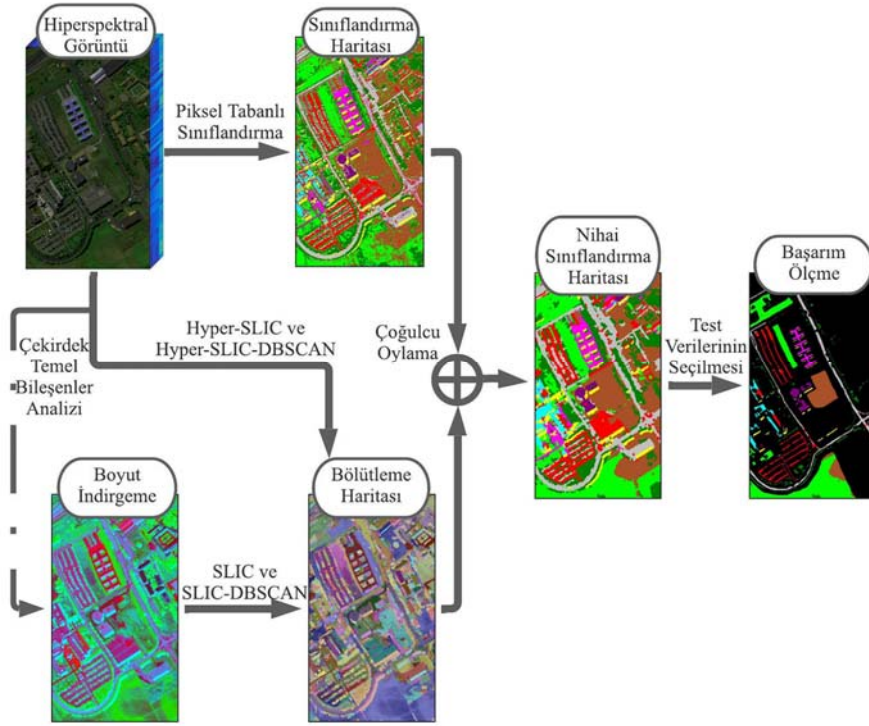
3.2. Deneysel Ortam ve Akış Diyagramı (Experimental Setup and Flow Chart)

Tüm çalışmalar Intel(R) Core(TM) i7-6700K 4.00GHz CPU ve 48GB RAM kapasiteli makinede ilerletilmiştir. Çalışmalar Python üzerinde sklearn ve skimage kütüphaneleri kullanılarak kodlanmıştır.

Şekil 5, deneylerde kullanılan akış diyagramını göstermektedir. Piksel tabanlı sınıflandırma aşamasında RBF tabanlı destek vektör makineleri yardımıyla sadece spektral bilgi kullanılarak sınıflandırma haritası elde edilmiştir. Bu yöntemin tercih edilme sebebi Giriş bölümünde açıklanmıştır [6]. SLIC algoritması yardımıyla bölütleme haritası elde edilmektedir. Hyper-SLIC algoritması, doğrudan hiperspektral görüntülere uygunken SLIC algoritması için üç bantlı bir girdi gerekmektedir. Bunun için hiperspektral görüntü çekirdek tabanlı temel bileşenler analizi ile 3 bantta indirgenerek SLIC algoritmasına girdi olarak verilmiştir. Çekirdek tabanlı yaklaşımların hiperspektral görüntülerdeki başarımlarından [6] ötürü çekirdek tabanlı temel bileşenler analizi kullanılmıştır. Sınıflandırma haritası ile bölütleme haritası çoğulcu oylama yöntemi ile birleştirilerek nihai

sınıflandırma haritası elde edilmiştir. Bu harita üzerinden test verilerinin sınıfları ile karşılaştırma yapılarak başarımlar ölçülmüştür. Geleneksel SLIC yaklaşımları ile hiperspektral görüntülere özgün olarak bu çalışmada önerilen SLIC yaklaşımlarının sınıflandırmaya etkileri; Pavia Üniversitesi veri kümesi için Tablo 3'te, Indian Pines veri kümesi için Tablo 4'te gösterilmiştir.

Yapılan deneyler sonucunda elde edilen sonuçlar Tablo 3 ve Tablo 4 ile gösterilmiştir. Tabloda sunulan sonuçlar genel ve sınıf özelinde doğruluk bilgisini içermektedir. Genel doğruluk bilgisi, doğru tespit edilen test verilerinin toplam test verisi sayısına bölünmesini temsil etmektedir. Sınıf özelindeki doğruluk yüzdesi ise, sınıf özelindeki test verilerinin yine o sınıfa ait tüm test verisi sayısına bölünmesi ile elde edilmektedir. κ katsayısı iki değişken arasındaki uyumu temsil eden $[0,1]$ aralığında bir değerdir. Bu değer 0 olduğunda iki değişkenin uyumsuz olduğunu gösterirken değer 1 olması uyumlu olduğunu göstermektedir. Parametrik olmayan bir istatistik yöntemi olduğundan yüzdesel orantı uyumalarına göre daha güvenli bir katsayıdır. Bu çalışmada ise κ , bulunan test verisi sonuçlarının gerçek verilerle olan uyumluluğunun oranını istatistiksel olarak göstermektedir.



Şekil 5. Veri kümeleri üzerinde sınıflandırma için önerilen akış diyagramı (Proposed flowchart for classification on datasets)

Tablo 3. Pavia Üniversitesi veri kümesi için deneysel sonuçlar (Experimental results for the Pavia University dataset)

	SLIC	Hyper SLIC	SLIC DBCAN	Hyper-SLIC DBCAN
Genel Doğruluk(%)	86,85	87,07	90,86	96,66
κ	0,8329	0,8355	0,8797	0,9559
Asfalt	92,8	93,9	57,8	94,3
Çim	77,1	77,6	97,4	98,8
Çakıl	77,8	70,4	95,8	98,6
Ağaç	93,9	94,1	87,4	80,9
Tabaka (metal)	98,5	99,1	99,6	98,5
Boş toprak	100	100	100	100
Zift	92,8	99,3	98,3	93,7
Tuğla	98,3	98,3	99,7	98,3
Gölge	95,6	94,4	88,2	95,6

Tablo 4. Indian Pines veri kümesi için deneysel sonuçlar (Experimental results for the Indian Pines dataset)

	SLIC	Hyper SLIC	SLIC DBSCAN	Hyper-SLIC DBSCAN
Genel Doğruluk(%)	89,06	91,50	89,16	97,26
κ	0,8782	0,9052	0,8793	0,9694
Yonca	87,5	100	75	100
Mısır – işlenmemiş toprak	86,26	91,6	89,31	96,95
Mısır – az işlenmiş toprak	90,14	90,14	94,37	97,18
Mısır	89,19	89,19	86,48	100
Çayır / otlak	82,35	88,24	88,24	96,07
Çayır / ağaç	83,1	92,96	91,55	98,59
Çayır / biçilmiş otlak	100	91,67	100	100
Saman	89,1	89,1	92,73	100
Yulaf	88,89	100	77,78	100
Soya fasulyesi – işlenmemiş toprak	90,91	93,18	88,64	97,73
Soya fasulyesi – az işlenmiş toprak	89,64	90,1	85,59	96,85
Soya fasulyesi	88,06	88,06	89,55	95,52
Buğday	93,34	96,67	93,34	96,67
Ormanlık alan	93,34	92,5	90	96,67
Binalar-çayır-ağaç	87,80	97,56	92,68	95,12
Taş-çelik kuleler	100	100	81,82	100

Tablo 3 ve Tablo 4 incelendiğinde; hiperspektrale özgün düzenlenmiş olan Hyper-SLIC algoritması SLIC algoritmasına göre, Hyper-SLIC-DBSCAN algoritması ise SLIC-DBSCAN algoritmasına göre daha iyi sonuçlar verdiği görülmektedir. SLIC ve SLIC-DBSCAN sütunları SLIC bölütleme algoritmasının literatürde kullanıldığı gibi üç bant olacak şekilde boyut indirgeme yapılarak kullanıldığı durumu temsil etmektedir. SLIC algoritması CIELab uzayında daha anlamlı çalıştığından, hiperspektral görüntülerin üç banda indirgenmesi ve CIELab uzayına dönüştürülmesi bilgi kaybına sebep olabilmektedir. Bu durumun bir diğer sebebi; RGB uzayından CIELab uzayına dönüştürme işleminde önce XYZ uzayına dönüştürme işlemi yapılmaktadır. Dolayısıyla yüzlerce banttan oluşan hiperspektral görüntü; temel bileşenler analizi ile üç banda indirgindikten sonra, önce XYZ uzayına, sonra CIELab uzayına çevrilmektedir. Her ne kadar temsil uzayı değişse de veriler ayırt edici özelliklerinden kayıplar ortaya çıkmaktadır.

Tablolarda dikkat çeken bir diğer kısım; DBSCAN algoritması ile birleştirilen süperpiksel yaklaşımlarının daha yüksek sonuç vermesidir. Bu durum sınıflandırma haritalarının başarımlarının düşük olmasından kaynaklanmaktadır. Sınıflandırma haritaları sadece spektral imzaya göre elde edildiğinden ve eğitim verisinin az olmasından kaynaklı sorunlardan ötürü başarımları düşük, gürültüsü yüksek haritalardır. Süperpikseller küçük bölgeleri temsil ettiklerinden; çoğulcu oylama yönteminde gürültüler sonuca baskın etkide bulunabilmektedirler. Bu karşın, DBSCAN algoritması ile birleştirilen süperpikseller daha büyük bölgeler oluşturduklarından; gürültülerin etkileri azalmış olmakta ve çoğulcu oylama yöntemi daha etkin sonuçlar vermektedir.

4. Simgeler (Symbols)

C_k	: k numaralı kümenin merkezi
d	: görüntüdeki bant sayısı
m	: normalizasyon parametresi
p_{ik}	: i numaralı pikselin k numaralı banttaki değeri
S	: Başlangıç ızgara boyutu
\bar{x}	: x vektörünün ortalaması
σ_x	: x vektörünün standart sapması
σ_{xy}	: x ve y vektörlerinin kovaryansı
σ_x^2	: x vektörünün varyansı
κ	: kappa katsayısı

5. Sonuçlar (Conclusions)

SLIC bölütleme algoritmasının üç bant içeren görüntüleri girdi olarak alması ve hiperspektral görüntülerin yüzlerce banttan oluşmasından kaynaklı bant indirgeme maliyetlerinin ortaya çıkması SLIC algoritmasının hiperspektral görüntüleri uygun çalışacak şekilde düzenlenmesi ihtiyacı bu çalışmanın ana motivasyonunu oluşturmaktadır. Hiperspektral görüntülerin üç banda indirgeme kayıpları olmadan değiştirilmiş SLIC (Hyper-SLIC) algoritması kullanılarak yapılan sınıflandırma çalışmalarının başarımları, üç banda indirgenerek geleneksel SLIC algoritması ile yapılan sınıflandırma çalışmasından daha yüksek çıkmıştır. Pavia Üniversitesi veri kümesi için, %86,85'te kalan geleneksel SLIC yaklaşımından, önce hiperspektrale özgü değişimler ile %87,07'ye ardından bölütleme temsil kabiliyeti artırılarak %96,66'ya ulaşan başarımlar elde edilmiştir. Benzer şekilde Indian Pines veri kümesi için %89,06'da kalan geleneksel yaklaşımdan %97,26'ya ulaşan başarımlar elde edilmiştir. Hatta Indian Pines veri kümesinde SLIC ve SLIC-DBSCAN algoritmaları arasında yüksek bir başarımlar farkı yokken, hiperspektrale özel düzenlendiklerinde başarımlarda önemli bir artış gözükülmektedir. Böylece süperpiksel bölütleme yaklaşımları hiperspektral görüntülerin sınıflandırılmasında daha anlamlı şekilde kullanılabileceği gösterilmiştir.

Yapılan çalışmada sunulan tablolar incelendiğinde; hiperspektrale özgün düzenlenmiş olan Hyper-SLIC algoritmasının SLIC algoritmasına göre, Hyper-SLIC-DBSCAN algoritmasının ise SLIC-DBSCAN algoritmasına göre daha iyi sonuçlar verdiği görülmektedir. SLIC algoritması CIELab uzayında daha anlamlı çalıştığından, hiperspektral görüntülerin üç banda indirgenmesi bilgi kaybına sebep olabilmektedir. Bu durumun bir diğer sebebi; RGB uzayından CIELab uzayına dönüştürme işleminde önce XYZ uzayına dönüştürme işlemi yapılmaktadır. Dolayısıyla yüzlerce banttan oluşan hiperspektral görüntü; temel bileşenler analizi ile üç banda indirgindikten sonra, önce XYZ uzayına, sonra CIELab uzayına çevrilmektedir. Her ne kadar temsil uzayı değişse de verilerin ayırt edici özelliklerinden kayıplar ortaya çıkmaktadır. Tablolarda dikkat çeken bir diğer kısım; DBSCAN algoritması ile birleştirilen süperpiksel yaklaşımlarının daha yüksek sonuç vermesidir. Bu durum sınıflandırma haritalarının başarımlarının düşük olmasından kaynaklanmaktadır. Sınıflandırma haritaları sadece spektral imzaya göre elde edildiğinden ve eğitim

verisinin az olmasından kaynaklı sorunlardan ötürü başarımı düşük, gürültüsü yüksek haritalardır. Süperpikseller küçük bölgeleri temsil ettiklerinden; çoğulcu oylama yönteminde gürültüler sonuca baskın etkide bulunabilmektedirler. Bu karşın, DBSCAN algoritması ile birleştirilen süperpikseller daha büyük bölgeler oluşturduklarından; gürültülerin etkileri azalmış olmakta ve çoğulcu oylama yöntemi daha etkin sonuçlar vermektedir.

Sınıf bazlı sonuçlar irdelendiğinde; eğitim verilerinin az olduğu sınıflarda başarımların daha düşük olduğu gözlemlenmektedir; ancak Pavia Üniversitesi veri kümesinde yer alan Asfalt sınıfı SLIC-DBSCAN algoritmasında daha düşük başarımla tespit edilmiştir. Bu durum görüntüdeki asfaltın ince uzun seritler halinde olması ve gölge sınıfı ile karışık sinyallerin olmasından kaynaklanmaktadır. Piksel başına düşen alanın çok yüksek olduğu Indian Pines veri setinde, toprağın işlenmemiş, işlenmiş ve yalın hallerinde yer alan mısır ve fasulyeler homojen ve yüksek başarımla ayırt edilebilmiştir. Çayır başlığı ile belirtilen otlak, ağaç ve biçilmiş otlak sınıfları da Hyper-SLIC-DBSCAN algoritması ile başarılı şekilde tespit edilmektedir.

Sonraki çalışmalarda, hiperspektral görüntülerin daha iyi temsil edildiği renk uzaylarının tespit edilmesi üzerine çalışılacaktır. Temsil kabiliyeti yüksek uzaylarda yapılacak süperpiksel bölütleme işlemlerinin sınıflandırma başarımına etkileri incelenecektir.

Teşekkür (Acknowledgement)

Bu çalışma Yıldız Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü Bölümü tarafından, 2014-04-01-KAP01 proje numarası ile desteklenmiştir.

Kaynaklar (References)

1. J. Ham, Y. Chen, M. M. Crawford, and J. Ghosh, Investigation of the random forest framework for classification of hyperspectral data, *IEEE Transaction on Geoscience and Remote Sensing*, 43 (3), 492–501, 2005.
2. E. Arzuaga-Cruz, L. O. Jimenez-Rodríguez, and M. Velez-Reyes, Unsupervised feature extraction and band subset selection techniques based on relative entropy criteria for hyperspectral data analysis, in *Proceeding of SPIE*, 5093, 462–473, 2003.
3. S. Kawaguchi and R. Nishii, Hyperspectral image classification by bootstrap adaboost with random decision stumps, *IEEE Transaction on Geoscience and Remote Sensing*, 45 (11), 3845–3851, 2007.
4. F. Melgani and L. Bruzzone, Classification of hyperspectral remote sensing images with support vector machines, *IEEE Transaction on Geoscience and Remote Sensing*, 42 (8), 1778–1790, 2004.
5. J. Li, J. M. Bioucas-Dias, and A. Plaza, Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning, *IEEE Transaction on Geoscience and Remote Sensing*, 51(2), 844–856, 2013.
6. G. Camps-Valls and L. Bruzzone, Kernel-based methods for hyperspectral image classification, *IEEE Transaction on Geoscience and Remote Sensing*, 43 (6), 1351–1362, 2005.
7. Hanbay K., Hyperspectral image classification using convolutional neural network and twodimensional complex Gabor transform, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (1), 443–456, 2019.
8. Hong, D., Gao, L., Yao, J., Zhang, B., Plaza, A., Chanussot, J, Graph convolutional networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2020.
9. Y. Tarabalka, J. Chanussot, and J. A. Benediktsson, Classification based marker selection for watershed transform of hyperspectral images, in *IEEE International on Geoscience and Remote Sensing Symposium, IGARSS'09*, 3, III–105, 2009.
10. B. Fulkerson, A. Vedaldi, and S. Soatto, Class segmentation and object localization with superpixel neighborhoods, in *IEEE 12th International Conference on Computer Vision (ICCV)*, 670–677, 2009.
11. K.-Y. Chang, T.-L. Liu, H.-T. Chen, and S.-H. Lai, Fusing generic objectness and visual saliency for salient object detection, in *IEEE International Conference on Computer Vision (ICCV)*, 914–921, 2011.
12. S. Wang, H. Lu, F. Yang, and M.-H. Yang, Superpixel tracking, in *IEEE International Conference on Computer Vision (ICCV)*, 1323–1330, 2011.
13. Karaca A, Güllü M., Detection of forest fire in Menderes district using a superpixel segmentation based search method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (2), 1061–1076, 2019.
14. Felzenszwalb, P.F., & Huttenlocher, D.P., Efficient graph-based image segmentation. *International journal of computer vision*, 59 (2), 167–181, 2004.
15. Vedaldi, A., & Soatto, S., Quick shift and kernel methods for mode seeking. In *European conference on computer vision*, Springer, Berlin, Heidelberg, 705–718, October 2008.
16. R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, Slic superpixels compared to state-of-the-art superpixel methods, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 34, 2274–2282, 2012.
17. Huang, W., Huang, Y., Wang, H., Liu, Y., & Shim, H. J., Local binary patterns and superpixel-based multiple kernels for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 4550–4563, 2020.
18. Zhang, Y., Jiang, X., Wang, X., Cai, Z., Spectral-spatial hyperspectral image classification with superpixel pattern and extreme learning machine. *Remote Sensing*, 11 (17), 1983, 2019.
19. L. Fang, S. Li, W. Duan, J. Ren, and J. A. Benediktsson, Classification of hyperspectral images by exploiting spectral-spatial information of superpixel via multiple kernels, *IEEE Transaction on Geoscience and Remote Sensing*, 53(12), 6663–6674, 2015.
20. Zhang, Y., Liu, K., Dong, Y., Wu, K., & Hu, X. (2019). Semisupervised classification based on SLIC segmentation for hyperspectral image. *IEEE Geoscience and Remote Sensing Letters*, 17 (8), 1440–1444.
21. Zhang, X., Chew, S. E., Xu, Z., & Cahill, N. D., SLIC superpixels for efficient graph-based dimensionality reduction of hyperspectral imagery. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXI*, International Society for Optics and Photonics, 705–718, May 2015.
22. Zhao, P., Zhou, S., Yang, Y., & Hu, Y., Classification method of hyperspectral remote sensing image based on SLIC and active learning. *Computer Engineering & Applications*, 3, 2017.
23. M. Ester, H.-P. Kriegel, J. Sander, X. Xu, et al., A density-based algorithm for discovering clusters in large spatial databases with noise., in *KDD*, 96, 226–231, 1996.
24. Zhang, F., Li, Z., Qu, X., & Zhang, X., Inverse halftoning algorithm based on slic superpixels and dbscan clustering. In *International Conference on Intelligent Computing*, Springer, Cham., 466–471, August 2018.
25. Albayrak, A., & Bilgin, G. (2019). Automatic cell segmentation in histopathological images via two-staged superpixel-based algorithms. *Medical & biological engineering & computing*, 57 (3), 653–665.
26. Hu, H., Liu, B., Guo, W., Zhang, Z., & Yu, W., Superpixel generation for SAR images based on DBSCAN clustering and probabilistic patch-based similarity. In *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE, 803–806, July, 2017.
27. Z. Wang and A. C. Bovik, A universal image quality index, *IEEE Signal Processing Letters*, 9 (3), 81–84, 2002.
28. J. Wang and C.-I. Chang, Independent component analysis-based dimensionality reduction with applications in hyperspectral image anal., *IEEE Transaction on Geoscience and Remote Sensing*, 44 (6), 1586–1600, 2006.
29. Dell'Acqua, F., Gamba, P., & Ferrari, A., Exploiting spectral and spatial information for classifying hyperspectral data in urban areas. In *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No. 03CH37477)*, IEEE., 1, 464–466, July 2003.
30. Benediktsson, J. A., Palmason, J. A., & Sveinsson, J. R., Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43 (3), 480–491, 2005.
31. Landgrebe, D. A., *Signal theory methods in multispectral remote sensing*, John Wiley & Sons, 24, 2003.

