

Hiperspektral Görüntülerde Gürültülü Bantların Bilişim Kuramsal Tespiti

Information-Theoretic Noisy Band Detection in Hyperspectral Imagery

Mustafa Ergül, Fatih Nar, Emre Akyılmaz, Nigar Şen
 Uzay ve Savunma Teknolojileri (SDT)
 Ankara, Türkiye
 {mergul, fnar, eakyilmaz, nsen}@sdt.com.tr

Müjdat Çetin
 Sabancı Üniversitesi
 İstanbul, Türkiye
 mcetin@sabanciuniv.edu

Özetçe—Hiperspektral görüntüler farklı dalga boylarında ait oldukları materyaller ile ilgili spektral bilgiler taşıyan arduşk yüzlerce banttan oluşmaktadır. Bununla birlikte, atmosferik etkiler ve sensör yapısı gibi pratik faktörlerden dolayı bazı spektral bantlar yüksek seviyede gürültü içermektedir. Bu bildiride, gürültülü bantları otomatik ve etkin olarak tespit eden karşılıklı bilgi miktarı kavramına dayalı bir algoritma önerilmiştir. Önerilen yaklaşımın etkinliği ve doğruluğu AVIRIS ve TELOPS sensörleri ile toplanan hiperspektral verilerle doğrulanmıştır. Test sonuçları önerilen yaklaşımın diğer algoritmalarla göre daha üstün performans sergilediğini göstermektedir.

Anahtar Kelimeler — gürültü azaltma; gürültülü bant tespiti; karşılıklı bilgi miktarı; bilişim kuramı; hiperspektral görüntü işleme.

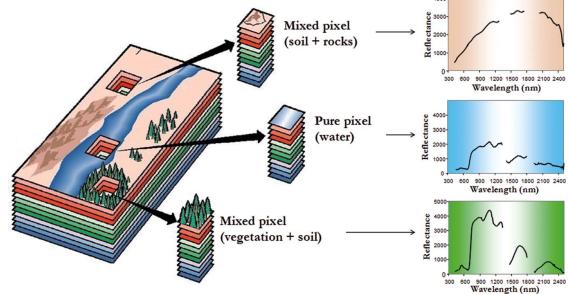
Abstract—Hyperspectral imagery consists of hundreds of successive bands that carry spectral information about the underlying materials at various wavelengths. However, due to practical factors such as atmospheric effects and sensor characteristics, some spectral bands contain high amounts of noise. In this paper, an effective information-theoretic algorithm based on mutual information that automatically detects such noisy bands is proposed. The effectiveness and accuracy of the proposed approach is validated on hyperspectral images collected by the AVIRIS and TELOPS sensors. Experimental results show that the proposed method outperforms the other algorithms in the literature.

Keywords — hyperspectral denoising; noisy band detection; mutual information; information theory; hyperspectral image processing.

I. GİRİŞ

Son yıllarda meydana gelen teknolojik gelişmelerle birlikte hiperspektral görüntüleme sistemlerinin tarım, mineralojisi, jeoloji, çevrebilim, savunma sanayii vb. alanlara ait çeşitli uzaktan algılama uygulamalarında

kullanımı hızla yaygınlaşmaktadır. Geleneksel görüntüleme tekniklerinin aksine, hiperspektral veriler yüzlerce arduşk dar bant aralıklarından toplanmış spektral bilgilerden oluşmaktadır (Şekil 1). Bu sayede, farklı materyaller için farklı spektral imzalar içeren çok bantlı verilerden materyal tanıma ve hedef tespiti gibi uygulamaları daha başarılı bir şekilde gerçekleştirmeye kapasitesine sahip güçlü bir araç ortaya çıkmaktadır.



Şekil 1: Hiperspektral görüntülemede veri küpü yapısı ve spektral imza örneği [1].

Bununla birlikte, atmosferik etkiler ve sensör yapısı gibi faktörlerden dolayı hiperspektral (HS) verilerde hem uzamsız hem de spektral boyutta farklı seviyelerde gürültü meydana gelmektedir. Bu gürültülerin varlığı, eldeki verinin görselliliğini bozmasının yanı sıra görüntü üzerinde gerçekleştirilecek sınıflandırma, spektral ayırtırma, hedef tespiti gibi işlemlerin performansını da düşürmektedir. Bu yüzden, hiperspektral verilerdeki gürültülerin azaltmak ve ardından gelebilecek olası işlemlerden önce veri kalitesini yükseltmek hayatı önem taşımaktadır.

HS verilerde var olan en kritik gürültü; yansıtıcı spektral bant bölgelerinde atmosferdeki oksijen ve su buharı parçacıklarının varlığından, yayıcı spektral bant bölgesinde ise sensör yapısından kaynaklanmaktadır. Düşük sinyal-gürültü oranına (SGO) sahip ve materyalle ilgili herhangi bir bilgi taşımayan bu spektral bantlar, olası görüntü analizi işlemlerine geçmeden önce atılmalıdır.

Literatürdeki çalışmalarında genellikle bu bantlar araştırıcı tarafından manuel olarak atılmaktadır. Ama bu işlem çok sayıda veri içeren durumlarda hem çok yorucu olmakta hem de tam otomatik bir sistem geliştirilmesini imkânsız hale getirmektedir. Son yıllarda bu sorunun üstesinden gelmek için düşük SGO değerine sahip gürültülü bantları otomatik olarak tespit eden ve veriden çıkarılan metotlar önerilmeye başlanmıştır. [2,3]'te spektral bantlar arasındaki ilinti katsayısı kullanılarak gürültülü bantlar belirlenmeye çalışılmıştır. Bu algoritmaların temel yaklaşım ilinti katsayısının ardışık temiz bantlar arasında yüksek, ardışık gürültülü bantlar arasında ise düşük değerlere sahip olacağı perspektifine dayanmaktadır. Nguyen ve arkadaşı [3], ilinti katsayısını uzamsal bilgiyi dikkate almadan global olarak hesaplarken; Bhushan ve diğerleri [2] ise bantlar arasındaki ilintiyi uzamsal bilgileri de göz önünde bulundurarak bloklar arasında hesaplamaktadır. Bir diğer çalışmada [4], dördün ağaç veri yapısı ve oransal kırılma boyutu kavramı benimsenerek verinin uzamsal boyutta yerel özelliklerini hesaba katan bir yöntem önerilmiştir.

Şu ana kadar literatürde önerilen yöntemler, iki rastgele değişkenin doğrusal ilişkisini ölçen ilinti katsayısına dayalı olduğu için gürültülü bantların belirlenmesinde yetersiz kalmaktadır. Bu çalışmada ise, bahsedilen problemin üstesinden gelmek için bantlar arasındaki doğrusal olmayan ilişkileri de hesaba katan karşılıklı bilgi miktarı (KBM) kavramına dayalı bir algoritma önerilmiştir. Bilişim kuramı alanında yaygın olarak kullanılan bu kavram hiperspektral görüntülerde boyut azaltma amacıyla bant seçme işleminde de kullanılmaktadır [5,6]. Bu yöntemlerde, yer gerçekliği gibi bir referans verisiyle yüksek seviyede istatistiksel benzerlik gösteren spektral bantlar “*anlamlı bantlar*” olarak seçilir.

Bildirinin bundan sonrası şu şekilde organize edilmiştir. Bölüm 2'de KBM kavramı ve bu kavrama dayalı gürültülü bantların tespiti için önerilen algoritma anlatılmıştır. Deneyler sırasında kullanılan veri kümelerinin özelliklerinden Bölüm 3'te bahsedilmiştir. Bölüm 4, önerilen algoritmanın performans analizini içeren deney sonuçlarını sunmaktadır. Son olarak, bildiri sonuç ve gelecek çalışmalar ile sonlandırılmıştır.

II. ÖNERİLEN ALGORİTMA

A. Karşılıklı Bilgi Miktarı

Karşılıklı bilgi miktarı (KBM), iki rastgele değişken arasındaki istatistiksel bağımlılığı ölçmek için kullanılan bilişim kuramı alanındaki temel kavamlardan biridir. Birleşik olasılık dağılımı $p_{AB}(a, b)$, marginal olasılık dağılımı $p_A(a)$ ve $p_B(b)$ olarak verilen iki rastgele değişken A ve B için KBM değeri aşağıdaki gibi hesaplanır:

$$I(A, B) = \sum_{a,b} p_{AB}(a, b) \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)} \quad (1)$$

Ayrıca, Shannon entropisi tanımı kullanılarak Denklem (1) entropi cinsinden aşağıdaki gibi de ifade edilebilir.

$$\begin{aligned} I(A, B) &= H(A) + H(B) - H(A, B) \\ &= H(A) - H(A|B) = H(B) - H(B|A) \end{aligned} \quad (2)$$

Bu ibarede, $H(A)$ ve $H(B)$ marginal entropi değerlerini, $H(A, B)$ birleşik entropi değerini, $H(A|B)$ ve $H(B|A)$ ise koşullu entropi değerlerini belirtmektedir.

Sezgisel olarak ise, KBM A ve B rastgele değişkenlerinin paylaştığı bilgi miktarını ölçmektedir. Yani, bir değişken gözlendiğinde veya bilindiğinde diğer değişkenin belirsizliğinin ne kadar azaldığını ölçmektedir. Ilinti katsayısından farklı olarak, KBM iki rastgele değişkenin ilişkisinin doğrusal olup olmadığı ile ilgilenmemektedir. Diğer bir fark ise; ilinti katsayısı değişkeni olasılık dağılımına ihtiyaç duyulmadan ikinci dereceden momentler kullanılarak hesaplanırken, KBM değişkeninin olasılıksal dağılım bilgisini de hesaba katarak bir değer üretmesidir.

B. Gürültülü Bantların Belirlenmesi

HS veriler dar spektral genişliğe sahip çok sayıda banttan oluştugundan, ardışık bantlar çoğu zaman benzer bilgiler taşımaktadır. Bununla birlikte, bu olgusal gerçeklik düşük SGO'ya sahip gürültülü bantlarda sağlanamamaktadır. Gürültülü bantların tespiti işlemi bu gözleme dayanarak, ardışık spektral bantlar arasındaki benzerliği ölçen KBM metriği vasıtasiyla gerçekleştirilir.

KBM metriğinin hesaplanması sırasında, ihtiyaç duyulan marginal ve birleşik olasılık dağılımlarının kaba birer kestirimi olarak, her banttaki piksel değerlerinden oluşturulan marginal ve birleşik histogramlar kullanılmaktadır. Her bir spektral bandın ardışık spektral bantlara benzerliği aşağıdaki gibi hesaplanmaktadır:

$$d(i) = \max(I(i, i-1), I(i, i+1)) \quad (3)$$

i , spektral bant numarasını; I , karşılıklı bilgi değerini; $d(i)$ ise ilgili bandın komşu bantlarına benzerlik seviyesini temsil etmektedir. Yukarıda hesaplanan benzerlik değeri ne kadar düşük ise ilgili spektral bandın gürültülü bant olarak belirlenme olasılığı o oranda artmaktadır. Bu yüzden, herhangi bir spektral bant bir önceki veya sonraki spektral banda benzerlik gösteriyorsa o bant gürültüsüz olarak işaretlenir.

Ayrıca, bazı HS verilerde kötü veya eksik piksellerden ötürü çok miktarda tuz-biber gürültüsü meydana gelmektedir. Bu gürültü tipi, ilgili pikselin bütün bantlarında meydana geldiği için normalde yüksek seviyede benzerlik gösteren spektral bantların KBM değerleri ve dolayısıyla benzerlik değeri düşebilmektedir. Bu yüzden, bu çalışmada benzerlik hesaplamasına geçmeden önce uzamsal boyuttaki tuz-biber gürültü

pikselleri her bir bant için medyan filtre ile temizlenmektedir.

III. HİPERSPETRAL TEST VERİSİ KÜMESİ

Önerilen algoritmanın performans analizini gerçekleştirmek için AVIRIS ve TELOPS sensörleri ile toplanmış 4 farklı veri kümesi kullanılmıştır. AVIRIS sensörü tarafından toplanan ve literatürde yoğun bir şekilde kullanılan "Indian Pines" ve "Salinas" adlı veriler, yansıtılık spektral bant bölgesinde dalga boyu 0.4 - 2.5 μm aralığında 224 spektral banttan oluşmaktadır. Indian Pines verisi düşük uzamsal çözünürlüğe sahip olup 145x145 piksel, yüksek çözünürlüklü ($\sim 3.7 \text{ m/pixel}$) Salinas verisi ise 512x217 piksel içermektedir. Yayıçılık spektral bant bölgesinde bilgi içeren TELOPS verileri ise dalga sayısı yaklaşık olarak $800 - 1350 \text{ cm}^{-1}$ aralığında 165 ve 660 adet spektral bant içeren iki veri kümelerinden oluşmaktadır. Yerden toplanan bu veriler yüksek çözünürlüklü olup 320x256 piksel içermektedir. İçerik olarak, 660 bantlı veri çeşitli gömülü hedeflerin yerleştirildiği toprak ve taşları; 165 bant içeren veri ise bina ve arabaların yer aldığı bir şehir merkezini kapsamaktadır.

Indian Pines ve Salinas veri kümeleri, atmosferik etkilerden ve sensör yapısından kaynaklı sırasıyla 32 ve 21 gürültülü bant içermektedir. TELOPS verilerinin gürültülü bant sayısı ise 18/165 ve 90/660 olarak belirlenmiştir.

IV. DENEYSEL SONUÇLAR

Önerilen yaklaşımın geçerliliğini doğrulamak ve literatürdeki diğer yaklaşılara göre etkinliğini kanıtlamak için çeşitli testler gerçekleştirilmiştir. Yer gerçekliği belirlenmesi sırasında, su sogurma spektral bölgesindeki ve yüksek gürültü seviyesine sahip spektral bantlar gürültülü bant sınıfı; diğer bantlar ise bilgi verici veya temiz bant sınıfı olarak işaretlenmiştir. Performans değerlendirmesi sırasında her algoritma sonucu için yer gerçekliğine göre kesinlik-geri getirme eğrisi (KGE) üretilmiştir ve kıyaslama bu eğriler üzerinden yapılmıştır. Her bir banda ait benzerlik değeri üzerinden eşikleme işlemi gerçekleştirilerek eğri üzerindeki farklı çalışma noktaları elde edilmiştir.

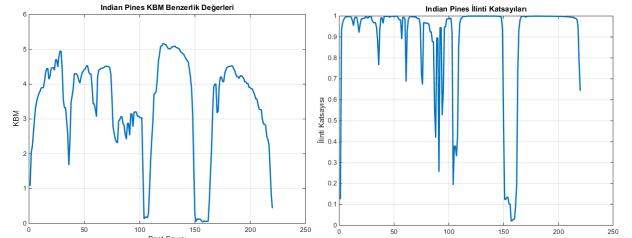
Önerilen yaklaşımın diğer yöntemlere göre üstünlüğünü doğrulamak için literatürde yaygın olarak kullanılan ilinti katsayısı ve sinyal-gürültü oranı (SGO) karşılaştırma için kullanılmıştır. Ilinti katsayısına dayalı benzerlik değeri şu şekilde hesaplanmıştır:

$$\rho(i, i+1) = \frac{E[(A_i - \mu_i)(A_{i+1} - \mu_{i+1})]}{\sigma_i \cdot \sigma_{i+1}} \quad (4)$$

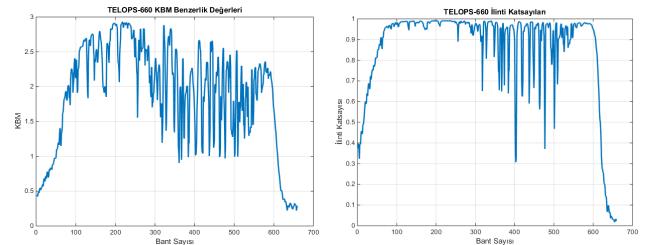
Denklem 4'te $\rho(i, i+1)$, i . ve $(i+1)$. bantlar arasındaki ilinti katsayısını; A_i , verinin i . bandını; μ_i , i . bandın ortalama değerini; σ_i , i . bandın standart sapmasını temsil etmektedir. İlgili banda ait benzerlik değeri ise KBM hesaplamasında olduğu gibi hesaplanmıştır.

$$d_\rho(i) = \max(\rho(i, i-1), \rho(i, i+1)) \quad (5)$$

Indian Pines ve TELOPS-660 veri kümesi kullanılarak elde edilen KBM benzerlik değeri ve ilinti katsayısı benzerlik değeri grafikleri Şekil 2 ve Şekil 3'te gösterilmektedir.



Şekil 2: Indian Pines verisine ait KBM (soldaki) ve İlinti katsayısı benzerlik değeri (sağdaki).



Şekil 3: TELOPS-660 verisine ait KBM (soldaki) ve İlinti katsayısı benzerlik değeri (sağdaki).

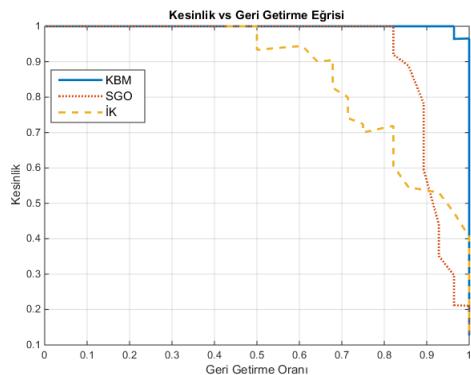
İlgili çizgiler dikkatlice incelendiğinde, ilinti katsayısına dayalı benzerlik değerlerinin KBM katsayısına dayalı yöntemden farklı olarak temiz veya bilgi taşıyan bantlarda da (Indian Pines: 80-95, TELOPS-660: 300:500) düşük değerlere sahip olduğu görülmektedir. Bundan dolayı, ilinti katsayısına dayalı gürültülü bantların tespiti sonucunda çok sayıda yanlış alarm meydana gelmektedir. İlinti katsayısı yerine KBM değerlerinin kullanılması sonucunda ise algoritmanın kesinlik oranının arttığı gerçekleştirilen deneyler sonucunda da ortaya çıkmaktadır.

Testler sırasında kullanılan diğer bir karşılaştırma yöntemi, bir sinyaldeki gürültü seviyesini ifade eden sinyal-gürültü oranı metrigine dayanmaktadır. Bu yaklaşımında, düşük SGO değerli bantlar gürültülü bant olarak işaretlenmektedir. SGO değerlerinin kestirilmesi sırasında ise referans görüntüyü olarak her bir banda ayrı ayrı uygulanan Wiener süzgeç sonucu kullanılmaktadır.

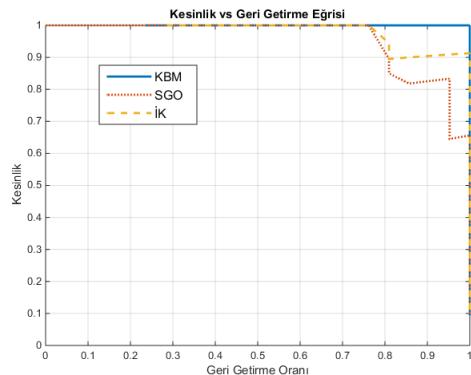
$$SGO(i) = \frac{w(A_i)^2}{(A_i - w(A_i))^2} \quad (6)$$

$w(\cdot)$, Wiener filtreyi; A_i , HS verinin i . bandını belirtmektedir. Filtre çıkışının enerjisi sinyal enerjisi, orijinal veri ile滤re çıkışının farkının enerjisi de gürültü enerjisi olarak değerlendirilmiştir.

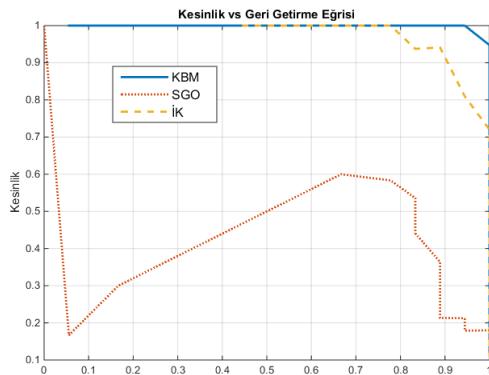
Önerilen yaklaşımın ve diğer iki algoritma sonucunun kesinlik-geri getirme eğrisi her bir veri kümesi için Şekil 4 - 7'de sunulmuştur. Bu grafiklerde sunulan test sonuçlarından da görüldüğü üzere önerilen yöntem hem SGO hem de İK tabanlı yaklaşılardan istikrarlı bir şekilde daha üstün performans göstermiştir. Bunun yanında, ilinti katsayısına dayalı yöntem Salinas ve TELOPS-165 veri kümesinde SGO yaklaşımına göre daha başarılı performans göstermesine rağmen diğer iki veri kümesinde aynı başarıyı göstermemiştir. Bu sonuçlar, önerilen KBM tabanlı algoritmanın aksine İK ve SGO tabanlı yaklaşımının gürbüz ve istikrarlı sonuç üretmediğini göstermiştir.



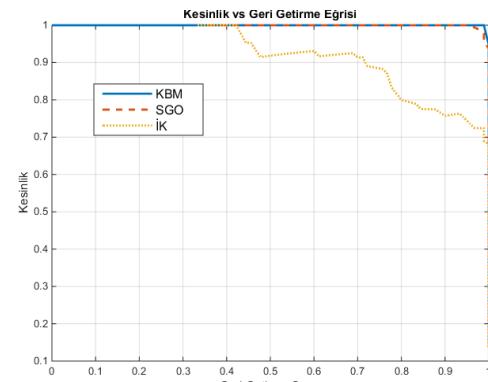
Şekil 4: Indian Pines HS verisine ait algoritma KGE çizgileri.



Şekil 5: Salinas HS verisine ait algoritma sonucu KGE çizgileri.



Şekil 6: TELOPS-165 HS verisine ait algoritma KGE çizgileri.



Şekil 7: TELOPS-660 HS verisine ait algoritma KGE çizgileri.

Ayrıca, önerilen yöntemin sensör farkı (AVIRIS, TELOPS), spektral bant bölgesi (VNIR-SWIR, LWIR), spektral bant sayısı vb. faktörlerden bağımsız olarak benzer performansı yakaladığı deneyler sonucunda anlaşılmaktadır. Önerilen yaklaşım hız açısından analiz edildiğinde ise karşılıklı bilgi miktarı değerinin hesaplama maliyetinin ilinti katsayısi hesaplama maliyetine yakın olduğu görülecektir. n piksel ve m bant sayısı olmak üzere ikisi de $\mathcal{O}(nm)$ hesaplama karmaşıklığına sahiptir.

V. VARGILAR

Bu bildiride, hiperspektral görüntülerde atmosferik etkiler ve sensör yapısı gibi faktörlerden kaynaklanan gürültülü bantların tespiti için etkin bir algoritma önerilmiştir. Önerilen yaklaşım bilişim kuramı alanında yaygın olarak kullanılan karşılıklı bilgi miktarı kavramına dayanmaktadır. Farklı sensör, spektral bant bölgesi ve bant sayısında toplanmış verilerle gerçekleştirilen deneyler sonucunda önerilen yaklaşımın diğer yöntemlere göre daha gürbüz ve başarılı sonuçlar ürettiği gözlemlenmiştir. Gelecek çalışmalarda, bilişim kuramı kavramlarının hiperspektral görüntülerde gürültü azaltma probleminin çözümüne katkısı araştırılacaktır.

KAYNAKÇA

- 1 Czernicki M., Kurowski K, and Plaza A. "Graphics processing unit implementation of JPEG2000 for hyperspectral image compression." *Journal of Applied Remote Sensing*, 6(1):1-14, 2012.
- 2 Bhushan D, Sowmya V, Manikandan M.S., "An effective pre-processing algorithm for detecting noisy spectral bands in hyperspectral imagery." *IEEE Sym. on Ocean Elec.* p.34-39, 2011.
- 3 Nguyen V.H, Hakil K. "Noisy Band Removal Using Band Correlation in Hyperspectral Images." *Korean Journal of Remote Sensing*, 25(2):263-270, 2009.
- 4 Chang A.J, Yong-II K. "Noise Band Extraction of Hyperion Image using Quad tree Structure and Fractal Characteristic." *Korean Journal of Remote Sensing*, 26(5):489-495, 2010.
- 5 Wang B, Wang X, Chen Z. "Spatially Entropy based Mutual Information in Hyperspectral Band Selection for Supervised Classification." *Int. J. of Numerical Analysis and Modeling*, 9(2):181-192, 2012.
- 6 Guo B, Gunn S, Damper B, Nelson J. "Adaptive band selection for hyperspectral image fusion using mutual information." *IEEE Int. Conf. on Information Fusion*, p.1-8., 2005