

# Hiperspektral Görüntülerde Kaynaştırma Temelli Çözünürlük Artırımı

## Fusion Based Resolution Enhancement in Hyperspectral Images

Hasan Irmak  
Aselsan A.Ş.  
Elektrik ve Elektronik Mühendisliği  
ODTÜ  
Ankara, Türkiye  
hirmak@aselsan.com.tr

Gözde Bozdağı Akar  
Elektrik ve Elektronik Mühendisliği  
ODTÜ  
Ankara, Türkiye  
bozdağı@metu.edu.tr

Seniha Esen Yüksel  
Elektrik ve Elektronik Mühendisliği  
Hacettepe Üniversitesi  
Ankara, Türkiye  
eyuksel@ee.hacettepe.edu.tr

**Özetçe** —Hiperspektral görüntüler (HSG) için düşük olan uzamsal çözünürlüklerinin artırılması, HSG'nin kullanıldığı uygulamalarda performans artışı sağlamaktadır. Bu çalışmada HSG'nin çözünürlüklerinin artırılması için kaynaştırma temelli bir yöntem önerilmiştir. Önerilen yöntemde düşük çözünürlüklü (DÇ) HSG ile yüksek çözünürlüklü (YÇ) RGB görüntü kaynaştırılarak YÇ HSG oluşturulmaktadır. Önerilen yöntem, hiperspektral imgeleri kullanan geleneksel yöntemlerin yerine, RGB görüntüyü ve HSG'nin son elemanlarına ayrıştırılmasından hesaplanan bolluk haritalarını birlikte kullanmakta ve bolluk haritaları üzerinden uzamsal çözünürlüğü artırmaktadır. Önerilen yöntemde öncelikle son elemanlar kestirilmiş ve DÇ bolluk haritaları çıkarılmıştır. DÇ bolluk haritaları ile YÇ RGB görüntü kullanılarak oluşturulan enerji fonksiyonu en aza indirilerek YÇ bolluk haritaları oluşturulmuştur. Son olarak, YÇ bolluk haritalarından YÇ HSG bulunmuştur. Yöntem gerçek HSG'lerde test edilmiştir. Bu metodun ana katkısı kaynaştırma problemini, bolluk haritaları alanında hiçbir varsayım veya önsel bilgi kullanmadan, ikinci dereceden bir optimizasyon problemine dönüştürmesidir. Önerilen yöntem kaynaştırma problemini varolan yöntemlere göre çok daha düşük işlem zamanı ve yakın performans ile çözmektedir.

**Anahtar Kelimeler**—Hiperspektral, Çözünürlük Artırma, Görüntü Kaynaştırma, Bolluk Haritaları

**Abstract**—Increasing the low spatial resolution of hyperspectral images (HSIs) improves the performance of applications in which the HSIs are used. In this study, a fusion based method is proposed to increase the resolution of HSIs. In the proposed method, low resolution (LR) HSI is fused with the high resolution (HR) RGB image to obtain the HR HSI. In this approach, instead of using the spectral images as in the conventional methods, RGB image is used with the abundance maps of the HSI estimated from the linear unmixing and the spatial resolution is enhanced using these maps. In this method, firstly, endmembers are estimated and LR abundance maps are obtained. Then, HR abundance maps are obtained by minimizing an energy function, which is constructed from the LR abundance maps with the HR RGB image. Finally, HR HSI is obtained from these HR abundance maps. The method is tested with real HSIs. Main contribution of the method is converting fusion problem to a quadratic optimization problem in the abundance map domain without any assumption or prior

knowledge. The proposed method solves the fusion problem with a computational time much lower than the state-of-the-art fusion based methods with a competing performance.

**Keywords**—Hyperspectral, Resolution Enhancement, Image Fusion, Abundance Maps

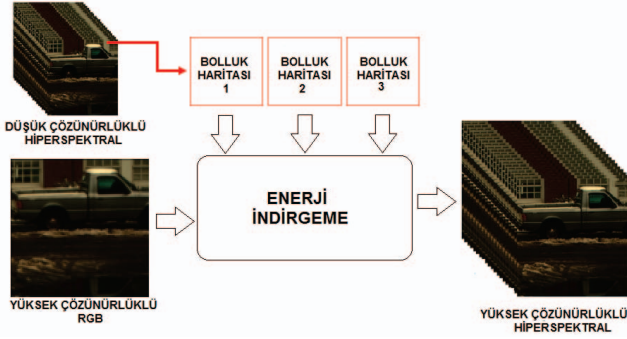
### I. GİRİŞ

Hiperspektral kameralar elektromanyetik spektrumdaki yüzlerce bantta görüntü alabilmektedir. Bu özellikleri sayesinde görüntüdeki maddeleri tanımlama olanağı sağlamaktadır. Sahip oldukları yüksek spektral çözünürlüklerine rağmen RGB ve multispektral kameralara kıyasla çok daha düşük uzamsal çözünürlüklere sahiptirler. Bu sebeple HSG'lerin çözünürlüklerinin iyileştirilmesi kullandığı uygulamalar için önem arz etmektedir.

Literatürde HSG'lerin çözünürlüklerinin artırılması için birçok yöntem önerilmiştir. Kütüphane temelli yöntemler oldukça popüler yöntemler arasındadır [1] [2]. Bu yöntemlerde öncelikle YÇ hiperspektral bir veri seti üzerinden verinin belli karakteristik özellikleri kullanılarak kütüphane verisi oluşturulur. Daha sonra DÇ HSG'nin belli bölümlerindeki aynı karakteristik özelliklerinin kütüphanedeki verilerden en iyi eşleşenleri belirlenir. Eşleşen veriler birleştirilerek YÇ görüntü elde edilir. Bu yöntemin en büyük dezavantajı performansının kütüphanenin oluşturulduğu veri kümesinin test edilen görüntüyle benzeşimine ciddi şekilde bağlı olmasıdır. Diğer bir yöntem ise doğrusal spektral katışım temelli yöntemdir. Bu yöntemde DÇ HSG'den doğrusal katışım modeliyle bolluk haritaları çıkarılır. Bolluk haritalarının bir pikseldeki değeri çevre piksellerdeki değerlerine göre değerlendirilerek YÇ bolluk haritaları elde edilir [3] [4]. Bu yöntemde görüntünün çözünürlüğü artırılırken YÇ bolluk haritalarının saf son eleman varsayımı kullanılmaktadır. Kısıtlı bir varsayım olduğu için performansı olumsuz etkilemektedir. Bu sebeple bu varsayımı kullanmadan çözünürlük artırma çalışmaları da yapılmıştır [5] [6] [7]. Kaynaştırma temelli yöntem de sıklıkla kullanılan bir yöntemdir [8] [9] [10]. Bu yöntemde ise YÇ RGB ya da

multispektral görüntü DÇ HSG ile kaynaştırılarak YÇ HSG görüntü elde edilmektedir.

Bu çalışmada HSG'lerin çözünürlüğünün artırılması için kaynaştırma temelli bir yaklaşım doğrusal spektral katışım temelli bir yöntemle belirlenen bolluk haritaları ile birlikte kullanılmıştır. Önerilen yöntemde öncelikle DÇ HSG'den DÇ bolluk haritaları bulunmaktadır. Elde edilen DÇ bolluk haritaları YÇ RGB görüntüyle birlikte bir enerji fonksiyonuna çevrilmiştir. Bu enerji fonksiyonun değeri indirgenerek YÇ bolluk haritaları hesaplanmıştır. Son olarak hesaplanan YÇ bolluk haritaları ve spektral imza matrisi kullanılarak YÇ HSG oluşturulmuştur. Yöntemin blok diyagramı Şekil-1'de görülmektedir. Bu yaklaşımda HSG'nin her bandındaki görüntüler yerine görüntüdeki son elemanların bolluk haritaları ve YÇ RGB görüntü çözünürlük artırımında beraber kullanılmıştır. Yöntemin en büyük avantajı bütün spektral bantlardaki görüntüleri bulmak yerine daha az sayıda bolluk haritasını bulmaya çalışarak çözüm kümesini daraltmasıdır. Bu sayede diğer kaynaştırma temelli yöntemlere göre daha iyi performans sağlamaktadır.



Şekil 1: Önerilen Yöntem

## II. YÖNTEM

YÇ RGB görüntü YÇ HSG'nin spektral olarak indirgenmiş halidir. Bu iki görüntü arasındaki ilişki (1)'de verilmiştir.

$$Z_{RGB} = Z_{HSI} R_{RGB}^T \quad (1)$$

Denklem (1)'de  $Z_{HSI}$  ve  $Z_{RGB}$  sırasıyla YÇ hiperspektral ve RGB görüntüleri ifade etmektedir.  $R_{RGB}$  ise kameranın spektral tepki fonksiyonu göstermektedir. YÇ RGB görüntüden YÇ HSG (2)'deki ifade kullanılarak elde edilir:

$$\hat{Z}_{HSI} = \arg \min_{Z_{HSI}} \|Z_{HSI} R_{RGB}^T - Z_{RGB}\|_l \quad (2)$$

Denklem (2)'de  $l$  normu göstermektedir.  $Z_{RGB}$  görüntüsü yüksek uzamsal çözünürlüğe sahip olmasına karşın düşük spektral çözünürlüğe sahiptir. Bu sebeple (2)'deki denklemi sağlayan birden fazla çözüm vardır. Çözüm kümesini daraltmak için farklı yöntemler kullanılabilir. En bilinen yöntemlerden biri toplam varyasyonu azaltma temelli bir yaklaşımdır [11]. Bu yaklaşımda görüntüyle ilgili önbilgiler kullanılarak çözüm kümesi daraltılmaya çalışılır. Diğer bir yöntem ise çözüm kümesindeki bilinmeyen sayısını azaltmaktır. HSG'ler

çok sayıda bantta görüntüden oluşmasına rağmen bantlar arası benzeşim çok fazla olduğu için daha az sayıda parametre ile tanımlanabilir. Doğrusal katışım modeline göre HSG içerdiği maddelerin spektral karakteristiklerinin ağırlıklı toplamı şeklinde yazılabilir. HSG'de ayrıştırılan bu maddeler son eleman olarak tanımlanır. Son elemanların görüntüdeki pikseller içindeki oranları ise bolluk haritaları olarak ifade edilir. Başka bir deyişle doğrusal katışım modeli kullanılarak, YÇ HSG bolluk harita matrisi ve spektral imza matrisinin çarpımı şeklinde yazılabilir. Buna göre (1)'deki ifade, (3)'deki gibi yazılabilir.

$$Z_{RGB} = A_Z P R_{RGB}^T \quad (3)$$

Denklem (3)'de  $E$  son eleman sayısını,  $p$  spektral bant sayısını ve  $N$  bir banttaki görüntü boyutunu göstermek üzere  $A_Z$   $N \times E$  boyutlarında bolluk haritaları matrisi,  $P$  ise  $E \times p$  boyutlarındaki spektral imza matrisidir.

YÇ HSG son elemanların spektral imzaları ve bolluk haritalarının toplamı şeklinde de yazılabilir:

$$A_Z P = A_Z(1)(P^T(1))^T + \dots + A_Z(E)(P^T(E))^T \quad (4)$$

Bolluk haritalarını da tek bir sütun vektörü şeklinde yazabiliriz:

$$z \triangleq \begin{bmatrix} A_z(1) \\ A_z(2) \\ \vdots \\ A_z(E) \end{bmatrix} \quad (5)$$

Denklem (4) ve (5)'deki ifadeler kullanılarak YÇ RGB görüntü, bolluk haritaları kullanılarak ifade edilebilir:

$$Z_{RGB} = W_{RGB} z \quad (6)$$

Denklem (6)'daki  $W_{RGB}$  RGB kameranın spektral tepki fonksiyonundan ve DÇ HSG'den doğrusal katışım modeli kullanılarak bulunan spektral imza matrisinin çarpımından elde edilen ağırlık matrisidir. Bu sayede (2)'deki ifade (7) şeklinde yazılabilir.

$$\hat{z} = \arg \min_z \|W_{RGB} z - Z_{RGB}\|_l \quad (7)$$

Denklem (7)'deki ifade de Frobenious norm ( $l=2$ ) kullanıldığımızda ifade (8)'e dönüşür.

$$\hat{z} = \arg \min_z [z^T W_{RGB}^T W_{RGB} z - 2 Z_{RGB}^T W_{RGB} z] \quad (8)$$

Denklem (8)'in (2)'ye göre iki temel avantajı vardır. İlk avantajı sistemin çözüm kümesindeki bilinmeyen sayısını spektral bant sayısının son eleman sayısına oranı kadar düşürmesidir. Bu sayede çözüm kümesi daralmıştır. Bir diğer avantajı ise sistemin ikinci dereceden bir indirgeme problemine dönüştürülmesidir. Bu sayede sistem ikinci dereceden programlama teknikleri kullanılarak çözülebilmektedir.

İkinci dereceden programlama teknikleri ile en düşük noktası bulunan (8) YÇ bolluk haritalarını vermektedir. YÇ bolluk haritaları ve spektral imza matrisinin çarpımından YÇ HSG oluşturulmaktadır.

### III. DENEYSSEL SONUÇLAR

Önerilen yöntem Cave ve Harvard hiperspektral veri kümeleri üzerinde test edilmiştir. Cave veri kümesi 32 adet 400-700 nm bandındaki iç ve dış ortam görüntülerinden oluşmaktadır [12]. Cave veri kümesindeki görüntülerin tamamı kullanılmıştır. Harvard veri kümesi ise 50 adet 420-720 nm bandındaki görüntülerden oluşmaktadır [13]. Harvard veri kümesinin bazı görüntülerindeki bazı bölgelerinde görüntü oynaması olduğu için maskeleme vardır. Bu yüzden testlerde görüntü merkezinin 256x256 piksel bölgesinde maskeleme olmayan 30 adet görüntü kullanılmıştır. İki veri kümesinin de görüntü merkezinin 256x256 piksel bölgesi kullanılmıştır. Bu bölgelere bulanıklaştırma ve veri indirgeme işlemlerinden sonra 30 dB Gaussian gürültü eklenerek DÇ HSG'ler elde edilmiştir. Kaynaştırma işlemi kullanılan YÇ RGB görüntü ise örnek bir kamera filtre fonksiyonu kullanılarak hiperspektral veri setlerinden elde edilmiştir. Yöntemin performansı diğer hiperspektral çözünürlük yöntemlerine göre daha iyi performans veren Lanaras *et al.*'ın yöntemi ile karşılaştırılmıştır [14]. Karşılaştırılan yöntemin seçilme sebebi güncel beş farklı hiperspektral çözünürlük artırma yöntemine göre daha iyi performans göstermesidir [14]. Performans karşılaştırması PSNR, SSIM ve SAM metrikleriyle yapılmıştır.

PSNR olabilecek en yüksek güç miktarının gürültüye oranı olarak tanımlanır [15]. Her ikisi de piksel başına  $b$  bit olarak kodlanmış tahmin edilen bir  $y$  görüntüsü ve referans  $x$  görüntüsü için, PSNR şöyle tanımlanır:

$$PSNR = 10 \log_{10} \left( \frac{2^b - 1}{\frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [x(i, j) - y(i, j)]^2} \right) \quad (9)$$

SSIM metriği insanın görsel algısına daha uygun bir metriktir. Yapısal bilgilere daha duyarlı bir karşılaştırma yapmak için kullanılır [16]. SSIM metriği ise aşağıdaki şekilde tanımlanır:


$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2\mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (10)$$

Denklem (10)'daki  $\mu_x$  ve  $\mu_y$ ,  $x$  ve  $y$  görüntülerinin ortalamasıdır.  $\sigma_x^2$ ,  $\sigma_y^2$  ve  $\sigma_{xy}$  sırasıyla  $x$  ve  $y$ 'nin varyansları ve kovaryanslarıdır.  $C_1$  ve  $C_2$  kararsız sonuçları engellemek için kullanılan katsayılardır [16].

SAM metriği hiperspektral görüntülerde sıklıkla kullanılan bir metriktir. SAM, tahmin edilen  $x(i)$  görüntüsündeki  $i$  pikseli ve referans  $y(i)$  görüntüsündeki  $i$  pikseli arasındaki açının görüntü boyunca ortalamasıdır [17]. SAM metriğinin birimi açıdır ve (11)'de verilmiştir. Denklemde  $N$  görüntüdeki piksel sayısını göstermektedir. PSNR ve SSIM metriklerinin aksine düşük SAM değeri daha iyi eşleşmeyi gösterir.

$$SAM(x, y) = \frac{1}{N} \sum \arccos \frac{x(i)^T y(i)}{\|x(i)\|_2 \|y(i)\|_2} \quad (11)$$

Veri setlerindeki yapılan testlerin sonuçları Tablo-I ve Tablo-II'de verilmiştir. Tablodaki sonuçlara bakıldığında Cave veri kümesinde kullanılan metrikler açısından önerilen yöntemin Lanaras *et al.*'ın yöntemine çok yakın bir performans sergilediği görülmektedir. Harvard veri kümesinde ise önerilen yöntem kullanılan metrikler açısından Lanaras *et al.*'a göre daha iyi performans sergilemiştir. Şekil-2 ve Şekil-3 ise iki veri setinden örnek görsel sonuçları göstermektedir.



Şekil 2: Cave veri kümesinden bir görüntü

TABLO I: Cave veri kümesi için deney sonuçları

	PSNR	SSIM	SAM
Lanaras <i>et al.</i>	<b>35.492</b>	<b>0.967</b>	<b>0.072</b>
Önerilen Yöntem	35.212	0.932	0.087

TABLO II: Harvard veri kümesi için deney sonuçları

	PSNR	SSIM	SAM
Lanaras <i>et al.</i>	33.397	0.902	0.063
Önerilen Yöntem	<b>35.668</b>	<b>0.908</b>	<b>0.062</b>

Önerilen yöntemin en büyük avantajlarından biri de gelişmiş metotlara göre kaynaştırma problemini çok daha düşük işlem zamanı ile çözmesidir. Veri kümelerindeki yapılan deneylerin toplam süreleri Tablo-III'te verilmiştir. Tablodaki



(a) Yüksek Çözünürlüklü Görüntü



(b) Düşük Çözünürlüklü Görüntü



(c) Lanaras *et al.*



(d) Önerilen Yöntem

Şekil 3: Harvard veri kümesinden bir görüntü

sonuçlara bakıldığında önerilen yöntemin Lanaras *et al.*'in yöntemine göre iki kata yakın zaman avantajı sağladığı görülmektedir.

TABLO III: Yapılan Deneylerdeki Toplam Ölçüm Süreleri

	Cave (32 görüntü)	Harvard (30 görüntü)
Lanaras <i>et al.</i>	96 dakika	61 dakika
Önerilen Yöntem	<b>49 dakika</b>	<b>31 dakika</b>

#### IV. SONUÇ

Bu çalışmada kaynaştırma temelli bir yöntem doğrusal katişım uygulanarak elde edilen bolluk haritalarıyla birleştirilerek HSG'lerin çözünürlüğünün artırılması amaçlanmıştır. Önerilen yöntem, YÇ RGB görüntüsü ve bolluk haritalarını beraber kullanarak HSG'nin çözünürlüğünü artırmaktadır. Yöntemde öncelikle DÇ bolluk haritaları bulunmaktadır. Bu haritaları ve YÇ RGB görüntüyü kullanarak bir enerji fonksiyonu tanımlanmıştır. Enerji fonksiyonun minimum değeri bulunarak YÇ bolluk haritaları elde edilmiştir. Son olarak, YÇ görüntü, YÇ bolluk haritalarından oluşturulmaktadır. Önerilen yöntem gerçek hiperspektral veri kümelerinde test edilerek varolan modern ve gelişmiş yöntemlere göre PSNR, SSIM ve SAM metrikleriyle karşılaştırıldığında Harvard veri kümesinde performans artışı, Cave veri kümesinde ise çok yakın performans sergilediği görülmüştür. Ayrıca önerilen yöntem karşılaştırılan yöntemlere göre iki kata yakın zaman avantajı sağlamaktadır.

#### KAYNAKLAR

[1] W. Huang, Z. Wu, H. Liu, L. Xiao, and Z. Wei, "Spatial-spectral compressive sensing for hyperspectral images super-resolution over learned dictionary," in *Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International*. IEEE, 2014, pp. 4930–4933.

[2] M. A. Veganzones, M. Simoes, G. Licciardi, N. Yokoya, J. M. Bioucas-Dias, and J. Chanussot, "Hyperspectral super-resolution of locally low rank images from complementary multisource data," *IEEE Transactions on Image Processing*, vol. 25, no. 1, pp. 274–288, 2016.

[3] A. Villa, J. Chanussot, J. A. Benediktsson, M. Ulfarsson, and C. Jutten, "Super-resolution: an efficient method to improve spatial resolution of hyperspectral images," in *Geoscience and Remote Sensing Symposium (IGARSS), 2010 IEEE International*. IEEE, 2010, pp. 2003–2006.

[4] Z. Guo, T. Wittman, and S. Osher, "L1 unmixing and its application to hyperspectral image enhancement," in *SPIE Defense, Security, and Sensing*. International Society for Optics and Photonics, 2009, pp. 73 341M–73 341M.

[5] H. Irmak, G. B. Akar, and S. E. Yuksel, "A map-based approach to resolution enhancement of hyperspectral images," in *IEEE workshop on hyperspectral image and signal processing (WHISPERS)*. IEEE, 2015.

[6] H. Irmak, G. B. Akar, and S. E. Yuksel, "Hiperspektral görüntülerde süperçözünürlük," in *2016 24. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*. IEEE, 2016, pp. 1057–1060.

[7] H. Irmak, G. B. Akar, S. E. Yuksel, and H. Aytaylan, "Superresolution reconstruction of hyperspectral images via an improved map-based approach," in *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. IEEE, 2016.

[8] Y. Zhao, Y. Yang, Q. Zhang, J. Yang, and J. Li, "Hyperspectral imagery super-resolution by image fusion and compressed sensing," in *Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International*. IEEE, 2012, pp. 7260–7262.

[9] H. Kwon and Y.-W. Tai, "Rgb-guided hyperspectral image upsampling," in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, pp. 307–315.

[10] N. Yokoya, T. Yairi, and A. Iwasaki, "Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 2, pp. 528–537, 2012.

[11] R. Leonid I., S. Osher, and E. Fatemi, "Nonlinear total variation based noise removal algorithms," *Physica D: Nonlinear Phenomena*, vol. 60, no. 1-4, pp. 259–268, 1992.

[12] F. Yasuma, T. Mitsunaga, D. Iso, and S. K. Nayar, "Generalized assorted pixel camera: Postcapture control of resolution, dynamic range, and spectrum," *IEEE Transactions on Image Processing*, vol. 19, no. 9, pp. 2241–2253, 2010.

[13] A. Chakrabarti and T. Zickler, "Statistics of real-world hyperspectral images," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 193–200, 2011.

[14] C. Lanaras, E. Baltsavias, and K. Schindler, "Hyperspectral super-resolution by coupled spectral unmixing," in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, pp. 3586–3594.

[15] A. Horé and D. Ziou, "Image quality metrics: PSNR vs. SSIM," *Proceedings - International Conference on Pattern Recognition*, pp. 2366–2369, 2010.

[16] Z. Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli, "Wavelets for Image quality assessment: From error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, 2004.

[17] S. Rashmi, S. Addamani, and S. Ravikiran, "Spectral Angle Mapper Algorithm for Remote Sensing Image Classification," *International Journal of Innovative Science, Engineering & Technology*, vol. 1, no. 4, pp. 201–205, 2014.