

Spektral Eşleştirme Yöntemleri Kullanarak Hiperspektral Görüntülerin Seyrek Gösterim Tabanlı Sınıflandırılması

Tuğcan DÜNDAR^{1*}, Taner İNCE²

¹Gaziantep Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Gaziantep
(dundar@gantep.edu.tr) ORCID ID 0000 – 0003 – 1374 – 8651

² Gaziantep Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Gaziantep
(tanerince@gantep.edu.tr) ORCID ID 0000 – 0003 – 1757 – 5209

Öz

Seyrek gösterim tabanlı yaklaşımlar sinyal ve görüntü işleme alanlarında gösterdikleri performanstan dolayı son zamanlarda hiperspektral görüntüler üzerine de uygulanmaya başlanmış ve başarılı sonuçlar sağlanmıştır. Hiperspektral görüntü içerisindeki uzamsal bilginin de sınıflandırma işlemine dahil edilebilmesi için ortak seyrek gösterim sınıflandırıcı (OSGS) modeli geliştirilmiştir. Fakat bu modelde test pikseli etrafındaki sabit boyutlu bir pencere içerisindeki tüm komşu piksellerin ağırlık oranlarının eşit olduğu varsayılmaktadır. Özellikle de pencere boyutu arttıkça farklı sınıfa ait piksellerin sınıflandırma işlemine dahil olacağı düşünülürse hata payı artacaktır. Bu soruna bir çözüm üretebilmek için pencere içerisindeki merkez test pikseli ve her bir komşu piksele 3 adet spektral eşleştirme yöntemi uygulayıp OSGS ile birleştiren 3SE-OSGS metodu önerilmiştir. Eşleştirme yöntemlerinden elde edilen verilere ve eşik değerine göre ilgili komşu pikselin seçilmesi veya seçilmemesi sağlanmıştır.

Anahtar Kelimeler: seyrek gösterim, spektral eşleştirme, hiperspektral görüntü, sınıflandırma.

Sparse Representation-Based Classification of Hyperspectral Images Using Spectral Matching Methods

Abstract

Sparse representation based approaches have recently begun to be applied to hyperspectral images due to the performance displayed in areas such as signal and image processing and successful results have been achieved. The joint sparse representation classifier (JSRC) model has been developed so that spatial information in the hyperspectral image can be included in the classification process. However, it is assumed that the weight ratios of all neighboring pixels in a fixed size window around the test pixel are equal in this model. Particularly, as the window size increases, the error rate will increase if it is considered that the pixels belonging to different classes will be included in the classification process. In order to solve this problem, 3SM-JSRC method utilizing 3 spectral matching methods to central test pixel and each neighbor pixel in the window and combines with JSRC is proposed. It is provided that the neighboring pixel is selected or not selected according to the data obtained from the matching methods and the threshold value.

Keywords: sparse representation, spectral matching, hyperspectral image, classification.

* Sorumlu Yazar

1. GİRİŞ

Hiperspektral görüntüler birbirine bitişik olarak konumlandırılmış çok sayıda spektral banttan oluşmaktadır (Christophe, Leger ve Mailhes, 2005). Görüntü içerisindeki spektral bilginin oldukça fazla olması yeryüzündeki materyallerin tespitine ve sınıflandırılmasına olanak sağlamaktadır. Bu sebeple de askeri, tarım ve mineraloji gibi uygulama alanlarında sıklıkla kullanılmaktadır (Datt, McVicar, Niel, Jupp ve Pearlman, 2003; Garcia ve Ustin, 2001; Manolakis ve Shaw, 2002; Shukla ve Kot, 2016). Hiperspektral görüntü sınıflandırma işlemindeki amaç verilen bir test pikselini sınıflandırma metotları yardımı ile ait olduğu doğru sınıfa atamaktır. Bu amaçla önerilen ilk çalışmalarda hiperspektral görüntüdeki spektral bilgi kullanılarak destek vektör makinaları tabanlı metotlar (Bruzzone, Chi ve Marconcini, 2006; Chi ve Bruzzone, 2007; Melgani ve Bruzzone, 2004), rastgele ormanlar (Dalponte, Örka, Gobakken, Gianelle ve Næsset, 2013; Ham, Chen, Crawford ve Ghosh, 2005) ve k en yakın komşuluk (Ma, Crawford ve Tian, 2010), yapay sinir ağları (Ratle, Camps-Valls ve Weston, 2010; Zhong ve Zhang, 2012), lojistik regresyon (J. Li, Bioucas-Dias ve Plaza, 2012, 2013), genetik algoritma (Stavroudis, Galidaki, Gıtas ve Theocharis, 2012) ve karar ağaçları (Goel vd., 2003) gibi yöntemler sayesinde sınıflandırma işlemi yapılmıştır.

Son zamanlarda, seyrek gösterim tabanlı sınıflandırma modelleri hiperspektral görüntüler için önerilmiştir. Chen vd. tarafından spektral bilgiyi kullanan seyrek gösterim sınıflandırıcısı (Sparse Representation Classifier – SRC) (Chen, Nasrabadi ve Tran, 2011) önerilmiştir. SRC modelinde bir hiperspektral test pikselinin tüm sınıflara ait eğitim örneklerinden oluşan eğitim sözlüğü içerisinde sadece birkaç eğitim örneği ile temsil edilebileceği önerilmektedir. Ayrıca, görüntü içerisindeki uzamsal bilginin yani piksellerin komşuluk bilgilerinin sınıflandırma işlemine dahil edildiği ortak seyrek gösterim sınıflandırıcı (Joint Sparse Representation Classifier – JSRC) (Chen vd., 2011) modeli de yine Chen vd. tarafından aynı çalışmada sunulmuştur. JSRC modelinde pencere içerisindeki merkez

test pikseli etrafındaki piksellerin hepsinin de aynı sınıfa ait olduğu varsayılır ve sınıflandırma işlemi yapılır.

Sonraki yıllarda JSRC yönteminin sağladığı sınıflandırma doğruluk sonuçlarında artış sağlayabilmek için birçok çalışma yapılmıştır (Dundar ve Ince, 2019; Fang, Li, Kang ve Benediktsson, 2014, 2015; W. Li ve Du, 2014; Sun, Qu, Nasrabadi ve Tran, 2014; Tu vd., 2018). (Tu vd., 2018)'de önerilen CCJSR (Correlation Coefficient – Joint Sparse Representation) çalışmasında test pikselinin sınıfını belirlerken hesaplanan artık değere test pikseli ile eğitim örnekleri arasındaki benzerlik korelasyon katsayısı yardımı ile eklenmiştir. (Fang vd., 2014)'daki MASR (Multiscale Adaptive Sparse Representation) metodunda test pikseli etrafında tek bir pencere oluşturmak yerine farklı boyutlarda pencereler oluşturularak uzamsal bilginin daha fazla kullanılması amaçlanmıştır. (Fang vd., 2015)'da önerilen SBDSM (Superpixel-Based Discriminative Sparse Model) yöntemi sayesinde sabit boyutlu pencere yerine uzamsal bilgiye göre şekil ve boyut değiştiren süperpikseller test pikseli etrafında oluşturulmuştur ve uzamsal bilgi daha verimli kullanılmıştır. Test örneği etrafında tek bir süperpiksel yerine farklı ölçeklerde süperpikseller oluşturan ve sınıflandırma sonuçlarına rehberli filtreyi ekleyerek uzamsal bilginin daha da verimli kullanılmasını sağlayan yöntem MSS–GF (Multi Scale Superpixels–Guided Filter) ise (Dundar ve Ince, 2019)'de önerilmiştir. (Sun vd., 2014)'de ise sınıflandırma problemine bazı seyreklik temelli sınırlandırmalar getirilerek sınıflandırma sonuçlarında artış sağlanması amaçlanmıştır. (W. Li ve Du, 2014)'de yapılan çalışmada komşuluk bilgilerini ve test pikseli ile eğitim örnekleri arasındaki benzerlikleri sınıflandırma yöntemine dahil eden JCR (Joint Collaborative Representation) metodu önerilmiştir.

JSRC yönteminde özellikle de pencere boyutu arttıkça farklı sınıflara ait pikseller de pencere içerisine girecektir. Herhangi bir seçim yöntemi de olmadığı için bu durum sınıflandırma sonuçları üzerinde olumsuz bir etki oluşturabilir. Zhang vd. test pikseli ile komşu piksellerin benzerliğine göre piksellere farklı ağırlıklar atayan NLW–JSRC (Non-Local Weighted–Joint Sparse Representation

Classifier) modelini (Zhang, Li, Huang ve Zhang, 2014) geliştirmişlerdir. Bu sayede test pikseline benzer piksellerin ağırlığı sınıflandırma işleminde fazla olurken, farklı karakteristiğe sahip komşu piksellerin ağırlığı düşük ya da sıfır olabilmektedir. Sonuç olarak da sınıflandırma doğruluklarının JSRC modeline göre daha iyi olduğu gözlemlenmiştir.

Bu çalışmada, sınıflandırma aşamasında test pikseli ile birlikte hangi komşu piksellerin seçileceğine veya seçilmeyeceğine karar verebilmek için Öklit Uzaklığı, Spektral Açık Haritalama ve Pearson Korelasyon Katsayısı spektral eşleştirme yöntemleri ortak bir şekilde kullanılmıştır. Bu yöntemler birbirlerine benzer hiperspektral bantların seçimi ve sınıflandırma çalışmalarında kullanılmaktadır (Keshava, 2004; Tu vd., 2018; Yan, Cui ve Prasad, 2018). Eşleştirme metodları, test pikseli ile sırasıyla tüm komşu piksellere uygulanarak eşik değerine göre ilgili komşu pikselin seçilmesi veya seçilmemesi sağlanmıştır.

Makalenin 2. bölümünde seyrek gösterim ve ortak seyrek gösterim tabanlı sınıflandırıcılar anlatılmıştır. 3. bölümde, ortak seyrek gösterim tabanlı sınıflandırıcının performansını arttırmak için kullanılan spektral eşleştirme metodları verilmiştir. 4. bölümde önerilen metodun teorik altyapısı ve formülasyonu sunulmuştur. Deneysel kurulum ve deney sonuçları 5 bölümde verilmiştir. Son olarak bölüm 6 ise sonuç kısmıdır.

2. YÖNTEM

Bu bölümde sırası ile seyrek gösterim ve ortak seyrek gösterim tabanlı sınıflandırıcıların teorik alt yapısı anlatılmaktadır.

2.1. Seyrek Gösterim Tabanlı Sınıflandırıcı

Hiperspektral görüntü içerisindeki bir piksel \mathbf{p} , görüntünün sahip olduğu bant sayısı B uzunluğundaki bir vektör olarak tanımlanır ve $\mathbf{p} \in R^{B \times 1}$ ile ifade edilir. Tüm sınıflara ait eğitim örneklerinden oluşan sözlük matrisi ise $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_M] \in R^{B \times N}$ ile gösterilir. Burada M toplam sınıf sayısını ve N toplam eğitim örneği sayısını temsil etmektedir. Seyrek gösterim tabanlı sınıflandırma modelinde bir test pikselinin sözlük matrisi

içerisindeki eğitim örneklerinden yalnızca birkaçı ile temsil edilebileceği varsayıldığı için bu durum

$$\mathbf{p} = \mathbf{D}\boldsymbol{\alpha} + \mathbf{n} \quad (1)$$

eşitliği ile gösterilebilir. Denklem (1)'de $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_M]^T \in R^{M \times 1}$ seyrek katsayı vektörünü ve \mathbf{n} ise görüntü içerisinde olabilecek bazı gürültüleri temsil etmektedir. Seyrek gösterim tabanlı yaklaşımlarda amaç seyrek katsayı vektörünü hesaplayarak geri çatlınmış test pikselini bulmaktır. Seyrek katsayı vektörünü bulmak için

$$\hat{\boldsymbol{\alpha}} = \underset{\boldsymbol{\alpha}}{\operatorname{argmin}} \|\mathbf{p} - \mathbf{D}\boldsymbol{\alpha}\|_2 \quad \text{öyle ki} \quad \|\boldsymbol{\alpha}\|_0 \leq L \quad (2)$$

denklem (2)'deki optimizasyon problemi çözümlidir. Burada $\|\cdot\|_0$ normu $\boldsymbol{\alpha}$ içerisindeki sıfır olmayan katsayıları sayar ve L ise seyreklik seviyesinin üst sınırını yani seyrek katsayı vektörü $\hat{\boldsymbol{\alpha}}$ içerisindeki sıfır olmayan katsayıları temsil eder. (2) nolu problemin çözümü için literatürdeki Dik Eşleştirme Arayış (Orthogonal Matching Pursuit – OMP) (Tropp ve Gilbert, 2007) algoritması kullanılabilir.

Seyrek katsayı vektörü bulunduktan sonra test pikseli \mathbf{p} 'nin ait olduğu sınıfı bulmak için \mathbf{p} ile sözlük matrisi \mathbf{D} ve seyrek katsayı vektörü $\hat{\boldsymbol{\alpha}}$ kullanılarak artık değer

$$E_m(\mathbf{p}) = \|\mathbf{p} - \mathbf{D}_m \hat{\boldsymbol{\alpha}}_m\|_2, \quad m = 1, 2, \dots, M \quad (3)$$

denklem (3)'teki gibi her sınıfa ait eğitim örnekleri için hesaplanır. Son olarak test pikseli \mathbf{p} 'nin sınıfı ise artık değer minimum olduğu eğitim örneğinin sınıfı olarak (4)'teki gibi belirlenir.

$$\hat{m} = \underset{m}{\operatorname{argmin}}(E_m) \quad (4)$$

2.2. Ortak Seyrek Gösterim Tabanlı Sınıflandırıcı

Seyrek gösterim tabanlı sınıflandırıcı (Sparse Representation based Classifier – SRC) modelinde piksellerin spektral bilgisi kullanılarak sınıflandırma işlemi yapılmaktadır. Ortak seyrek gösterim tabanlı sınıflandırıcı (Joint Sparse Representation Classifier – JSRC) modelinde ise görüntü içerisindeki spektral bilgiye ek olarak uzamsal bilgi de kullanılır. Yapılan bir çalışmada test

pikselli etrafında sabit boyutlu bir pencere oluşturularak komşu piksellerin de aynı sınıfa ait olacağı fikri ile tüm pikseller ortak bir şekilde sınıflandırılmıştır (Chen ve diğerleri, 2011). Test pikseli \mathbf{p}_1 'in $K = Q \times Q$ boyutlu kare bir penceredeki komşulukları $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{Q \times Q}]$ ile gösterilebilir. SRC modelinde bir test pikseli için (1)'de uygulanan denklem test pikseli ile komşu piksellerin birleşiminden oluşan \mathbf{P} matrisi için

$$\mathbf{P} = \mathbf{D}\mathbf{A} + \mathbf{N} \quad (5)$$

ile ifade edilebilir. Denklem (5)'te $\mathbf{A} = [\alpha_1, \alpha_2, \dots, \alpha_{Q \times Q}] \in \mathbb{R}^{N \times K}$ seyrek katsayı matrisini ve \mathbf{N} ise gürültüleri temsil eder. \mathbf{A} matrisini bulmak için

$$\hat{\mathbf{A}} = \underset{\mathbf{A}}{\operatorname{argmin}} \|\mathbf{P} - \mathbf{D}\mathbf{A}\|_F \quad \text{öyle ki} \quad \|\mathbf{A}\|_0 \leq L \quad (6)$$

denklem (6)'daki problem çözümlenmelidir. Çözüm için Eşzamanlı Dik Eşleştirme Arayış (Simultaneous Orthogonal Matching Pursuit – SOMP) (Chen ve diğerleri, 2011) algoritması kullanılabilir. $\hat{\mathbf{A}}$ matrisi bulunduktan sonra artık değer

$$E_m(\mathbf{P}) = \|\mathbf{P} - \mathbf{D}_m \hat{\mathbf{A}}_m\|_F, \quad m = 1, 2, \dots, M \quad (7)$$

(7) numaralı denklem yardımı ile her sınıfa ait eğitim örnekleri için hesaplanır. Son olarak pencere içerisindeki piksellerin sınıfı \hat{m} ise minimum artık değer kullanılarak (8) ile bulunur.

$$\hat{m} = \underset{m}{\operatorname{argmin}}(E_m) \quad (8)$$

2.3. Spektral Eşleştirme Metotları

Bu bölümde ortak seyrek gösterim tabanlı sınıflandırıcı modelinin geliştirilmesinde kullanılan Öklit Uzaklığı, Spektral Açık Haritalama ve Pearson Korelasyon Katsayısı metotları açıklanmış ve ilgili formüller verilmiştir.

2.3.1. Öklit uzaklığı

B boyutlu bir uzayda X ve Y vektörleri arasındaki uzaklığı belirlemek için Öklit Uzaklığı (Euclidean Distance – ED) kullanılmaktadır. Uzaklık değerinin küçük olması iki vektörün birbirine olan yakınlığını ifade etmektedir. Öklit uzaklığı

$$ED(X, Y) = \sqrt{\sum_{i=1}^B (X_i - Y_i)^2} \quad (9)$$

(9)'daki formül yardımı ile hesaplanabilir.

2.3.2. Spektral açı haritalama

Spektral Açık Haritalama (Spectral Angle Mapper – SAM) yöntemi sayesinde B boyutlu bir spektral uzayda X ve Y vektörleri arasındaki açı hesaplanabilir. Açık değerinin küçük olması iki vektörün benzer olduğunu göstermektedir. SAM değeri takip eden denklem yardımı ile hesaplanabilir.

$$SAM(X, Y) = \cos^{-1} \left(\frac{\sum_{i=1}^B X_i Y_i}{\sqrt{\sum_{i=1}^B X_i^2} \sqrt{\sum_{i=1}^B Y_i^2}} \right) \quad (10)$$

2.3.3. Pearson korelasyon katsayısı

Pearson Korelasyon Katsayısı (Pearson Correlation Coefficient – PCC) da SAM yöntemi gibi iki vektörün benzerliğini gösterir ve -1 ile 1 arasında bir değerdir. Değerin -1'e yakın olması iki vektörün benzer olduğunu fakat zıt yönde olduğunu belirtir. Tam tersi durumda yani değer 1'e yakın olması ise iki vektörün benzer olduğunu ve aynı yönde olduğunu belirtir. Bu sebeple eğer B boyutlu bir uzayda X ve Y vektörleri birbirlerine benzer ise mutlak değer 1'e yakın olmaktadır. Tam tersi durumda ise bu değer 0'a yakın olmaktadır.

$$PCC(X, Y) = \frac{\sum_{i=1}^B (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^B (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^B (Y_i - \bar{Y})^2}} \quad (11)$$

(11)

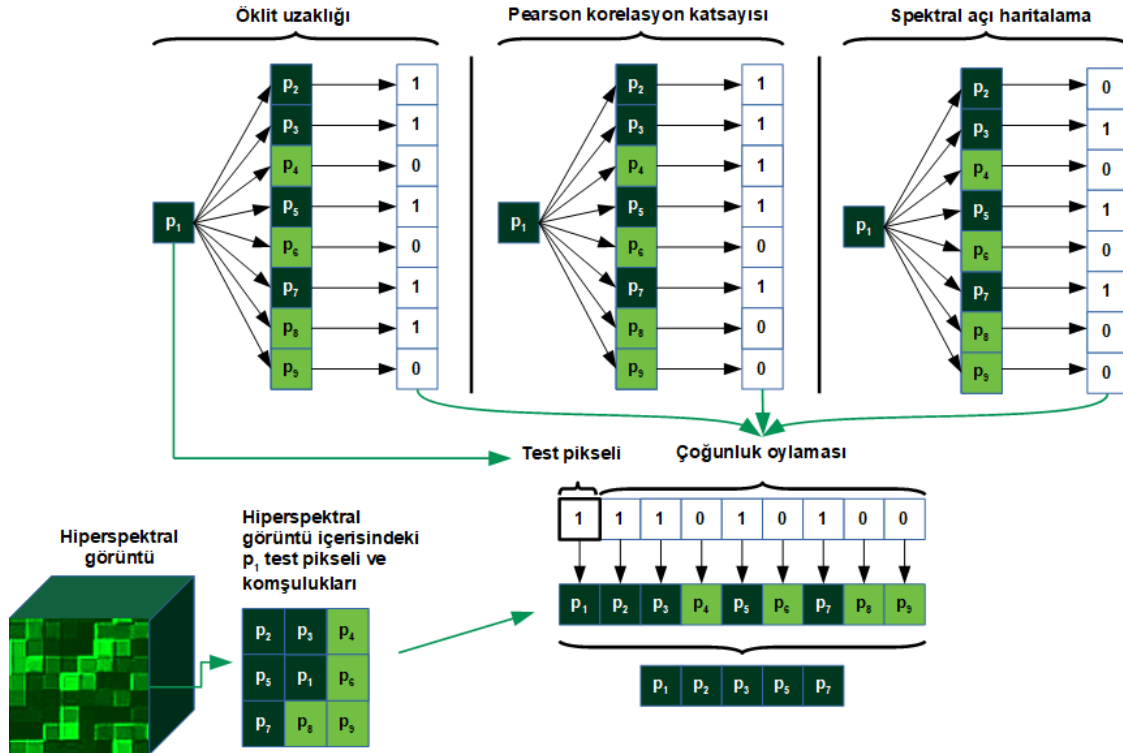
Denklem (11)'de $\bar{X} = \left(\frac{1}{B} \sum_{i=1}^B X_i \right)$ ve

$\bar{Y} = \left(\frac{1}{B} \sum_{i=1}^B Y_i \right)$ sırasıyla X ve Y vektörlerinin

ortalama değerlerini temsil etmektedir.

2.4. Problem Formülasyonu

Pencere içerisindeki pikseller \mathbf{p}_1 test pikseli olmak koşulu ile $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{Q \times Q}]$ matrisi



Şekil 1. Test Pikseli Etrafında 3×3 Boyutunda Oluşturulan Pencere İçerisindeki Komşu Piksellerin Öklit Uzaklığı, Pearson Korelasyon Katsayısı ve Spektral Açık Haritalama Yöntemleri ile Seçilmesi

ile gösterilir. p_1 pikseli sırası ile pencere içerisindeki tüm komşu pikseller ile ED , SAM ve PCC yöntemlerine tabi tutulur. Bu durumu

$$ED_j = ED(p_1, p_j) \quad j = 2, 3, \dots, Q \times Q \quad (12)$$

$$SAM_j = SAM(p_1, p_j) \quad j = 2, 3, \dots, Q \times Q \quad (13)$$

$$PCC_j = PCC(p_1, p_j) \quad j = 2, 3, \dots, Q \times Q \quad (14)$$

Denklem (12), (13) ve (14)'teki gibi gösterebiliriz. Bu değerler tüm pikseller için bulunduktan sonra değerlerin ortalaması (15), (16) ve (17) numaralı denklemler aracılığı ile hesaplanır.

$$\overline{ED} = \frac{1}{(Q \times Q) - 1} \sum_{j=2}^{Q \times Q} ED_j \quad (15)$$

$$\overline{SAM} = \frac{1}{(Q \times Q) - 1} \sum_{j=2}^{Q \times Q} SAM_j \quad (16)$$

$$\overline{PCC} = \frac{1}{(Q \times Q) - 1} \sum_{j=2}^{Q \times Q} PCC_j \quad (17)$$

Ortalama değerler de bulunduktan sonra test pikseli ve ilgili komşu piksel için hesaplanan spektral eşleştirme metodlarının eşik değeri

olarak belirlenen ortalama değerlerden büyük veya küçük olması durumuna göre yalnızca $[0,1]$ değerlerini alan

$$ED_{1,0} = \begin{cases} 1 & ; ED_j \geq \overline{ED} \\ 0 & ; ED_j < \overline{ED} \end{cases} \quad (18)$$

$$SAM_{1,0} = \begin{cases} 1 & ; SAM_j \geq \overline{SAM} \\ 0 & ; SAM_j < \overline{SAM} \end{cases} \quad (19)$$

$$PCC_{1,0} = \begin{cases} 1 & ; PCC_j \geq \overline{PCC} \\ 0 & ; PCC_j < \overline{PCC} \end{cases} \quad (20)$$

$ED_{1,0}$, $SAM_{1,0}$ ve $PCC_{1,0}$ vektörleri oluşturulur. Daha sonra bu üç vektör üzerine çoğunluk oylaması (Majority Voting – MV) kuralı uygulanarak 1 ve 0'lardan oluşan V vektörü oluşturulur.

$$V = MV[ED_{1,0}; SAM_{1,0}; PCC_{1,0}] \\ = [V_2 \ V_3 \ \dots \ V_{Q \times Q}] \quad ; \quad V_{j=2,3,\dots,Q \times Q} \in [0,1] \quad (21)$$

Denklem (21)'de merkez test pikseli p_1 etrafındaki komşu pikseller için seçim yapılmaktadır. p_1 pikselini de hesaba katarak ağırlık vektörü W

$$W = [1 V_2 V_3 \dots V_{Q \times Q}] \quad (22)$$

oluşturulur. Son olarak ise test pikseli p_1 ve seçilen komşu pikselleri içeren \tilde{P} matrisi

$$\tilde{P} = WP \quad (23)$$

(23) nolu denklem yardımı ile oluşturulur. Bu işlemden sonra sırasıyla (5), (6), (7) ve (8) numaralı denklemler hesaplanarak pencere içerisindeki piksellerin sınıfı belirlenir.

Merkez test pikseli etrafındaki komşu piksellerin önerilen spektral eşleştirme metotları yardımı ile seçilmesini gösteren görsel Şekil 1'de bulunmaktadır. Ayrıca önerilen metoda ait aşamalar Algoritma 1'de özetlenmiştir.

Algoritma 1: 3SM—JSRC

Giriş: Hiperspektral veri seti H ; Eğitim örneği indeksleri ; Test örneği indeksleri ; Seyreklik seviyesi L ; Pencere boyutu K ; Sınıf sayısı M

Çıkış: Test piksellerinin sınıf etiketleri

Başlatma: H 'yi [0,1] arasında normalize et ve eğitim sözlüğü matrisi D 'yi oluştur

tekrarla her bir test pikseli için

1:Merkezde test pikseli olacak şekilde P 'yi oluştur

2: $ED_{1,0}$, $SAM_{1,0}$ ve $PCC_{1,0}$ vektörlerini oluştur

3: MV uygulayarak W ağırlık vektörünü oluştur

4: W 'yi P üzerine uygula ve \tilde{P} matrisini oluştur

5: Seyrek katsayı matrisi A 'yı bul

6: Her bir sınıf için artık değer E 'yi hesapla

7: Minimum artık değere göre pikselin sınıfını belirle

sonlandır

3. BULGULAR

Bu bölümde, önerilen 3SM—JSRC metodu iki adet hiperspektral veri seti üzerinde test edilmiştir. Literatürdeki SVM (Melgani ve Bruzzone, 2004), SRC (Chen vd., 2011), JSRC (Chen vd., 2011) ve NLW—JSRC (Zhang vd., 2014) metotları ise karşılaştırma amacı ile kullanılmıştır. Bu çalışma kapsamında yapılan tüm deneyler farklı eğitim örnekleri ile 10 kez tekrarlanmıştır ve

sonuçların ortalaması alınmıştır. Elde edilen sınıflandırma sonuçlarını karşılaştırmak için

Tablo 1. Indian Pines Veri Setinde Her Sınıfa Ait Eğitim ve Test Örnekleri Sayısı

Sınıf	İsim	Eğitim	Test
1	Alfalfa	6	48
2	Corn-notill	144	1290
3	Corn-min	84	750
4	Corn	24	210
5	Grass/Pasture	50	447
6	Grass/Trees	75	672
7	Grass/Pasture-mowed	3	23
8	Hay-windrowed	49	440
9	Oats	2	18
10	Soybean-notill	97	871
11	Soybean-min	247	2221
12	Soybean-clean	62	552
13	Wheats	22	190
14	Woods	130	1164
15	Building-Grass-Tree-Drives	38	342
16	Stone-steel Towers	10	85
Toplam		1043	9323

ise bazı hesaplama metrikleri kullanılmaktadır. Bunlar sırasıyla genel doğruluk (GD), sınıf doğrulukları (SD), ortalama doğruluk (OD), ve kappa (K) değerleridir. Bu metrikler ise aşağıdaki gibi hesaplanır.

$$GD = \frac{\text{Doğru sınıflandırılan test örneği sayısı}}{\text{Toplam test örneği sayısı}}$$

$$SD = \frac{\text{Sınıfa doğru atanan test örneği sayısı}}{\text{Sınıftaki toplam test örneği sayısı}}$$

$$OD = \frac{\text{Sınıf doğruluk değerlerinin toplamı}}{\text{Toplam sınıf sayısı}}$$


$$K = \frac{GD - \text{Beklenen doğruluk değeri}}{1 - \text{Beklenen doğruluk değeri}}$$

3.1. Indian Pines

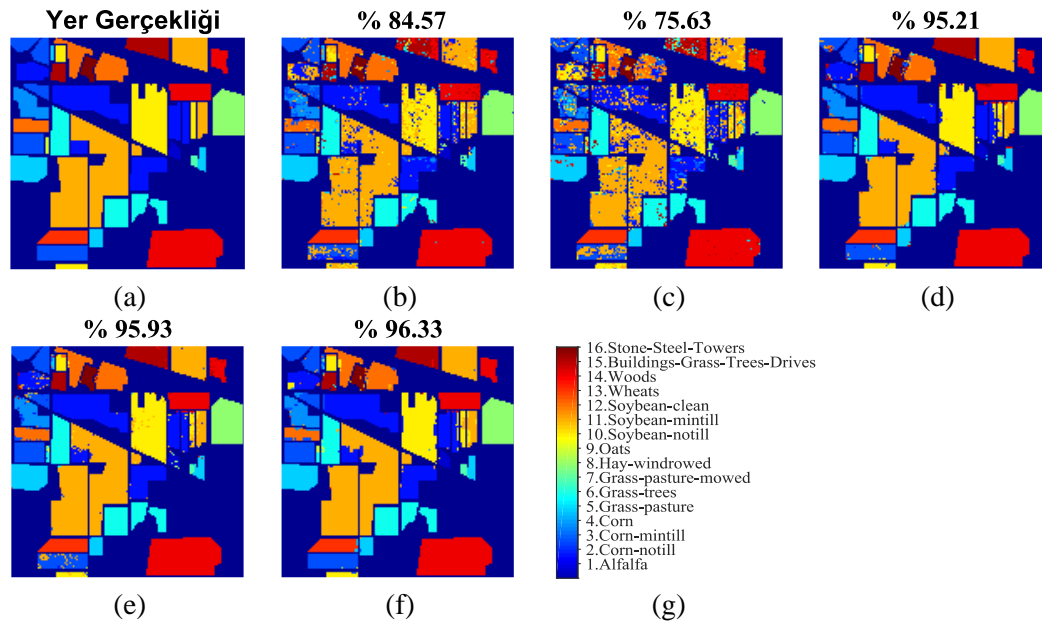
Bu veri seti Indian Pines test alanı üzerinde AVIRIS (Airborne/Visible Infrared Imaging Spectrometer) sensörü tarafından elde edilmiştir. Toplamda 224 adet spektral banttan oluşmaktadır ve bantların dalgaboyu 0.4–2.5 μm arasındadır. Su emilimi gibi sebeplerden dolayı 24 adet bant (104-108, 150-163, 220) veri setinden çıkartılmıştır (Gualtieri ve Cromp, 1999) ve dolayısıyla geriye 200 adet spektral bant kalmıştır.

Uzamsal olarak ise 145×145 adet pikselden oluşmaktadır. Çoğunluğu tarım ürünlerinden

oluşan 16 adet sınıf içermektedir. Bu veri seti ile ilgili yapılan tüm çalışmalarda her sınıftan



Şekil 2. Indian Pines Veri Setinde Farklı Pencere Boyutları ve Seyreklik Seviyeleri Kullanılarak Elde Edilen (a) GD, (b) OD Sonuçları



Şekil 3. Indian Pines Görüntüsüne Ait: (a) Yer Gerçekliği Haritası; (b) SVM, (c) SRC, (d) JSRC, (e) NLW-JSRC, (f) 3SM-JSRC Metotları ile Elde Edilen Sınıflandırma Haritaları ve GD Sonuçları; (g) Sınıf İsimleri

%10 kadar örnek eğitim için ve geriye kalan %90 örnek ise test için kullanılmıştır. Sınıflara ve örneklerle ait bilgiler Tablo 1'de bulunmaktadır.

SVM için Gauss RBF çekirdeği kullanılmış ve en iyi parametrelerin seçilebilmesi için 5-kat çapraz doğrulama yapılmıştır. SRC metodunda (Chen vd., 2011)'te önerilen $L=5$ seyreklik

seviyesi kullanılmıştır. JSRC metodu için 9×9 pencere boyutu ve seyreklik seviyesi olarak 30 kullanılmıştır (Chen vd., 2011).NLW-JSRC metodunda da en yüksek genel doğruluk değerlerine komşuluk için pencere boyutu 9×9 , yerel olmayan ağırlık hesaplaması için kullanılan pencere boyutu 7×7 ve seyreklik seviyesi olarak 30 değerleri ile ulaşılmıştır (Zhang vd., 2014).

Önerilen 3SM–JSRC metodu için optimum seyreklik seviyesi ve pencere boyutunun belirlenebilmesi için farklı değerler ile test yapılmıştır. Pencere boyutu olarak 3×3 , 5×5 , 7×7 , 9×9 ve 11×11 kullanılmıştır. Seyreklik seviyesi olarak da 5, 10, 15, 20, 25 ve 30 değerleri kullanılmıştır.

Şekil 2’de ise bu parametreler ile elde edilen *GD* ve *OD* sonuçları bulunmaktadır. Görüleceği üzere 9×9 pencere boyutu ile 11×11 pencere boyutu arasında tüm seyreklik seviyeleri için *OD* sonuçlarında düşüş olmaktadır. 3×3 pencere boyutu ile 5×5 pencere boyutu arasında ise hem *GD* hem de *OD* sonuçlarında artış gözlemlenmektedir. Dolayısıyla pencere boyutu için 5×5 , 7×7 veya 9×9 arasında seçim yapılmalıdır. 9×9 ölçekte 25 seyreklik seviyesinde *GD* sonucu 5×5 ve 7×7 ölçeklerin sonuçlarına yakın çıksa da *OD* sonucu diğer iki ölçek sonuçlarına göre düşük çıkmaktadır.

Tablo 2. Indian Pines Veri Seti için SVM, SRC, JSRC, NLW–JSRC ve 3SM–JSRC Metotları Kullanılarak Elde Edilen Karşılaştırma Sonuçları (%)

Sınıf	SVM	SRC	JSRC	NLW–JSRC	3SM–JSRC
1	76.67	68.33	86.67	85.83	96.88
2	81.01	65.15	93.74	94.53	93.90
3	76.65	61.55	89.91	89.29	93.68
4	71.00	43.33	93.81	91.52	89.67
5	94.97	89.08	93.42	97.23	96.00
6	95.67	94.94	99.14	99.88	98.44
7	79.57	82.17	51.74	33.04	86.96
8	97.48	97.25	99.80	100	100
9	71.11	41.67	4.44	23.89	51.67
10	70.54	72.45	89.07	86.99	92.92
11	85.41	76.47	97.25	98.04	97.35
12	86.68	59.22	89.00	94.49	91.47
13	99.16	97.74	99.21	99.74	98.79
14	95.40	93.77	99.24	99.24	99.66
15	61.87	44.71	98.45	93.71	94.74
16	89.06	87.53	92.24	98.24	90.94
<i>GD</i>	84.83	75.91	94.86	95.31	95.83
<i>OD</i>	83.26	73.46	86.07	86.60	92.06
K	82.69	72.49	94.13	94.64	95.24

Dolayısıyla seçim için yalnızca 5×5 ve 7×7 ölçek boyutları kalmaktadır. Her iki ölçek boyutu için de $L=5$ seyreklik seviyesinde *GD* ve *OD* sonuçları daha yüksek çıkmaktadır. 7×7 ölçek boyutunda *GD* sonucu daha yüksek olduğu için optimum parametreler 7×7 pencere boyutu ve $L=5$ seyreklik seviyesi

olarak belirlenmiştir. Çünkü yüksek *GD* sonucu doğru sınıflandırılan test örneklerinin sayısının daha fazla olduğunu işaret etmektedir.

Parametre ayarlamaları ve deneyler yapıldıktan sonra elde edilen karşılaştırma sonuçları Tablo 2’de sunulmuştur. Görüleceği üzere önerilen 3SM–JSRC metodu *GD*, *OD* ve K değerleri açısından diğer metotlara göre üstün gelmektedir. Herhangi bir şekilde komşuluk bilgilerinin kullanılmadığı SVM ve SRC yöntemlerinde sınıflandırma doğruluk sonuçları komşuluk bilgilerinin kullanıldığı JSRC, NLW–JSRC ve 3SM–JSRC yöntemlerine göre daha düşük olmaktadır. Dolayısıyla komşuluk bilgileri sayesinde sınıflandırma doğruluk sonuçlarının arttığı rahatlıkla gözlemlenebilir. Pencere içerisindeki komşu pikseller için herhangi bir seçimin yapılmadığı JSRC metodu ile komşu pikseller için seçimin yapıldığı 3SM–JSRC metodunun sonuçları karşılaştırılacak olursa *GD* açısından yaklaşık olarak %1, *OD* açısından yaklaşık olarak %6 ve K açısından %1’den daha yüksek sınıflandırma doğruluk sonuçları 3SM–JSRC ile elde edilmektedir. Komşu piksellere ağırlık atamasının yapıldığı NLW–JSRC metoduna göre de 3SM–JSRC metodunda *GD* ve K değerlerinde ciddi bir farklılık olmasa da *OD* açısından metodumuz %6’ya yakın daha üstün gelmektedir.


Sınıflandırma sonuçlarının görsel olarak daha iyi bir şekilde gözlemlenebilmesi için Indian Pines verisine ait yer gerçekliği haritası, karşılaştırma yapılan metotlar ve önerilen metoda ait sınıflandırma haritaları Şekil 3’de sunulmuştur. Görüleceği üzere 3SM–JSRC metoduna ait sınıflandırma haritası benzerlik açısından yer gerçekliği haritası ile daha çok örtüşmektedir.

3.2. University of Pavia


Bu veri seti ROSIS (Reflective Optics System Imaging Spectrometer) sensörü tarafından Pavia Üniversitesi üzerinde yapılan uçuş ile elde edilmiştir. Toplamda 103 adet spektral banttan oluşmaktadır. Orijinal görüntü 610×610 adet piksele sahip olsa da veri seti içerisindeki bazı kısımlar hakkında herhangi bir bilgi olmadığı için veri seti içerisinden çıkartılmıştır ve sınıflandırma amacı ile yapılan çalışmalarda 610×340 uzamsal boyut

kullanılmıştır. Farklı farklı gruplara ait (asfalt, çimenler, ağaçlar, toprak vs.) 9 adet sınıftan oluşmaktadır. Indian Pines veri setinde olduğu

gibi bu veri seti ile ilgili yapılan tüm çalışmalarda da her sınıftan %10 kadar örnek



(a)



(b)

Şekil 4. University of Pavia Veri Setinde Farklı Pencere Boyutları ve Seyreklik Seviyeleri Kullanılarak Elde Edilen (a) GD, (b) OD Sonuçları

eğitim için ve geriye kalan %90 örnek ise test için kullanılmıştır. Sınıflara ve örneklere ait bilgiler Tablo 3'de bulunmaktadır.

Tablo 3. University of Pavia Veri Setinde Her Sınıfa Ait Eğitim ve Test Örnekleri Sayısı

Sınıf	İsim	Eğitim	Test
1	Asphalt	664	5967
2	Meadows	1865	16784
3	Gravel	210	1889
4	Trees	307	2757
5	Painted metal sheets	135	1210
6	Bare Soil	503	4526
7	Bitumen	133	1197
8	Self-Blocking Bricks	369	3313
9	Shadows	95	852
Toplam		4281	38495

SVM için Gauss RBF çekirdeği kullanılmış ve en iyi parametrelerin seçilebilmesi için 5-kat çapraz doğrulama yapılmıştır. SRC metodunda $L=5$ seyreklik seviyesi kullanılmıştır. JSRC metodu için 3×3 pencere boyutu ve seyreklik seviyesi olarak 10 kullanılmıştır (Zhang vd., 2014). NLW-JSRC metodunda da en yüksek genel doğruluk değerlerine komşuluk için pencere boyutu 5×5 , yerel olmayan ağırlık hesaplaması için kullanılan pencere boyutu 7×7 ve seyreklik seviyesi olarak 15 değerleri ile ulaşılmıştır (Zhang vd., 2014). Önerilen

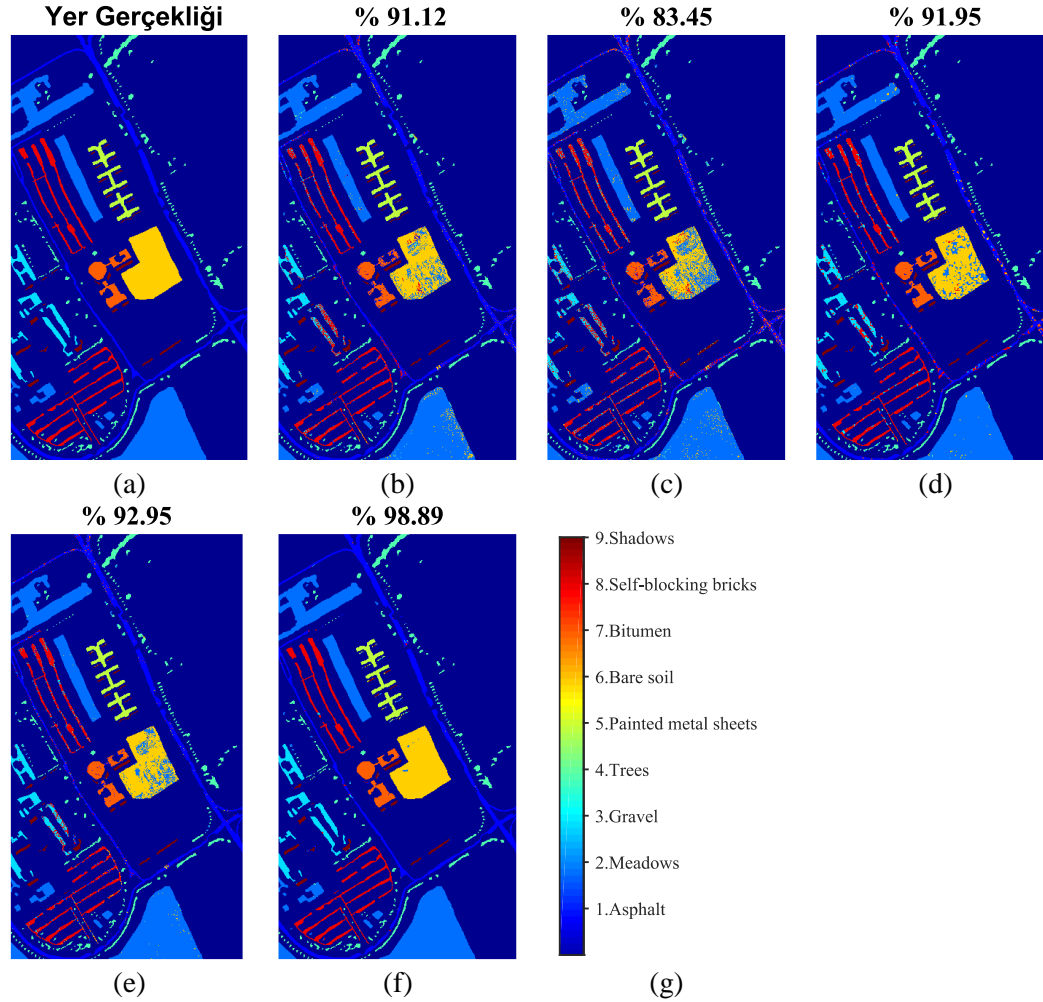
3SM-JSRC metodu için optimum seyreklik seviyesi ve pencere boyutunun belirlenebilmesi için farklı değerler ile test yapılmıştır. Pencere boyutu olarak 3×3 , 5×5 , 7×7 , 9×9 ve 11×11 kullanılmıştır. Seyreklik seviyesi olarak da 5, 10, 15, 20, 25 ve 30 değerleri kullanılmıştır.

Şekil 4'de ise bu parametreler ile elde edilen GD ve OD sonuçları bulunmaktadır. Görüleceği üzere tüm seyreklik seviyeleri için de pencere boyutu arttıkça hem GD hem de OD sonuçları artmaktadır. Fakat 9×9 ölçekten 11×11 ölçüğe doğru geçiş yaparken OD sonuçlarındaki artış iyice azalmıştır. Şekil 4(a) dikkatli incelenecek olursa 11×11 ölçekte $L=15$ seyreklik seviyesi için GD sonucu en yüksek değere ulaşmaktadır. OD sonuçlarında ise 11×11 ölçekte $L=5$ seyreklik seviyesi haricindeki değerler neredeyse aynı çıkmaktadır. Bu sebeple 11×11 pencere boyutu ve $L=15$ seyreklik seviyesi bu veri seti için optimum değerler olarak belirlenmiştir.

Parametre ayarlamalarından sonra yapılan karşılaştırma sonuçlarına ait veriler Tablo 4'de sunulmuştur. Görüleceği üzere GD, OD ve K değerleri 3SM-JSRC metodunda diğer metotlara göre oldukça yüksek çıkmaktadır.

JSRC ile *GD* açısından arasındaki fark yaklaşık olarak %7, *OD* açısından yaklaşık olarak %7 ve *K* açısından yaklaşık olarak %9.50 olmaktadır. NLW–JSRC ile ise *GD* açısından aradaki fark yaklaşık olarak %6, *OD*

açısından yaklaşık olarak %6 ve *K* açısından yaklaşık olarak %8 olmaktadır. Komşuluk bilgilerinin kullanılmadığı SVM ve SRC metotlarında ise sınıflandırma doğruluk sonuçları diğer 3 metoda göre düşük



Şekil 5. University of Pavia Görüntüsüne Ait: (a) Yer Gerçekliği Haritası; (b) SVM, (c) SRC, (d) JSRC, (e) NLW–JSRC, (f) 3SM–JSRC Metotları ile Elde Edilen Sınıflandırma Haritaları ve *GD* Sonuçları; (g) Sınıf İsimleri

kalmaktadır. Bu veri setinde JSRC ve NLW–JSRC metotlarına göre 3SM–JSRC metodunda sınıflandırma sonuçlarının daha yüksek olmasının sebebi büyük pencere boyutunun kullanılmasıdır. Çünkü JSRC ve NLW–JSRC metotlarında küçük pencere boyutlarında optimum değerlere ulaşılmıştır. Fakat küçük pencere ölçeklerinde uzamsal bilgi yeterince kullanılamayacağı için yüksek sınıflandırma doğruluk değerleri elde edilememiştir. 3SM–JSRC metodunda ise yüksek pencere ölçeği sayesinde uzamsal bilgi oldukça verimli bir

şekilde kullanılmıştır. Ayrıca pencere içerisine giren farklı sınıflara ait pikseller de spektral eşleştirme metotları sayesinde elenmiştir. Bu sayede de sınıflandırma doğruluk sonuçları oldukça yüksek değerlere ulaşmıştır.

Tablo 4. University of Pavia Veri Seti İçin SVM, SRC, JSRC, NLW–JSRC ve 3SM–JSRC Metotları Kullanılarak Elde Edilen Karşılaştırma Sonuçları (%)

Sınıf	SVM	SRC	JSRC	NLW–JSRC	3SM–JSRC
1	91.53	77.18	82.14	93.30	98.73

2	97.19	94.97	98.79	99.60	99.94
3	70.70	61.90	83.34	84.66	99.33
4	93.80	84.54	91.58	94.60	95.50
5	99.51	99.49	100	100	99.98
6	75.92	56.36	79.54	73.29	99.51
7	83.13	78.59	94.06	92.44	99.56
8	87.60	76.88	91.34	83.39	99.62
9	99.07	94.92	94.99	97.51	82.58
<i>GD</i>	91.12	83.38	91.84	92.79	98.93
<i>OD</i>	88.72	80.54	90.64	90.98	97.19
<i>K</i>	88.13	77.64	89.09	90.30	98.58

Sınıflandırma sonuçlarının görsel olarak daha iyi bir şekilde gözlemlenebilmesi için University of Pavia verisine ait yer gerçekliği haritası, karşılaştırma yapılan metotlar ve önerilen metoda ait sınıflandırma haritaları Şekil 5’te sunulmuştur. Görüleceği üzere 3SM–JSRC metoduna ait sınıflandırma haritası benzerlik açısından yer gerçekliği haritası ile daha çok örtüşmektedir. 3SM–JSRC metodu haricindeki metotlarda "Bare soil" sınıfına ait sonuçlar oldukça gürültülü olmasına rağmen 3SM–JSRC metodunda bu sınıfa ait sonuçlar yer gerçekliği haritası ile iyi bir şekilde örtüşmektedir. Yine aynı şekilde "Gravel" ve "Self-blocking bricks" sınıflarına ait sonuçlar sınıflandırma haritaları üzerinde incelenecek olursa 3SM–JSRC haricindeki yöntemlerde gürültü bulunmaktadır. 3SM–JSRC’de ise bu sınıfa ait sonuçlar yer gerçekliği haritasındaki ile neredeyse birebir örtüşmektedir.

4. SONUÇLAR ve TARTIŞMA

Bu çalışmada JSRC sınıflandırma modelinin başarımlarını arttırmak için spektral eşleştirme yöntemlerini ortaklaşa kullanan 3SM–JSRC modeli önerilmiştir. Test örneğinin sınıflandırılması aşamasında test pikseli etrafındaki komşu piksellerin spektral eşleştirme yöntemleri yardımı ile sınıflandırma işlemine dahil edilmesi veya edilmemesi sağlanmıştır. Oluşturulan sınıflandırma problemi ise SOMP yardımı ile çözülmüştür. 3SM–JSRC metodunun temel avantajı ise büyük pencere boyutları kullanılsa bile komşu piksellerin seçimi sayesinde farklı sınıflara ait piksellerin çoğunlukla pencere içerisinden çıkartılmasıdır. Önerilen sınıflandırma modeli iki adet hiperspektral veri seti üzerinde de test edilmiştir. Yapılan deneyler sonucunda 3SM–JSRC metodunun literatürdeki benzer metotlara göre daha iyi sınıflandırma doğruluk sonuçları sağladığı gözlemlenmiştir.

Piksellerin benzerlik durumlarını daha iyi bir şekilde ortaya çıkarabilecek eşleştirme yöntemlerinin kullanılması veya farklı bir ağırlık atama metodunun geliştirilmesi ve kullanılması ile önerilen metot geliştirilebilir.

KAYNAKÇA

- Bruzzone, L., Chi, M. ve Marconcini, M. (2006). A Novel Transductive SVM for Semisupervised Classification of Remote-Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 44(11), 3363-3373.
- Chen, Y., Nasrabadi, N. M. ve Tran, T. D. (2011). Hyperspectral Image Classification Using Dictionary-Based Sparse Representation. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10), 3973-3985.
- Chi, M. ve Bruzzone, L. (2007). Semisupervised Classification of Hyperspectral Images by SVMs Optimized in the Primal. *IEEE*, 45(6), 1870-1880.
- Christophe, E., Leger, D. ve Mailhes, C. (2005). Quality criteria benchmark for hyperspectral imagery. *IEEE*, 43(9), 2103-2114.
- Dalponte, M., Ørka, H. O., Gobakken, T., Gianelle, D. ve Næsset, E. (2013). Tree Species Classification in Boreal Forests With Hyperspectral Data. *IEEE*, 51(5), 2632-2645.
- Datt, B., McVicar, T. R., Niel, T. G. V., Jupp, D. L. B. ve Pearlman, J. S. (2003). Preprocessing EO-1 Hyperion hyperspectral data to support the application of agricultural indexes. *IEEE*, 41(6), 1246-1259.
- Dunder, T. ve Ince, T. (2019). Sparse Representation-Based Hyperspectral Image Classification Using Multiscale Superpixels and Guided Filter. *IEEE Geoscience and Remote Sensing Letters*, 16(2), 246-250.
- Fang, L., Li, S., Kang, X. ve Benediktsson, J. A. (2014). Spectral–Spatial Hyperspectral Image Classification via Multiscale Adaptive Sparse Representation. *IEEE Transactions on Geoscience and Remote Sensing*, 52(12), 7738-7749.
- Fang, L., Li, S., Kang, X. ve Benediktsson, J. A. (2015). Spectral–Spatial Classification of Hyperspectral Images With a Superpixel-Based Discriminative Sparse Model. *IEEE Transactions on Geoscience and Remote Sensing*, 53(8), 4186-4201.
- Garcia, M. ve Ustin, S. L. (2001). Detection of interannual vegetation responses to climatic variability using AVIRIS data in a coastal

- savanna in California. *IEEE*, 39(7), 1480-1490.
- Goel, P. K., Prasher, S. O., Patel, R. M., Landry, J. A., Bonnell, R. B. ve Viau, A. A. (2003). Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Comput. Electron. Agric.*, 39(2), 67-93.
- Gualtieri, J. A. ve Crompton, R. F. (1999). Support vector machines for hyperspectral remote sensing classification. *Proc. SPIE* içinde (C. 3584, ss. 221-232).
- Ham, J., Chen, Y., Crawford, M. M. ve Ghosh, J. (2005). Investigation of the random forest framework for classification of hyperspectral data. *IEEE*, 43(3), 492-501.
- Keshava, N. (2004). Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. *IEEE Transactions on Geoscience and Remote Sensing*, 42(7), 1552-1565.
- Li, J., Bioucas-Dias, J. M. ve Plaza, A. (2012). Spectral-Spatial Hyperspectral Image Segmentation Using Subspace Multinomial Logistic Regression and Markov Random Fields. *IEEE*, 50(3), 809-823.
- Li, J., Bioucas-Dias, J. M. ve Plaza, A. (2013). Semisupervised Hyperspectral Image Classification Using Soft Sparse Multinomial Logistic Regression. *IEEE*, 10(2), 318-322.
- Li, W. ve Du, Q. (2014). Joint Within-Class Collaborative Representation for Hyperspectral Image Classification. *IEEE*, 7(6), 2200-2208.
- Ma, L., Crawford, M. M. ve Tian, J. (2010). Local Manifold Learning-Based k -Nearest-Neighbor for Hyperspectral Image Classification. *IEEE*, 48(11), 4099-4109.
- Manolakis, D. ve Shaw, G. (2002). Detection algorithms for hyperspectral imaging applications. *IEEE*, 19(1), 29-43.
- Melgani, F. ve Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778-1790.
- Ratle, F., Camps-Valls, G. ve Weston, J. (2010). Semisupervised Neural Networks for Efficient Hyperspectral Image Classification. *IEEE*, 48(5), 2271-2282.
- Shukla, A. ve Kot, R. (2016). An Overview of Hyperspectral Remote Sensing and its applications in various Disciplines. *IRA-Int. J. Appl. Sci.*, 5(2), 85-90.
- Stavroulakis, D. G., Galidaki, G. N., Gitis, I. Z. ve Theodoridis, S. (2012). A Genetic Fuzzy-Rule-Based Classifier for Land Cover Classification From Hyperspectral Imagery. *IEEE*, 50(1), 130-148.
- Sun, X., Qu, Q., Nasrabadi, N. M. ve Tran, T. D. (2014). Structured Priors for Sparse-Representation-Based Hyperspectral Image Classification. *IEEE*, 11(7), 1235-1239.
- Tropp, J. A. ve Gilbert, A. C. (2007). Signal Recovery From Random Measurements Via Orthogonal Matching Pursuit. *IEEE Transactions on Information Theory*, 53(12), 4655-4666.
- Tu, B., Zhang, X., Kang, X., Zhang, G., Wang, J. ve Wu, J. (2018). Hyperspectral Image Classification via Fusing Correlation Coefficient and Joint Sparse Representation. *IEEE Geoscience and Remote Sensing Letters*, 15(3), 340-344.
- Yan, L., Cui, M. ve Prasad, S. (2018). Joint Euclidean and Angular Distance-Based Embeddings for Multisource Image Analysis. *IEEE Geoscience and Remote Sensing Letters*, 15(7), 1110-1114.
- Zhang, H., Li, J., Huang, Y. ve Zhang, L. (2014). A Nonlocal Weighted Joint Sparse Representation Classification Method for Hyperspectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2056-2065.
- Zhong, Y. ve Zhang, L. (2012). An Adaptive Artificial Immune Network for Supervised Classification of Multi-/Hyperspectral Remote Sensing Imagery. *IEEE*, 50(3), 894-909.