



## Hyperspectral and multispectral image fusion based on spectral decomposition and neighborhood pixel relation

Davut Çeşmeci<sup>1\*</sup>, Oğuzhan Urhan<sup>1</sup>, Mehmet Kemal Güllü<sup>2</sup>

<sup>1</sup>Department of Electronics and Communication Engineering, Faculty of Engineering, Kocaeli University, 41001 İzmit Kocaeli, Türkiye

<sup>2</sup>Department of Electrical and Electronics Engineering, Faculty of Engineering, İzmir Bakırçay University, 35665, Menemen İzmir, Türkiye

### Highlights:

- Hyperspectral and multispectral image fusion
- Neighborhood Pixel Relation
- Measuring fusion performances using quality metrics

### Keywords:

- Image Fusion
- Hyperspectral
- Multispectral
- Neighborhood pixel
- Spectral Decomposition

### Article Info:

Research Article

Received: 14.04.2021

Accepted: 10.12.2022

### DOI:

10.17341/gazimmfd.915691

### Correspondence:

Author: Davut Çeşmeci

e-mail:

davutcsmc@gmail.com

phone: +90 544 263 5326

### Graphical/Tabular Abstract

In literature, various fusion methods use spectral decomposition for endmember extraction and abundance estimation. However, to the best of our knowledge, neighborhood pixel relation was never directly used for image fusion. In this study, we propose a new hyperspectral and multispectral image fusion method that based on spectral decomposition and neighborhood pixel relation. Basically, we are taking both the neighborhood pixels and endmembers into account for estimation of abundance fractions and that provides incorporating information of the neighborhood pixels (Figure A).

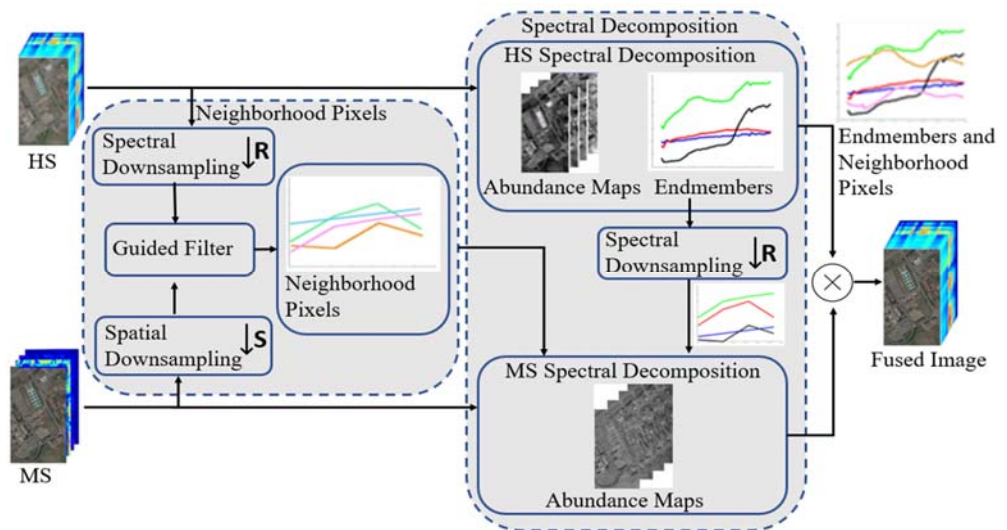


Figure A. Image fusion based on spectral decomposition and neighborhood pixel relation

**Purpose:** In this study, we aim to produce fused image with high spatial and spectral resolutions by using hyperspectral and multispectral images.

### Theory and Methods:

Spectral decomposition is used to extract endmembers from hyperspectral image. Then, hyperspectral endmembers are degraded to MS spectral resolution according to spectral response model of multispectral imaging sensor. And, then, linear mixture model is used to calculate abundance fractions for each degraded endmember and neighborhood pixel in multispectral image. Finally, the fused image is obtained as the product of multispectral abundance map and hyperspectral endmember/neighborhood pixels.

### Results:

The proposed method is tested on real hyperspectral images for different measurement metrics. The experimental results show that proposed method outperforms fusion algorithms in the literature.

### Conclusion:

In this paper we proposed a fusion method that using neighborhood pixel relation and experimental results show that it significantly increases the fusion accuracy. A mayor drawback of the proposed method is only applicable for the images that spatial resolution ratio two.



## Spektral ayrıştırma ve komşu piksel ilişkisi temelli hiperspektral ve multispektral görüntülerin kaynaştırılması

Davut Çeşmeci<sup>1\*</sup>, Oğuzhan Urhan<sup>1</sup>, Mehmet Kemal Güllü<sup>2</sup>

<sup>1</sup>Kocaeli Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, 41001 İzmit Kocaeli, Türkiye

<sup>2</sup>İzmir Bakırçay Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 35665, Menemen İzmir, Türkiye

### ÖNEÇİKANLAR

- Hiperspektral ve multispektral görüntülerin kaynaştırılması
- Komşuluk piksel ilişkisi
- Kaynaştırma başarısının kalite metrikleri ile ölçülmesi

### Makale Bilgileri

Araştırma Makalesi

Geliş: 14.04.2021

Kabul: 10.12.2022

DOI:

10.17341/gazimmfd.915691

### Anahtar Kelimeler:

Görüntü kaynaştırma,  
hiperspektral,  
multispektral,  
spektral ayrıştırma,  
komşuluk pikselleri

### ÖZ

Hiperspektral (HS) görüntüler yüksek spektral çözünürlüğe sahip oldukları halde, teknolojik kısıtlamalardan dolayı uzamsal çözünürlükleri düşüktür. Sınıflandırma başarımının artırılması veya daha detaylı içerik elde edilmesi gibi gereksinimlerin karşılanabilmesi için bu tip görüntülerin yüksek spektral çözünürlük yanında yüksek uzamsal çözünürlüğe de sahip olmaları faydalıdır. Bu nedenle, HS görüntülerin Multispektral (MS) görüntüler ile kaynaştırılması son yıllarda popülerliğini koruyan bir konu olarak çalışılmaktadır. Literatürde Matris Ayrıştırması (MA) temelli görüntü kaynaştırmasında, komşu piksellerin etkisini dikkate alan bir çalışma ile karşılaşılmamıştır. Bu nedenle, bu çalışmada spektral ayrıştırma ve uzamsal komşuluk etkisini dikkate alan yeni bir kaynaştırma yaklaşımı önerilmektedir. Öncelikle, spektral ayrıştırma kullanılarak hiperspektral görüntüden son eleman ve katışım oranları çıkarılmaktadır. Çıkarılan son elemanlar, multispektral görüntü algılayıcısının spektral yanıtı kullanılarak multispektral spektral çözünürlüğüne taşınmaktadır. Daha sonra, multispektral görüntüdeki her bir piksel için, son elemanlar ile komşuluk piksellerinin katışım oranları kestirilmektedir. Son olarak, multispektral görüntüden kestirilen katışım haritası ile hiperspektral görüntünün son elemanları ve komşuluk pikselleri kullanılarak hem uzamsal hem de spektral çözünürlüğü yüksek görüntü elde edilmektedir. Önerilen kaynaştırma yöntemi gerçek hiperspektral görüntüler üzerinde test edilmiştir ve deneysel çalışmalar literatürdeki çalışmalara göre başarımının daha yüksek olduğunu göstermektedir.

## Hyperspectral and multispectral image fusion based on spectral decomposition and neighborhood pixel relation

### HIGHLIGHTS

- Hyperspectral and multispectral image fusion
- Neighborhood pixel relation
- Measuring fusion performance using quality metrics

### Article Info

Research Article

Received: 14.04.2021

Accepted: 10.12.2022

DOI:

10.17341/gazimmfd.915691

### Keywords:

Image fusion  
hyperspectral  
multispectral  
neighborhood pixel  
spectral decomposition

### ABSTRACT

Hyperspectral (HS) images have high spectral resolution, but their spatial resolution is low due to technological constraints. It is beneficial to have HS images that have high spatial resolution as well as high spectral resolution to increase classification accuracy or obtain more detailed content in this kind of image. Thus, HS and multispectral (MS) image fusion have become a very popular topic in recent years. In this study, spectral decomposition and neighborhood pixel relation-based hyperspectral and multispectral image fusion is proposed. Firstly, spectral decomposition is used to get endmembers and their abundance maps from the hyperspectral image. Hyperspectral endmembers are degraded to multispectral spectral resolution according to the spectral response model of the multispectral sensor. Then, abundance fractions of the endmembers and neighborhood pixels are estimated for each multispectral pixel. Finally, the abundance map of multispectral image and endmembers, and neighborhood pixels of the hyperspectral image are used to obtain an image with high spatial and spectral resolution. The proposed method is tested on real hyperspectral images and experimental results show that it gives the highest accuracy compared to studies in the literature.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*davutcsmc@gmail.com, urhano@kocaeli.edu.tr, kemal.gullu@bakircay.edu.tr /  
Tel: +90 544 263 5326

## 1. Giriş (Introduction)

Hiperspektral (HS) görüntüler, elektromanyetik spektrumun ardışık ve dar dalga boyutlarında hedef yüzeyin görüntülenmesi ile elde edilmektedir. Bu nedenle, HS görüntünün her bir pikseli, sürekli yapıda onlarca/yüzlerce ışınım değerler dizisi ile temsil edilmektedir. Cisimlerin spektral imza olarak adlandırılan eşsiz spektruma sahip olmaları ve HS görüntülerin spektral bilgi bakımından zengin olmaları nedeniyle, HS görüntüleme hedef bölgelerin yüksek doğrulukta tanımlanması mümkün olmaktadır. Bu nedenle, sınıflandırma, bölütleme, hedef tespiti, değişim algılama, anomali tespiti gibi birçok uygulama alanında HS görüntüler kullanılmaktadır [1-3].

Hiperspektral görüntüler yüksek spektral çözünürlüğe sahip oldukları halde, teknolojik kısıtlamalardan dolayı uzamsal çözünürlükleri düşüktür. Multispektral (MS) görüntülerin ise spektral çözünürlükleri HS görüntülerin spektral çözünürlüklerine göre düşük ancak uzamsal çözünürlükleri HS görüntülerin uzamsal çözünürlüklerine göre daha yüksektir. Uzamsal ve spektral çözünürlükler açısından bakıldığında, HS ve MS görüntülerin birbirini tamamlayan karakteristiğe sahip oldukları görülmektedir. Kaynaştırma işlemi ile bu iki farklı bilgi zenginliğinin tek bir görüntüde toplanması amaçlanmaktadır. Yani, HS ve MS görüntülerin kaynaştırılması sonucunda hem uzamsal hem de spektral çözünürlüğü yüksek görüntü elde edilmesi beklenmektedir. Birbirini tamamlayan bu bilgilerin tek bir görüntüde toplanması, bu bilgilerin ayrı ayrı değerlendirilmesine göre daha fazla yararlı bilgi edinilmesini sağlamaktadır.

Literatürde birçok kaynaştırma yaklaşımı önerilmiştir [4, 5]. Çok-Çözünürlüklü Analiz (Multiresolution Analysis - ÇÇA) [6], Bileşen Değişimi (Component Substitution - BD) [7], Matris Ayrıştırması (Matrix Factorization - MA) [8], Tensor Ayrıştırması (Tensor Decomposition - TA) [9], Bayes olasılığı (Bayesian Probability) [10] temelli kaynaştırma yaklaşımları en popüler yaklaşımların başında gelmektedir. ÇÇA tipi yaklaşımlarda, yüksek uzamsal çözünürlüklü görüntü üzerinde çeşitli filtreler kullanılarak yüksek uzamsal bilgi çıkarılmaktadır [6]. Bu bilgi, yüksek spektral düşük uzamsal çözünürlüklü görüntü içerisine aktarılarak hem uzamsal hem spektral çözünürlüğü yüksek görüntü elde edilmektedir [6]. BD tipi yaklaşımlarda, spektral çözünürlüğü yüksek görüntü üzerinde spektral dönüşüm uygulanarak uzamsal ve spektral bilginin ayrıştırılması sağlanmaktadır. Uzamsal çözünürlüğü yüksek görüntünün uzamsal bilgisi, spektral dönüşüm uygulanmış görüntünün uzamsal uzaıyama aktarılmaktadır. Son olarak, spektral dönüşümün tersi uygulanarak spektral bilgi ile aktarılan uzamsal bilginin kaynaştırılması sağlanmaktadır [7]. BD tipi kaynaştırma yaklaşımları, hem hızlı ve kolay uygulanabilir olmaları hem de uzamsal detayların kaynaştırma görüntüsüne çok iyi aktarılmasını sağlamaları ile öne çıkmaktadır. Ancak BD tipi kaynaştırma yaklaşımlarında spektral bozulmalar ciddi sorun olmaktadır [11]. MA temelli kaynaştırma yaklaşımları HS ve MS görüntülerin kaynaştırılmasında sıklıkla kullanılmıştır. MA temelli yaklaşımlarda kaynaştırma görüntüsü, genel olarak HS görüntüden elde edilen son eleman matrisi ile MS görüntüden elde edilen katışım haritasının çarpımı ile elde edilmektedir [8]. MA temelli yaklaşımlarda HS ve MS görüntüleri matris olarak düşünülmekte ve kaynaştırma işlemi bu yapı üzerine kurulmaktadır. Halbuki HS ve MS görüntüler çok boyutludurlar ve iki boyutlu matrisler olarak dikkate alınması, uzamsal ve spektral ilintiden faydalanılmasını zorlaştırmaktadır. Bu sorunun üstesinden gelinmesi için tensör temelli kaynaştırma yaklaşımları önerilmiştir [9]. Görüntü kaynaştırması problemi doğası gereği kötü konumlandırılmış (ill-posed) yapıdadır. Bu nedenle, kaynaştırma görüntüsünün kestirimi için Bayes yaklaşımının kullanımına son yıllarda sıklıkla rastlanmaktadır [10].

## 2. Karşılaştırmada Kullanılan Yöntemler (Studies Used in Comparison)

Bu çalışmada geliştirilen yaklaşımın performansını karşılaştırmak amacıyla literatürde var olan kaynaştırma yaklaşımlarından en yaygın kullanıma sahip 11 farklı yöntem seçilmiştir. Yöntemlere ilişkin temel bilgiler aşağıda verilmiştir.

### 2.1. Gram Schmidt Adaptive (GSA)

Bu kapsamda ele alınan BD temelli Gram Schmidt Adaptive (GSA) yöntemi ilk olarak görüntü keskinleştirme için önerilmiştir [7]. GSA keskinleştirme, spektral boyutta eşleşen MS ve HS görüntü bantları arasında uygulanarak HS ve MS görüntü kaynaştırması işlemine dönüştürülmüştür [12].

### 2.2. Yumuşatıcı Filtre temelli Parlaklık Modülasyonu (Smoothing Filter-based Intensity Modulation - SFIM)

ÇÇA temelli yaklaşımlardan olan Yumuşatıcı Filtre temelli Parlaklık Modülasyonu [6] yöntemi HS ve MS görüntü kaynaştırması için [14]'te önerilmiştir.

### 2.3. Genelleştirilmiş Laplacian Piramidi (Generalized Laplacian Pyramid - GLP)

ÇÇA temelli yaklaşımlardan olan Genelleştirilmiş Laplacian Piramidi [13] yöntemi HS ve MS görüntü kaynaştırması için [14]'te önerilmiştir.

### 2.4. Rehberli Filtre Temelli Temel Bileşen Analizi (Guided Filter based Principal Component Analysis - GFPCA)

Hem BD hem de ÇÇA tipi yaklaşımları içinde barındıran hibrit bir yöntem olan Rehberli Filtre Temelli Temel Bileşen Analizi [15]'te önerilmektedir.

### 2.5. Olasılıksal Karışım Modeli ile En Büyük Olabilirlik (Maximum-A-Posteriori estimation with a Stochastic Mixing Model - MAP-SMM)

MAP-SMM [10] yöntemi Bayes temelli kaynaştırma yaklaşımlarındandır. MAP-SMM yönteminde kaynaştırma görüntüsünün ortalama vektörü hesaplanmasında ve kovaryans matrisinin kestiriminde SMM modeli kullanılmaktadır. HS ve MS görüntüleri yüksek veri boyutuna sahip olduğundan, En Büyük Olabilirlik (Maximum Likelihood - ML) ve Bayes kestiricilerinin hesaplanması için yüksek işlem yükü gerekmektedir.

### 2.6. Sylvester Eşitliği temelli Hızlı Kaynaştırma (Fast Fusion based on Sylvester Equation - FUSE)

FUSE [16] yöntemi Bayes temelli kaynaştırma yaklaşımlarındandır. MAP-SMM yönteminde kaynaştırma görüntüsünün ortalama vektörü hesaplanmasında ve kovaryans matrisinin kestiriminde SMM modeli kullanılmaktadır. HS ve MS görüntüleri yüksek veri boyutuna sahip olduğundan, En Büyük Olabilirlik (Maximum Likelihood - ML) ve Bayes kestiricilerinin hesaplanması için yüksek işlem yükü gerekmektedir. FUSE yönteminde, Bayes temelli kaynaştırma yaklaşımlarında daha hızlı sonuç alabilmek için Sylvester eşitliğinin kullanılması önerilmiştir.

### 2.7. Bağlı Negatif Olmayan Matris Ayrıştırması (Coupled Non-Negative Matrix Factorization - CNMF)

CNMF [8] yöntemi MA temelli kaynaştırma yaklaşımlarındandır. CNMF yönteminde son elemanlar ve katışım oranları matrislerinin Negatif Olmayan Matris Ayrıştırması (Non-negative Matrix Factorization - NMF) ile belirlenmesi önerilmektedir. Kaynaştırma

görüntüsü HS görüntüden elde edilen son eleman matrisi ile MS görüntüden gelen katışım matrisinin çarpımından elde edilmektedir.

### 2.8. Hiperspektral Süper Çözünürlük (Hyperspectral Super resolution - HySure)

HySure [4] yöntemi MA temelli kaynaştırma yaklaşımlarındandır. HySure yönteminde dönüşüm matrisleri, toplam değişim düzenleme terimi (total variation regularization term) temelli dış bükey (convex) en iyileme ile kestirilmektedir.

### 2.9. Ayrık Uzamsal-Spektral Temsilciler (Sparse Spatio-Spectral Representation – SSSR)

SSSR [17] yöntemi MA temelli kaynaştırma yaklaşımlarındandır. SSSR yönteminde son elemanların ve katışım oranlarının hesaplanması için sırasıyla Sözlük Öğrenme (Dictionary Learning) ve Ayrık Kodlama (Sparse Coding) kullanılması önerilmektedir.

### 2.10. Bağlı Spektral Ayrıştırma (Coupled Spectral Unmixing -CSU)

CSU [18] yöntemi MA temelli kaynaştırma yaklaşımlarındandır. CSU yönteminde bulunan son elemanların ve katışım oranlarının güncellenmesi için Gradyan İzdüşürme (Projected Gradient) kullanılması önerilmektedir.

### 2.11. Bağlı Ayrık Tensor Ayrıştırması (Coupled Sparse Tensor Factorization – CSTF)

MA temelli yaklaşımlarda çok boyutlu HS ve MS görüntüleri iki boyutlu matrisler olarak değerlendirilmektedir. Kaynaştırma işleminde HS ve MS görüntüleri çok boyutlu olarak dikkate almak ve böylece uzamsal ve spektral boyutta ilintiliğin daha iyi korunmasını sağlamak için TF temelli yaklaşımlar önerilmektedir. CSTF [9] en çok bilinen TF temelli kaynaştırma yaklaşımlarından birisidir.

Literatürde matris ayrıştırması temelli birçok yaklaşım önerilmiştir [4, 8, 17, 18]. Bazı çalışmalarda MA temelli kaynaştırma yaklaşımlarında spektral boyutta bozulmalar ile karşılaşıldığı belirtilmektedir [19, 20]. Bu sorunun çözümü için son eleman sayısının artırılması önerilmektedir [8]. Ancak son eleman sayısının belirlenmesi de ayrı bir problemdir [21].

Bu çalışmada, katışım oranlarının hesaplanmasında özgün olarak son elemanlarla beraber komşuluk piksellerinin de dikkate alınması önerilmektedir. Özellikle homojen bölgelerdeki komşu pikseller birbirleri ile ilintili bilgi taşıdıklarından, benzer spektral imzalara ve katışım oranlarına sahip olması beklenmektedir. Literatürde MA temelli görüntü kaynaştırmasında, komşu piksellerin etkisini doğrudan dikkate alan bir çalışma ile karşılaşılmamıştır. Katışım haritalarının Markov Rastlantı Alanları (Markov Random Fields - MRA) kullanılarak zenginleştirilmesi [22]'de önerilmektedir. Ancak bu çalışma bir görüntü kaynaştırma işlemi değil, süper-çözünürlük çalışmasıdır. RGB görüntüsü ile RGB spektral uzayına taşınmış son elemanlar arasında enerji en küçükleme denkleminin kurulduğu ve RGB görsele ait katışım haritasının hesaplandığı çalışma [23]'de önerilmektedir. Ancak [23]'de her bir piksel için kendi komşulukları doğrudan dikkate alınmamaktadır. Bu nedenle, bu çalışmada spektral ayrıştırma ve uzamsal komşuluk etkisini dikkate alan yeni bir kaynaştırma yaklaşımı önerilmektedir.

Üçüncü bölümde spektral ayrıştırma ve komşuluk etkisi temelli önerilen yöntem anlatılmaktadır. Deneysel çalışmalar dördüncü bölümde paylaşılmaktadır. Son olarak, beşinci bölümde sonuçlar verilmektedir.

## 3. Önerilen Yöntem (Proposed Method)

Bu çalışmada önerilen yaklaşım spektral ayrıştırma ve komşu piksel etkisi olmak üzere iki kısımdan oluşmaktadır (Şekil 1). Aşağıdaki alt bölümlerde bu konuda temel bilgiler verilmektedir.

### 3.1. Spektral Ayrıştırma (Spectral Decomposition)

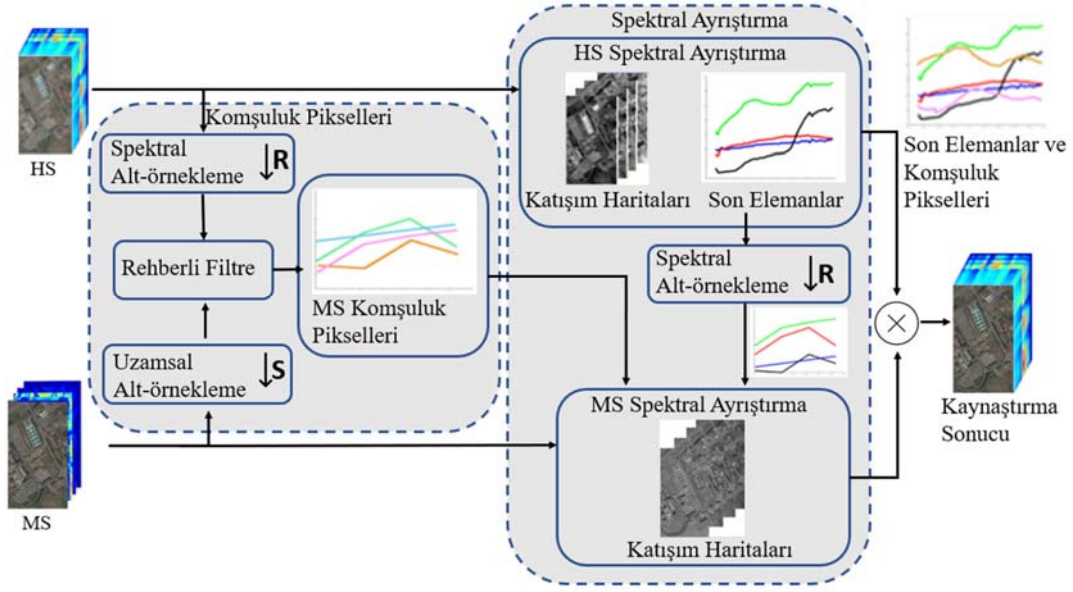
Görüntüleme algılayıcılarının yetersiz uzamsal çözünürlüğe sahip olması ya da görüntülenen yüzeyde farklı nesnenin mikroskobik düzeyde karışmış olması gibi nedenlerle görüntü pikseli içerisinde birden fazla son eleman bulunabilmektedir. Karışım pikseli olarak adlandırılan bu piksellere ait spektral imzalar, son elemanların belirli oranlarda karışımından oluşmaktadır. Görüntü içerisinde son elemanların kestirimi ve son elemanlara ait katışım oranlarının çıkarılması işlemi Spektral Ayrıştırma (SA) olarak adlandırılmaktadır. Son eleman kestirimi öncesinde, veri kümesi içerisindeki son eleman sayısının belirlenmesi gerekmektedir. Hiperspektral görüntüler oldukça yüksek spektral çözünürlüğe sahip olmalarına rağmen, genellikle daha düşük spektral alt-uzayda nesnelerin ayırt edilmesi mümkün olmaktadır. Sanal Boyutluluk (Virtual Dimensionality- SB) nesnelerin kayıpsız tespiti için hiperspektral görüntüyü spektral anlamda ifade edecek en az kaynak sayısını tanımlamaktadır. Diğer bir deyişle görüntü içerisindeki farklı spektral imzaların sayısı, sanal boyutluluk ile belirlenmektedir [21]. Bu çalışma kapsamında, HS görüntü içerisindeki son eleman sayısı HySime [24] sanal boyutluluk yaklaşımı ile belirlenmektedir. Son eleman sayısı belirlendikten sonra Zirve Bileşen Analizi (ZBA) [25] ile görüntü içerisindeki son elemanlar çıkarılmaktadır. Son elemanlar belirlendikten sonra her bir piksel için son elemanlara ait katışım oranları Tam Kısıtlı En Küçük Kareler (TKEK) [26] ile belirlenmektedir. Spektral Ayrıştırma süreci Şekil 2'de verilmektedir.

### 3.2 Komşu Piksel İlişkisi (Neighborhood Pixel Relation)

Bu çalışmada, HS ve MS görüntülerin geometrik olarak hizalanmış ve aynı son elemanlara sahip (aynı zamanda alınmış) oldukları varsayılmaktadır. Böylece, HS görüntüden kestirilen son elemanların MS spektral uzayına taşınması ve katışım hesabı için kullanılması mümkün olmaktadır. MA temelli kaynaştırma yaklaşımlarında MS görüntüsünün katışım oranları genellikle HS son elemanları kullanılarak belirlenmektedir. Bu aşamada komşuluk piksellerin etkisini dikkate alan bir çalışmaya literatürde rastlanmamıştır. Halbuki, hedef yüzeydeki nesnelere uzamsal sürekliliğe sahiptir ve bu süreklilikte komşu piksellerin benzer spektral imzalara sahip olmaları beklenmektedir. Bu çalışmada, MS görüntüsünden katışım oranları hesaplanırken, son elemanlar yanında komşuluk piksellerinin de dikkate alınması önerilmektedir. Önerilen yaklaşımın daha kolay takip edilebilmesi için temel semboller Tablo 1'de verilmektedir.

Şekil 3'de geometrik olarak hizalanmış ve uzamsal boyu dört kat çözünürlük farkı bulunan HS ve MS görüntü pikselleri temsili olarak gösterilmektedir. HS görüntünün  $(i,j)$  konumundaki pikseli  $\mathbf{x}_{i,j} \in \mathbb{R}^{B \times 1}$  vektörü ile temsil edilmektedir. Her bir HS pikseli  $2 \times 2$ 'lik MS piksel matrisi ile örtüşmektedir. MS görüntü pikselleri  $\mathbf{y}_{i,j,k} \in \mathbb{R}^{L \times 1}$  ile temsil edilmektedir.  $ij$  simgesi örtüştüğü HS piksel konumunu göstermekte,  $k$  simgesi ise MS uzayında  $2 \times 2$ 'lik matris içerisindeki konumunu göstermektedir. Basitlik açısından  $2 \times 2$  lik matris içerisinde tek bir indis ile konum ataması yapılmaktadır. Bu durumda  $(i,j)$  konumundaki  $\mathbf{x}_{i,j}$  HS pikseli  $\{\mathbf{y}_{i,j,1}, \mathbf{y}_{i,j,2}, \mathbf{y}_{i,j,3}, \mathbf{y}_{i,j,4}\}$  MS piksel matrisi ile örtüşmektedir (Şekil 3).

MS görüntüsünden katışım haritasının çıkarılmasında HS görüntüden elde edilen son elemanlar yanında MS görüntüsündeki komşu pikseller de kullanılmaktadır. Kaynaştırma görüntüsü oluşturma



**Şekil 1.** Spektral Ayrıştırma ve Komşuluk Pikseli Etkisi Temelli HS ve MS Görüntü Kaynaştırma (Spectral Decomposition and Neighborhood Pixel Relation Based on HS and MS Image Fusion)

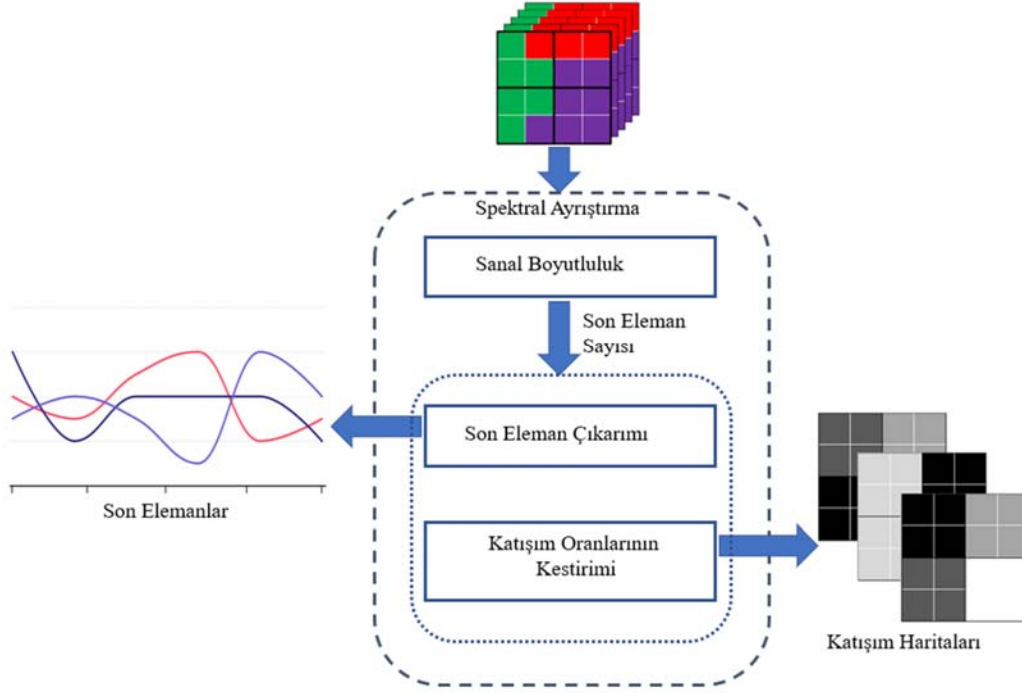
**Tablo 1.** Önerilen yaklaşımın daha kolay takip edilebilmesi için temel semboller (Key symbols to make the proposed approach easier to follow)

Sembol	Açıklaması
$X \in \mathbb{R}^{B \times n}$	X sembolü HS görüntü matrisini, n toplam piksel sayısını, B ise HS bant sayısı
$Y \in \mathbb{R}^{L \times m}$	Y sembolü MS görüntü matrisini, m toplam piksel sayısını, L ise MS bant sayısı
$Z \in \mathbb{R}^{B \times m}$	Z sembolü kaynaştırma görüntü matrisini, m toplam piksel sayısını, B ise spektral bant sayısı
$x \in \mathbb{R}^{B \times 1}$	HS görüntüsündeki bir piksel vektörü
$y \in \mathbb{R}^{L \times 1}$	MS görüntüsündeki bir piksel vektörü
$z \in \mathbb{R}^{B \times 1}$	Kaynaştırma görüntüsündeki bir piksel vektörünü
$X_{MS} \in \mathbb{R}^{L \times n}$	MS spektral çözünürlüğüne taşınmış HS görüntüsü
$Y_{HS} \in \mathbb{R}^{L \times n}$	HS uzamsal çözünürlüğüne taşınmış MS görüntü.
$Y_{RF}$	Rehberli Filtre (RF) [27] uygulanmış MS görüntü
$W_h \in \mathbb{R}^{B \times p}$	HS görüntüden elde edilen son eleman matrisini tanımlamaktadır. p son eleman sayısını tanımlamaktadır.
$W_m \in \mathbb{R}^{L \times p}$	MS görüntüsü için son eleman matrisi
S	HS algılayıcısının uzamsal yayılım dönüşüm matrisi
R	MS algılayıcısının spektral yanıt dönüşüm matrisi


adımında, bu komşu piksellerin HS görüntüsündeki karşılıklarına ihtiyaç duyulacaktır. Ancak HS görüntü ile MS görüntüsü arasında 4 kat çözünürlük farkı bulunmaktadır. Bu nedenle MS görüntüsündeki komşu piksellerin HS görüntüsünün uzamsal çözünürlüğünde tanımlanması gerekmektedir. Ayrıca, MS görüntüsünde tespit edilen komşu piksellerin HS görüntüsündeki karşılıkları kaynaştırma aşamasında kullanılacağından, alt-örneklemiş MS görüntü ile HS görüntünün birbirine yakınsaması beklenmektedir. Bu nedenle iki görüntü arasındaki tutarlılığın artırılması için Rehberli Filtre (RF) kullanılması önerilmektedir. RF uygulamak için MS görüntüsü HS algılayıcısının uzamsal yayılım fonksiyonu (S) ile HS uzamsal çözünürlüğüne ( $Y_{HS}$ ) taşınmaktadır. HS görüntüsü de MS algılayıcısının spektral yanıt fonksiyonu (R) ile MS spektral çözünürlüğüne ( $X_{MS}$ ) taşınmaktadır. Daha sonra  $Y_{HS}$  görüntüsünün her bir bandı için, aynı spektral aralıktaki  $X_{MS}$  bandı rehberliğinde RF uygulanmaktadır ( $Y_{RF} \in \mathbb{R}^{L \times n}$ ).

Şekil 4'te, geometrik olarak hizalanmış  $Y_{RF}$  ile Y pikselleri temsili olarak gösterilmektedir. (i,j) konumundaki  $Y_{RF}$  pikseli  $y_{RF(i,j)} \in \mathbb{R}^{L \times 1}$  ile tanımlanmaktadır.  $y_{ij,1}$  pikseli için katışım hesabında dikkate alınacak komşu pikseller  $y_{RF(i-1,j-1)}, y_{RF(i-1,j)}, y_{RF(i,j-1)}$  ve  $y_{RF(i,j)}$  olarak seçilmektedir.

SA adımında, HS görüntüden elde edilen son elemanların ( $W_h$ ) MS görüntüsünde katışım hesabında kullanılabilmesi için MS spektral çözünürlüğüne taşınması gerekmektedir.  $W_h$  son eleman matrisi, MS algılayıcısının spektral yanıt (R) matrisi ile çarpılarak MS spektral uzayına yansıtılmaktadır ( $W_m$ ). Son durumda  $y_{ij,1}$  pikseli için katışım oranları hesaplanacak son eleman ve komşuluk pikselleri matrisi ( $H_1$ ) Eş. 1'de ki gibi elde edilmektedir. Benzer şekilde,  $y_{ij,2}, y_{ij,3}$  ve  $y_{ij,4}$  pikselleri için sırasıyla  $H_2, H_3$  ve  $H_4$  matrisleri Eş. 2-Eş. 4'de verilmektedir.



Şekil 2. Spektral Ayırıştırma (Spectral Decomposition)



Şekil 3. Örtüşen HS ve MS pikselleri (Overlapping HS and MS pixels)

$$\mathbf{H}_1 = [\mathbf{W}_m, \mathbf{y}_{RF(i-1,j-1)}, \mathbf{y}_{RF(i,j-1)}, \mathbf{y}_{RF(i-1,j)}, \mathbf{y}_{RF(i,j)}] \quad (1)$$

$$\mathbf{H}_2 = [\mathbf{W}_m, \mathbf{y}_{RF(i,j-1)}, \mathbf{y}_{RF(i+1,j-1)}, \mathbf{y}_{RF(i+1,j)}, \mathbf{y}_{RF(i,j)}] \quad (2)$$

$$\mathbf{H}_3 = [\mathbf{W}_m, \mathbf{y}_{RF(i-1,j)}, \mathbf{y}_{RF(i-1,j+1)}, \mathbf{y}_{RF(i,j+1)}, \mathbf{y}_{RF(i,j)}] \quad (3)$$

$$\mathbf{H}_4 = [\mathbf{W}_m, \mathbf{y}_{RF(i,j+1)}, \mathbf{y}_{RF(i+1,j+1)}, \mathbf{y}_{RF(i+1,j)}, \mathbf{y}_{RF(i,j)}] \quad (4)$$

$\mathbf{H}_1$  matrisinde verilen imzaların pozitif ve toplamları bir olan katsayılarla çarpımları toplamının  $\mathbf{y}_{ij,1}$  pikseline mümkün olduğu

kadar yakın olması beklenmektedir. Bu probleme ait amaç fonksiyonu Eş. 5'te verilmektedir. Bu eşitlikte aranan katsayı vektörü yani  $\mathbf{y}_{ij,1}$  pikseline ait katılım vektörü  $\mathbf{u}_{ij,1}$  ile temsil edilmektedir. Bu problemin çözümünde TKEK yaklaşımı kullanılmaktadır.

$$\tilde{\mathbf{y}}_{ij,1} = \mathbf{H}_1 \mathbf{u}_{ij,1} \quad (5)$$

$$\min_{\mathbf{u}} \frac{1}{2} \|\mathbf{y}_{ij,1} - \mathbf{H}_1 \mathbf{u}_{ij,1}\|, s.t. \sum_{s=1}^4 u_s = 1, \forall u_s \geq 0$$

$\mathbf{y}_{ij,1}$  pikseli için katılım vektörü hesaplandıktan sonra kaynaştırma görüntüsüne ait  $\mathbf{z}_{ij,1}$  pikseli oluşturulmaktadır. Kaynaştırma görüntü pikselleri oluşturulurken,  $\mathbf{u}$  katılım vektörü yanında HS görüntüden

gelen son elemanlar ve komşuluk pikselleri kullanılmaktadır. HS görüntüdeki komşuluk pikselleri,  $Y_{RF}$  görüntüsündeki komşuluk piksellerinin bire-bir konumsal karşılıkları alınarak belirlenmektedir. Şekil 5’de  $Y_{RF}$  görüntüsündeki komşuluk pikselleri ile HS görüntü üzerindeki karşılıkları ve oluşturulacak kaynaştırma görüntü ( $z_{ij,1}$ ) pikseli gösterilmektedir.  $z_{ij,1}$  pikseli,  $u_{ij,1}$  katışım vektörü ile HS görüntüden gelen son elemanlar ve komşuluk pikselleri matrisinin çarpımı ile elde edilmektedir (Eş. 6). Benzer şekilde kaynaştırma görüntüsüne ait  $z_{ij,2}$ ,  $z_{ij,3}$  ve  $z_{ij,4}$  pikselleri Eş. 7-Eş. 9’da verildiği gibi hesaplanmaktadır.

$$z_{ij,1} = [W_h, x_{(i-1,j-1)}, x_{(i,j-1)}, x_{(i-1,j)}, x_{(i,j)}]u_{ij,1} \quad (6)$$

$$z_{ij,2} = [W_h, x_{(i,j-1)}, x_{(i+1,j-1)}, x_{(i+1,j)}, x_{(i,j)}]u_{ij,2} \quad (7)$$

$$z_{ij,3} = [W_h, x_{(i-1,j)}, x_{(i-1,j+1)}, x_{(i,j+1)}, x_{(i,j)}]u_{ij,3} \quad (8)$$

$$z_{ij,4} = [W_h, x_{(i,j+1)}, x_{(i+1,j+1)}, x_{(i+1,j)}, x_{(i,j)}]u_{ij,4} \quad (9)$$

Her bir MS pikseli için katışım kestirimi gerçekleştirilirken ve kaynaştırma görüntüsüne ait pikseller oluşturulurken bütün son elemanlar yerine ilgili MS pikseli ile örtüşen HS pikselinde katışımı yüksek olan son elemanlar dikkate alınmaktadır. Bu çalışma kapsamında, katışım hesabında kullanılacak son elemanlar için seçilen eşik değeri deneysel olarak 0,1 seçilmiştir.

#### 4. Deneysel Sonuçlar (Experimental Results)


Deneysel çalışmalarda AVIRIS, ROSIS ve Headwall Hyperspec-VNIR-C HS algılayıcıları ile alınan veri kümeleri kullanılmıştır. AVIRIS algılayıcısı için Indian Pine [28] ve Salinas [29], ROSIS algılayıcısından edinilen Pavia [30, 31] ve Hyperspec-VNIR-C algılayıcısından edinilen Headwall Chikusei [32] veri kümeleri deneysel karşılaştırma amacıyla kullanılmıştır. Salinas veri kümesi, Kaliforniya’daki Salinas Vadisi’nden edinilmiştir. 3,7m uzamsal çözünürlüğe sahip olup ve 234 spektral banttan oluşmaktadır. Orijinal veri kümesi 512×217 piksel uzamsal ebatlarında olduğu halde, iki, üç ve dörtün katı olması için bu veri kümesinin 504×216 piksellik bir bölümü kullanılmıştır. Indian Pine veri kümesi 224 spektral banttan oluştuğu halde gürültülü bantlar çıkarıldığında 200 bant kalmaktadır. Orijinal veri kümesi 145×145 piksel uzamsal ebatlarında olduğu halde, bu çalışma kapsamında 144×144 piksellik bir bölümü

kullanılmıştır. Pavia veri kümesi, 610×610 piksel uzamsal boyutlarda ve 103 spektral banttan oluşmaktadır. Bu çalışma kapsamında 600×336 piksellik bir bölgesi kullanılmıştır. Headwall Chikuhei veri kümesi, 2,5m uzamsal çözünürlüğe sahiptir ve 128 spektral banttan oluşmaktadır. Bu çalışma kapsamında 540×420 piksellik bir bölümü kullanılmıştır. Indian Pine, Pavia, Salinas ve Headwall Chikuhei veri kümelerine ait 3 bantlı görseller Şekil 6’da verilmektedir.

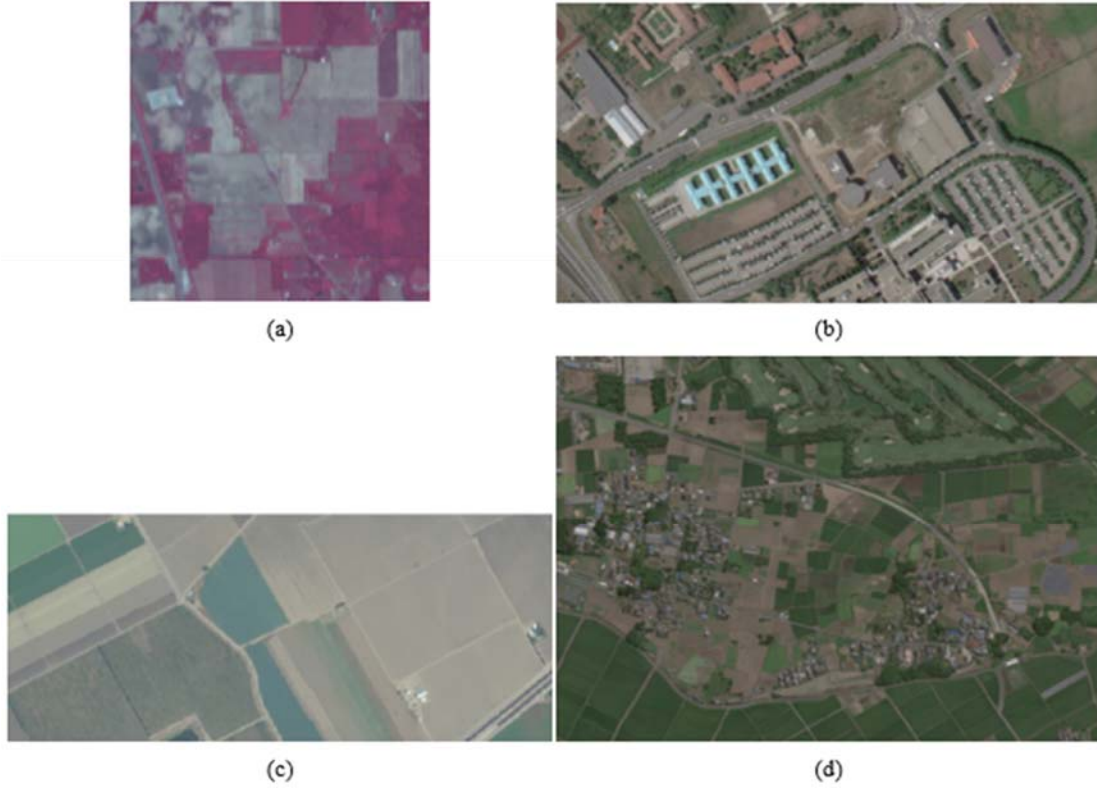
Kaynaştırma/keskinleştirme çalışmalarında başarımların değerlendirilmesi için önerilen yaklaşımlardan birisi Wald’s Protokolüdür [33]. Wald’s protokolünde, referans görüntü üzerinden temsili düşük çözünürlüklü görüntüler üretilmektedir. Üretilen bu sentetik görüntüler üzerinde kaynaştırma işlemi gerçekleştirilmekte ve kaynaştırma görüntüsü ile referans görüntü karşılaştırılarak başarımlar değerlendirilmesi gerçekleştirilmektedir. Wald’s Protokolü kapsamında Indian Pine, Pavia, Salinas ve Headwall Chikuhei HS veri kümeleri üzerinden düşük çözünürlüklü temsili HS ve yüksek çözünürlüklü ama düşük bant sayılı MS görüntüler oluşturulmaktadır. Uzamsal boyutta dört kat çift doğrusal alt-örnekleme ile temsili HS görüntü; spektral bantların MS algılayıcı karakteristiğine göre modellenmesiyle de temsili MS görüntüsü elde edilmektedir. Temsili MS görüntü oluşturulurken Worldview-2 MS algılayıcısının spektral karakteristiği referans alınmıştır. Worldview-2 algılayıcısının spektral karakteristiği Şekil 7’de verilmektedir.

Önerilen kaynaştırma işlemi sonucunda elde edilen kaynaştırma görüntüsü referans HS görüntü ile karşılaştırılarak başarımlar değerlendirilmesi gerçekleştirilmektedir. Başarımların değerlendirilmesinde Spektral Açık Eşleyici (Spectral Angle Mapper - SAM) [34], “Erreur Relative Globale Adimensionnelle de Synthèse” (ERGAS) [35] hata ölçütleri ile Zirve İşaret Gürültü Oranı (Peak Signal-to-Noise Ratio-PSNR) [36], Kalite Indisi (Quality Index -  $Q^2$ ) [37] kalite ölçütleri kullanılmıştır. SAM ölçütü ile spektral imzalarındaki bozulma, ERGAS ölçütü ile kaynaştırma işleminin bütünsel olarak referans görüntüye uzaklığı, PSNR ölçütü ile kaynaştırma işleminde uzamsal özelliklerin korunumu,  $Q^2$  ölçütü ile kaynaştırma sonucunun insan görüşü üzerinden ne kadar başarılı olduğu değerlendirilmektedir. Yüksek başarımlar için SAM ve ERGAS’ın düşük, PSNR ve  $Q^2$ ’in yüksek çıkması beklenmektedir. SAM, ERGAS, PSNR ve  $Q^2$  ölçütleri sırasıyla Eş. 10-Eş. 13’de verilmektedir.


$$SAM(\hat{Z}, Z) = \frac{1}{n} \sum_{i=1}^n \cos^{-1} \left( \frac{\langle \hat{z}_i, z_i \rangle}{\|\hat{z}_i\| \|z_i\|} \right) \quad (10)$$



Şekil 5. HS Görüntüde Tanımlanan Komşuluk Pikselleri (Neighborhood Pixels Defined on HS Image)



Şekil 6. Veri Kümesi Görselleri (a) Indian Pine, (b) Pavia, (c) Salinas, (d) Headwall Chikuhei  
(Dataset Images (a) Indian Pine, (b) Pavia, (c) Salinas, (d) Headwall Chikuhei)



Şekil 7. Worldview-2 MS algılayıcısı Spektral Karakteristiği (Spectral Response of Worldview-2 MS sensor)

$$ERGAS(\hat{\mathbf{Z}}, \mathbf{Z}) = 100d \sqrt{\frac{1}{B} \sum_{i=1}^B \left( \frac{RMSE_i}{\mu_i} \right)^2} \quad (11)$$

$$PSNR_i = 10 \log_{10} \left( \frac{MAX_i^2}{MSE_i} \right) \quad (12)$$

$$Q2^n = \frac{\sigma_{2z} \cdot 2\hat{z} \cdot 2\sigma_z}{\sigma_z \sigma_z \hat{z}^2 \hat{z}^2 \sigma_z^2 + \sigma_z^2} \quad (13)$$

Verilen eşitliklerin genelinde,  $\hat{\mathbf{Z}}$  ideal durumda ulaşılmak istenen kaynaştırma sonucu,  $\hat{\mathbf{z}}_i$  ise ideal görüntünün piksellerini tanımlamaktadır. Eş. 10'da  $\| \cdot \|$  sembolü  $L_2$  normu ifade etmektedir. Eş. 11 'de  $RMSE_i$  ortalama karesel hatanın karekökünü,  $\mu_i$  sembolü  $i$ . spektral bandın ortalama piksel değerini,  $d$  ise iki görüntü arasındaki çözünürlüklerin oranını göstermektedir. Eş. 12'de  $MAX_i^2$  ilgili spektral bandın en yüksek piksel değerinin karesini,  $MSE_i$  ortalama



karesel hatayı tanımlamaktadır. Eş. 13’de  $\sigma_{z,z}$  kovaryansı,  $\sigma_z$  ve  $\sigma_z$  standart sapmayı tanımlamaktadır.  $\bar{z}$  ve  $\bar{z}$  ise sırasıyla ideal görüntünün ve kaynaştırma görüntüsünün ortalama piksel değerlerini ifade etmektedir.

Önerilen spektral ayrıştırma ve komşu piksel etkisi (SAKİ) yöntemi, BD temelli GSA kaynaştırma yöntemi, ÇÇA temelli SFIM ve GLP kaynaştırma yöntemleri, Bayes temelli MAP-SMM ve FUSE kaynaştırma yöntemleri, MA temelli CNMF, HySure, SSSR ve CSU kaynaştırma yöntemleri ile TF temelli CSTF kaynaştırma yöntemi olmak üzere 5 farklı yaklaşımdan toplam 11 tane yöntem ile karşılaştırılmıştır. Indian Pine, Pavia, Salinas ve Headwall Chikuhei veri kümeleri için elde edilen başarımların değerleri sırasıyla Tablo 2-Tablo 5’de verilmektedir.

Indian Pine veri kümesi tarım arazileri ve doğal çok yıllık bitki örtüsü içermektedir. Indian Pine veri kümesi için en iyi başarımların değerleri sırasıyla SAKİ, CSU, GSA ve CNMF yöntemlerinde görülmektedir. Başarımları en düşük sonuçlar sırasıyla HySure, GFPCA ve FUSE yöntemlerinde görülmektedir. Indian Pine veri kümesi için en iyi ve

en kötü olarak paylaşılan yöntemler oldukça tutarlı yapıdadır. Yani yöntemlerin başarımlarının sıralaması bütün ölçütler için aynıdır.

Pavia veri kümesi çayır ve ağaçlar ile kentsel yerleşim yerlerini içermektedir. Pavia veri kümesi için en iyi başarımların değerleri sırasıyla SAKİ, CSU ve GSA yöntemleri ile elde edilmektedir. CSU yöntemi spektral imzaların yakınsaması (SAM), spektral bantlardaki uzamsal detaylar (PSNR) ve görsel kalite (Q2n) bakımından daha iyi sonuç verirken, GSA yöntemi bütünsel olarak (ERGAS) referans görüntüye daha yakın sonuç vermektedir. Spektral imzalarındaki yakınsaması, uzamsal detayların korunumu ve referans görüntüye bütünsel olarak yakınsaması bakımından HySure yöntemi en düşük başarımları verirken, görsel kalite olarak GFPCA en düşük başarımları vermektedir. Salinas veri kümesi üzüm ve sebze dikim alanları ile çıplak toprak alanları içermektedir. Salinas veri kümesi için en iyi başarımların değerleri sırasıyla SAKİ, CNMF, GSA yöntemleri ile elde edilmektedir. CNMF yöntemi spektral imzaların benzerliği (SAM), spektral bantlardaki uzamsal detaylar (PSNR) ve görsellik (Q2n) olarak daha iyi sonuç verirken, GSA yöntemi bütünsel olarak (ERGAS) referans görüntüye daha çok yakınsamaktadır. Referans imzalara yakınsaması, uzamsal

**Tablo 2.** Indian Pine Veri Kümesi için Ölçütlerin Sonuçları (Metric Results for Indian Pine Dataset)

Yöntemler	SAM	ERGAS	PSNR	Q2 <sup>n</sup>
GSA	1,06	2,37	34,84	0,80
SFIM	1,73	3,95	29,3	0,59
GLP	1,57	3,50	30,56	0,65
CNMF	1,08	2,54	34,30	0,79
SSSR	1,60	3,56	31,42	0,73
CSU	1,01	2,33	35,18	0,81
HySure	3,23	6,79	24,58	0,36
MAPSMM	1,54	3,41	30,58	0,65
FUSE	1,87	4,13	28,94	0,59
GFPCA	2,26	4,25	28,83	0,45
CSTF	1,69	3,69	29,93	0,64
SAKİ	0,81	2,03	36,86	0,88

**Tablo 3.** Pavia Veri Kümesi için Ölçütlerin Sonuçları (Metric Results for Pavia Dataset)

Yöntemler	SAM	ERGAS	PSNR	Q2 <sup>n</sup>
GSA	3,18	4,38	37,73	0,78
SFIM	5,12	12,07	29,02	0,45
GLP	4,25	8,24	31,75	0,61
CNMF	3,34	6,35	34,67	0,69
SSSR	4,05	5,99	34,99	0,68
CSU	3,00	4,42	38,08	0,81
HySure	6,41	12,65	28,14	0,49
MAPSMM	4,00	8,78	31,21	0,59
FUSE	5,89	11,65	29,17	0,55
GFPCA	5,50	9,16	30,81	0,34
CSTF	4,40	8,44	31,68	0,57
SAKİ	2,37	3,72	40,30	0,85

**Tablo 5.** Headwall Chikuhei Veri Kümesi için Ölçütlerin Sonuçları (Metric Results for Headwall Chikuhei Dataset)

Yöntemler	SAM	ERGAS	PSNR	Q2 <sup>n</sup>
GSA	1,08	1,76	44,01	0,91
SFIM	1,85	5,40	32,90	0,72
GLP	1,71	4,24	34,95	0,78
CNMF	1,16	2,21	42,43	0,90
SSSR	1,96	3,75	39,35	0,84
CSU	1,36	2,54	40,75	0,86
HySure	3,60	9,15	28,61	0,63
MAPSMM	1,67	4,70	33,92	0,75
FUSE	2,02	5,55	32,58	0,73
GFPCA	2,65	5,33	33,00	0,50
CSTF	1,98	5,13	33,41	0,75
SAKİ	0,96	1,64	45,50	0,92

**Tablo 4.** Salinas Veri Kümesi için Ölçütlerin Sonuçları (Metric Results for Salinas Dataset)

Yöntemler	SAM	ERGAS	PSNR	Q2 <sup>n</sup>
GSA	0,74	2,61	41,83	0,92
SFIM	1,31	7,94	33,63	0,73
GLP	1,22	3,72	35,99	0,79
CNMF	0,67	2,72	42,32	0,95
SSSR	2,18	7,54	33,47	0,91
CSU	0,72	2,84	41,16	0,93
HySure	2,22	7,43	29,72	0,61
MAPSMM	1,15	3,69	35,68	0,82
FUSE	1,34	4,09	34,69	0,76
GFPCA	1,65	3,85	35,06	0,78
CSTF	1,24	3,59	35,49	0,83
SAKİ	0,49	1,97	44,53	0,96

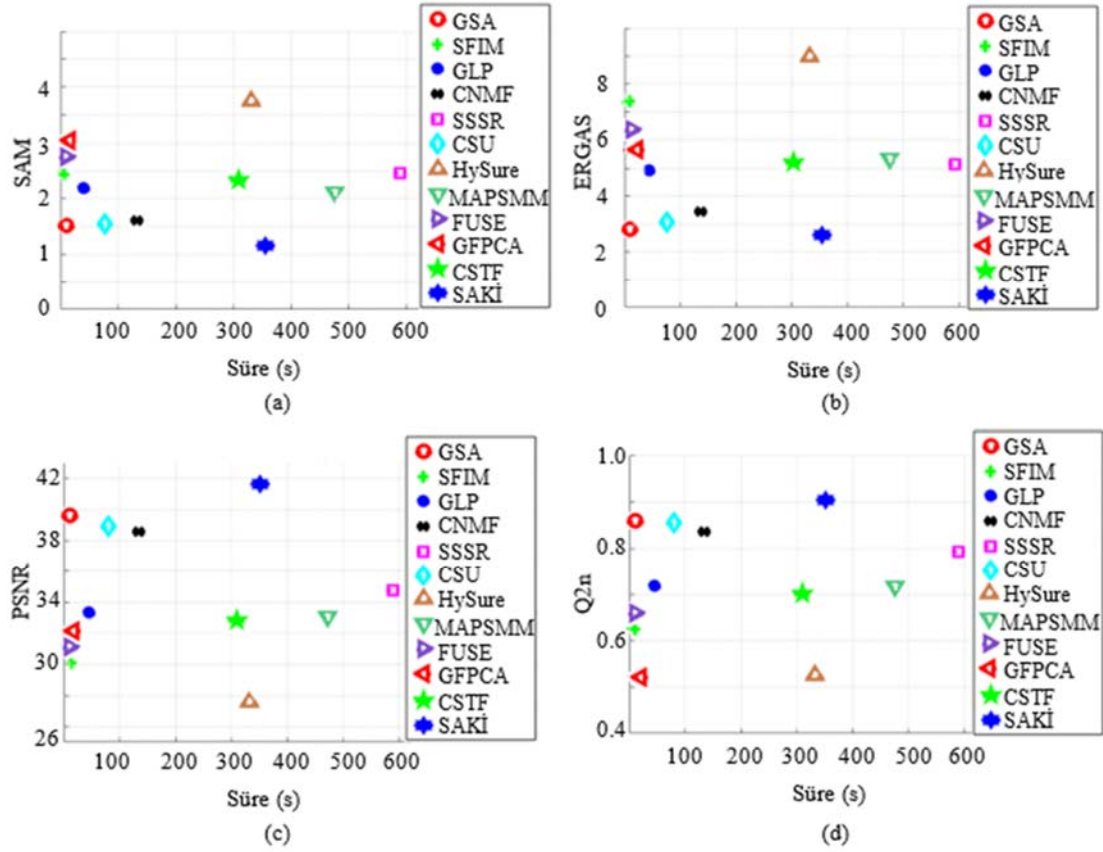
detayların korunumu ve görsel kalite açısından en kötü sonuçlar HySure yönteminde görülürken, SFIM yönteminde referans görüntüye bütünsel olarak en uzak sonuçlar elde edilmektedir.

Headwall Chikuhei veri kümesi tarım alanları ve kentsel yerleşimleri içermektedir. Headwall Chikuhei veri kümesi için en iyi başarımlar değerleri sırasıyla SAKİ, GSA, CNMF yöntemleri ile elde edilmektedir. Başarımları en düşük sonuçlar bütün ölçütler için HySure yönteminde görülmektedir.

Kullanılan veri kümelerinde tarım arazileri, kentsel yerleşimler, çok yıllık bitki örtüsü (orman), çıplak toprak, ağaçlık, çayır ve meyve-sebze dikim alanları bulunmaktadır. Ancak elde edilen sonuçlarda herhangi bir yöntemin belirli bir içeriğe sahip veri kümesi için daha iyi ya da daha kötü sonuç verdiği gözlenmemektedir. Sonuçların geneli değerlendirildiğinde, Bütün veri kümeleri için en iyi başarımlar değerleri önerilen SAKİ yaklaşımı ile elde edilmektedir. Önerilen yaklaşıma en yakın sonuçlar çoğunlukla GSA yöntemi ile elde edilmektedir. GSA yönteminde hızlı ve uygulanması kolay BD temelli bir yaklaşım izlenirken, önerilen SAKİ yöntemi daha yavaş ve

karmaşık yapıya sahip MA temelli bir yaklaşım izlemektedir. GSA yöntemi özellikle referans görüntüye olan bütünsel uzaklık bakımından (ERGAS) iyi sonuç vermektedir. Yine bütün veri kümeleri için en düşük başarımlar değerleri HySure yönteminde görülmektedir. Karşılaştırma amacıyla kullanılan yöntemlerin kodları literatürdeki çalışmaların yazarlarından temin edilmiştir. Bu sayede ilgili yöntemlerin gerçekleştirilmesinde oluşacak hataların önüne geçilerek başarımlar/harcanan süre açısından daha güvenilir bir karşılaştırma sağlanmıştır. Bu çalışma, 1,80 GHz hızındaki Intel Core i7-8550U işlemci ve 16 GB RAM'e sahip bilgisayarda gerçekleştirilmiştir. SAM, ERGAS, PSNR ve Q2<sup>n</sup> ölçütleri için dört veri kümesinde ortalama harcanan sürelerle ait grafikler, ortalama başarımlar/hata değerleri ile sırasıyla Şekil 8'de verilmektedir.

Önerilen SAKİ yönteminde katışım değerleri hesaplanırken ve kaynaştırma görüntüsü oluşturulurken her bir pikselin komşuluk piksellerinin etkisi dikkate alındığı için pikseller tek tek işlenmektedir. Bu yapısı nedeni ile harcanan süre literatürdeki bazı yöntemlerden oldukça fazla olmakla birlikte, bazı yöntemlere göre ise oldukça hızlıdır (Şekil 8).



Şekil 8. Kullanılan Yöntemlerin Ortalama Süre-Ortalama Metrik Değeri Grafikleri (a) Ortalama Süre - Ortalama SAM Hata Grafiği, (b) Ortalama Süre-Ortalama ERGAS Hata Grafiği, (c) Ortalama Süre-Ortalama PSNR Başarım Grafiği, (d) Ortalama Süre-Ortalama  $Q2^n$  Başarım Grafiği (Average Time-Average Metric Graph of the Given Methods, (a) Average Time-Average SAM Error Graph of the Given Methods, (b) Average Time-Average ERGAS Error Graph of the Given Methods, (c) Average Time-Average PSNR Accuracy Graph of the Given Methods, (d) Average Time-Average  $Q2^n$  Accuracy Graph of the Given Methods)

Önerilen yöntem ile literatürdeki yaklaşımlardan daha iyi kaynaştırma başarımı elde edilmektedir. Ancak önerilen yöntem sadece dört kat çözünürlük farkı olan HS ve MS görüntüler için kullanılabilir. İleriki çalışmalarda daha büyük ve ara kat çözünürlük farkları için komşu piksel etkisinin irdelenmesi planlanmaktadır. Daha büyük çözünürlük farkları için komşu piksel seçiminin kademeli olarak yapılması ve oluşturulan kaynaştırma görüntü piksellerinin yeni komşu pikseller olarak seçilmesi öngörülmektedir. Önerilen kaynaştırma yöntemi, sadece düşük uzamsal çözünürlüklü görüntü olduğu durumda Süper Çözünürlük çalışmasına da uyarlanabilir [38, 39].

## 5. Sonuçlar (Conclusions)

Sadece son eleman bilgisini kullanan kaynaştırma yaklaşımları görüntü genelinde oluşan aydınlanma oranlarındaki farklılıklardan etkilenebilmektedir [40]. Aynı zamanda homojen bölgelerdeki hedef pikseller son elemanlar yerine komşu pikseller ile daha iyi temsil edilebilmektedir. Sadece komşu piksellerin kullanılması durumunda ise anomali ya da komşulukları ile spektral benzerliği düşük hedeflerin yorumlanması eksik olacaktır. Bu nedenle, HS ve MS görüntülerin spektral ayrıştırma ve komşuluk etkisi temelli kaynaştırılması önerilmiştir. Önerilen yöntem, literatürde farklı tipte kaynaştırma yaklaşımları ile karşılaştırılmıştır. Gerçek HS görüntüler üzerinde yapılan değerlendirme sonuçlarına göre en yüksek doğruluk değerleri önerilen yöntem ile elde edilmektedir. Bu sonuçlar, kaynaştırma uygulamalarında komşuluk etkisinin dikkate alınmasının başarımı arttırdığını göstermektedir. Çalışma süresi açısından

önerilen yöntemin literatürde bulunan yöntemlere göre ortalama bir değere sahip olduğu söylenebilir. Ancak, önerilen yöntemin bazı adımları paralel hesaplamayı destekleyecek yapıdadır ve zaman tüketiminin daha önemli olduğu durumlarda performans iyileştirmesi yapılabilir. Bu aşamada sadece dört kat çözünürlük farkı için uygulanabilir olması önerilen yaklaşımın en büyük eksikliği olarak verilebilir. Ancak elde edilen sonuçlar daha yüksek çözünürlük farklarını da kapsayacak şekilde çalışmanın genişletilebileceğini göstermektedir. İleriki çalışmalarda, farklı çözünürlük farkları için önerilen yöntemin uyarlamalı yapıya taşınması ve çalışma süresini kısaltacak iyileştirmelerin yapılması planlanmaktadır.

## Kaynaklar (References)

1. 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, 2020.
2. Souza Jr,C., Firestone L., Silva L.M., Roberts D., Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models, Remote Sens. Environment, 87 (4), 494–506, 2003.
3. Licciardi G.A., Villa A., Khan M.M., Chanussot J., Image fusion and spectral unmixing of hyperspectral images for spatial improvement of classification maps, IEEE Int. Conf. Geosci. Remote Sens. (IGARSS), Munich, Germany, 7290–7299, 22-27 July 2012.
4. Simoes M., Bioucas Dias J., Almeida L., Chanussot J., A convex formulation for hyperspectral image superresolution via subspace-based regularization, IEEE Trans. Geosci. and Remote Sens., 53 (6), 3373–3388, 2015.

5. Wei Q., Bioucas Dias J.M., Dobigeon N., Tourneret J.Y., Hyperspectral and multispectral image fusion based on a sparse representation, *IEEE Trans. Geosci. and Remote Sens.*, 53 (7), 3658–3668, Sept. 2015.
6. Liu J.G. Smoothing Filter-based Intensity Modulation: A spectral preserve image fusion technique for improving spatial details, *International Journal of Remote Sensing*, 21 (18), 3461–3472, Jan. 2000.
7. Laben C.A., Brower B. V., Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening, Patent US 6 011 875 A, 2000.
8. Yokoya N., Yairi T., Iwasaki A., Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion, *IEEE Trans. Geosci. Remote Sens.*, 50 (2), 528–537, Feb. 2012.
9. Li S., Dian R., Fang L., Bioucas-Dias J.M., Fusing hyperspectral and multispectral images via coupled sparse tensor factorization, *IEEE Transactions on Image Processing*, 27 (8), 4118–4130, 2018.
10. Eismann M.T., Resolution enhancement of hyperspectral imagery using maximum a posteriori estimation with a stochastic mixing model, *IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data*, Greenbelt, MD, USA, 282-289, 27-28 October 2003.
11. Thomas C., Ranchin T., Wald L., Chanussot J., Synthesis of multispectral images to high spatial resolution: a critical review of fusion methods based on remote sensing physics, *IEEE Trans. Geosci. And Remote Sens.*, 46 (5), 1301–1312, May 2008.
12. Yokoya N., Grohnfeldt C., Chanussot J., Hyperspectral and Multispectral Data Fusion: A comparative review of the recent literature, *IEEE Geoscience and Remote Sensing*, 5 (2), 20-56, June. 2017.
13. Aiazzi B., Alparone L., Baronti S., Garzelli A., Selva M., MTFtailored multiscale fusion of high-resolution MS and Pan imagery, *Photogramm. Eng. Remote Sens.*, 72 (5), 591–596, May 2006.
14. Selva M., Aiazzi B., Butera F., Chiarantini L., Baronti S., Hypersharpener: A first approach on SIM-GA data, *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 8 (6), 3008–3024, Jun. 2015.
15. Liao W., Huang X., Coillie F., Gautama S., Pizurica A., Philips W., Liu H., Zhu T., Shimoni M., Moser G., Tuia D., Processing of multiresolution thermal hyperspectral and digital color data: Outcome of the 2014 IEEE GRSS data fusion contest, *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 8 (6), 2984-2996, June 2015.
16. Wei Q., Dobigeon N., Tourneret J.Y., Fast fusion of multi-band images based on solving a Sylvester equation, *IEEE Trans. Image Process.*, 24 (11), 4109–4121, Nov. 2015.
17. Akhtar N., Shafait F., Mian A., Sparse spatio-spectral representation for hyperspectral image super-resolution, *European Conference on Computer Vision (ECCV)*, Zurich, Switzerland, 63–78, 6-12 September, 2014.
18. Lanaras C., Baltasvias E., Schindler K., Hyperspectral superresolution by coupled spectral unmixing, in *Proc. IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 3586–3594, 07-13 December, 2015.
19. Alparone L., Wald L., Chanussot J., Thomas C., Gamba P., Bruce L.M., Comparison of pan sharpening algorithms: Outcome of the 2006 GRSS data fusion contest, *IEEE Trans. Geosci. Remote Sens.*, 45 (10), 3012-3021, Oct. 2007.
20. Du Q., Younan N., King R., Shah V., On the performance evaluation of pan-sharpening techniques, *IEEE Geosci. Remote Sens. Lett.*, 4 (4), 518-522, Oct. 2007.
21. Chang C.I., Du Q., Estimation of number of spectrally distinct signal sources in hyperspectral imagery, *IEEE Trans. on Geoscience and Remote Sensing*, 42 (3), 608-619, March 2004.
22. Irmak H., Akar G.B., Yuksel S.E., A MAP-Based Approach for Hyperspectral Imagery Super-Resolution, *IEEE Transactions on Image Processing*, 27 (6), 2942-2951, June 2018.
23. Irmak H., Akar G.B., Yuksel S.E., Fusion based resolution enhancement in hyperspectral images, *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya-Turkey, 1-4, 15-18 May, 2017.
24. Bioucas-Dias J., Nascimento J., Hyperspectral subspace identification, in *IEEE Transactions on Geoscience and Remote Sensing*, 46 (8), 2435-2445, 2005.
25. Nascimento J., Bioucas-Dias J., Vertex component analysis: a fast algorithm to unmix hyperspectral data, in *IEEE Transactions on Geoscience and Remote Sensing*, 43 (8), 898-910, 2005.
26. Heinz D., Chang C.-I., Fully constrained least squares linear mixture analysis for material quantification in hyperspectral imagery, *IEEE Trans. on Geoscience and Remote Sensing*, 39 (3), 529-545, March 2001.
27. He K., Sun J., Tang X., Guided image filtering, *IEEE Trans. Patt. Anal. Mach. Intell.*, 35 (6), 1397–1409, 2013.
28. Baumgardner M.F., Biehl L.L., Landgrebe D.A., 220 band aviris hyperspectral image data set: June 12, 1992 indian pine test site 3, Purdue University Research Repository, Sep 2015.
29. Computational Intelligence Group. Hyperspectral Remote Sensing Scenes. [https://www.ehu.eus/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](https://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes). Yayın tarihi Mayıs 20, 2011. Güncelleme tarihi Temmuz 12, 2021. Erişim tarihi Nisan 10, 2021.
30. Fauvel M., Benediktsson J.A., Chanussot J., Sveinsson J.R., Spectral and spatial classification of hyperspectral data using svms and morphological profiles. *IEEE Trans. on Geoscience and Remote Sensing* 46 (11), 3804–3814, 2008.
31. Li J., Bioucas-Dias J.M., Plaza A., Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Trans. on Geoscience and Remote Sensing* 48 (11), 4085–4098, 2010.
32. Yokoya N., Iwasaki A., Airborne hyperspectral data over Chikusei, Space Appl. Lab., Univ. Tokyo, Japan, Tech. Rep. SAL-2016-05-27, May 2016.
33. Wald L., Ranchin T., Mangolini M., Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting image, *Photogrammetric Engineering and Remote Sensing*, 63 (6), 691-699, 1997.
34. Roberta H.Y., Goetz A.F.H., Boardman J.W., Discrimination Among Semi-Arid Landscape Endmembers Using the Spectral Angle Mapper (SAM) Algorithm, *Summaries of the 4 th JPL Airborne Earth Science Workshop*, California-USA, 1, 147-149, 1992.
35. Wald L., Assessing the Quality of Synthesized Images, *Data Fusion Definitions and Architectures Fusion of images of different spatial resolutions*. Les Presses de l'Ecole des Mines, Paris, France, 159-163, 2002.
36. Eskicioglu A.M., Fisher P.S., Image quality measures and their performance, *IEEE Transactions on Communications*, 43 (12), 2959-2965, 1995.
37. Garzelli A., Nencini F., Hypercomplex quality assessment of multi/hyperspectral images, *IEEE Geosci. Remote Sens. Lett.*, 6 (4), 662–665, October 2009.
38. Çatalbaş M.C., Gülten A., A novel super-resolution approach for computed tomography images by inverse distance weighting method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 33 (2), 671–684, 2018.
39. Licciardi G.A., Veganzones M. A., Simoes M., Bioucas J., Chanussot J., Super-resolution of hyperspectral images using local spectral unmixing, *IEEE Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Lausanne, Switzerland, 1-4, 24-27 June, 2014.
40. Mei S., He M., Wang Z., Feng D., Spatial Purity Based Endmember Extraction for Spectral Mixture Analysis, *IEEE Transactions on Geoscience and Remote Sensing*, 48 (9), 3434-3445, 2010.