

LWIR ve MWIR Görüntülerde Yerel Doğrusal Gömme ile Boyut Azaltma ve Anomali Tespiti

LWIR and MWIR Images Dimension Reduction and Anomaly Detection with Locally Linear Embedding

Ayşe Sıddıka Aydoğdu
Algılayıcılar, Görüntü ve
Sinyal İşleme Grubu
HAVELSAN A.Ş.
Ankara, Türkiye
aaydogdu@havelsan.com.tr

Poyraz Umut Hatipoğlu
Algılayıcılar, Görüntü ve
Sinyal İşleme Grubu
HAVELSAN A.Ş.
Ankara, Türkiye
phatipoglu@havelsan.com.tr

Levent Özparlak
Algılayıcılar, Görüntü ve
Sinyal İşleme Grubu
HAVELSAN A.Ş.
Ankara, Türkiye
lozparlak@havelsan.com.tr

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

Özetçe— Son yıllarda hiperspektral görüntüler uzaktan algılama alanında yaygın olarak kullanılmaktadır. Hiperspektral alıcıları diğer alıcılardan ayıran en önemli özellik bu alıcıların dünyadan gelen ışınlarını çok dar ve sık aralıklarla ölçüm yapabilmesidir. Bu çalışma kapsamında uzun dalga kızılötesi (LWIR) ve orta dalga kızılötesi (MWIR) alıcılardan alınan görüntülerde boyut indirgeme algoritmalarının anomali tespitine olan etkisi incelenmiştir. Farklı gürültü seviyelerindeki onbir MWIR ve yedi LWIR verisinde, boyut indirgeme algoritmalarından yerel doğrusal gömme (YDG) ve temel bileşen analizi (TBA) karşılaştırılmıştır. Bu işlemten sonra, bir anomali tespit yöntemi olan çift pencere Reed-Xialoi (ÇPRX) algoritması ile yüzey üzerinde bulunan hedeflerin tespiti gerçekleştirilmiştir. Yerel doğrusal gömme (YDG) algoritmasının pek çok görüntüde temel bileşen analizinden (TBA) daha iyi sonuçlar verdiği gözlenmiş, gürültünün miktarına göre hangi algoritmanın tercih edileceği incelenmiştir.

Anahtar Kelimeler—Hiperspektral görüntü; boyut azaltma; temel bileşen analizi; yerel doğrusal gömme; anomali tespiti.

Abstract— In recent years, hyperspectral imaging has been widely used in remote sensing. As opposed to many other imaging instruments, hyperspectral receivers can measure the radiation coming from the earth in very narrow and frequent intervals. In this study, long-wave infrared (LWIR) and mid-wave infrared (MWIR) hyperspectral images were used to determine the effect of dimensionality reduction on anomaly detection. On eleven MWIR and seven LWIR images of various noise levels, two dimensionality reduction methods, namely the local linear embedding (LLE) and principal component analysis (PCA) were compared. After dimension reduction, dual window Reed-Xialoi (DWRX) algorithm was used for anomaly detection. On several images, it was observed that locally linear embedding gives better results when compared to principle component analysis, especially on hyperspectral images with higher noise levels.

Keywords—Hyperspectral image; dimension reduction; local linear embedding; principal component analysis; anomaly detection

I. GİRİŞ

Hiperspektral görüntü, spektral anlamda bilgi içeren bir görüntü çeşididir. Hiperspektral alıcılar dünyadan yayılan ışınımı 10-20 nm gibi çok dar ve sık aralıklarla ölçmekte ve çok sayıda banttan görüntü alabilmektedir. Bu görüntüler, hedef tespiti, madde tanıma, madde sınıflandırma ve yüzey özelliklerinin belirlenmesi gibi birçok farklı alanda kullanılmaktadır.

Hiperspektral alıcılar ölçüm yaptıkları aralıklara göre dört gruba ayrılmaktadır: 0.4-1 μ m arasını ölçen görünür ve yakın kızılötesi (VNIR) alıcı, 1-2.5 μ m arasını ölçen kısa dalga kızılötesi (SWIR) alıcı, 3-8 μ m arasını ölçen orta dalga kızılötesi (MWIR) alıcı ve 8-15 μ m arasını ölçen uzun dalga kızılötesi (LWIR) alıcılardır. Bu çalışmada MWIR ve LWIR görüntüler üzerinde çalışılmıştır.

Hiperspektral görüntülerin bant sayısının fazla olması belirli bir hesaplama maliyeti getirmektedir. Hedef tespiti, sınıflandırma gibi işlemleri yapmadan önce görüntüden temel ve baskın özelliklerin çıkarılması işlem maliyetini düşürmektedir. Boyut düşürme yöntemleri ile, verinin özelliklerinden önemli bir kayıp olmadan, görüntü içindeki yüksek bant sayıları azaltılabilmektedir.

Yerel doğrusal gömme (YDG) algoritması ilk olarak üç boyutlu verilerde kullanılmıştır. Kim ve Finkel [1] hiperspektral verileri retinal spektral soğurma eğrisi ile çarparak RGB görüntü elde etmiştir. Retinal soğurma eğrisi insan gözünün soğurduğu spektral ışınlarını belirleyen bir eğridir. Bu veri seti üzerinde anomali tespit algoritmaları uygulanmıştır. K-ortalama ve YDG algoritması beraber

uygulandığında etkin bir şekilde sınıflandırma yapılabildiği görülmüştür.

Mohan ve diğerleri [2] YDG algoritmasına uzamsal komşulukları da hesaba katarak bölütleme ve sınıflandırma yapmıştır. Sınıflandırmayı ve boyut azaltmayı geliştirmişlerdir.

Chen ve Quian [3] YDG'deki hesaplama maliyetini ve bellek kullanımını azaltmak için yerel doğrusal gömme algoritmasını geliştirmişlerdir. K-en yakın komşuluklarını kullanarak uzamsal komşuluklar çerçevlenmiştir. VNIR-SWIR görüntülerde, yeni geliştirilen YDG'nin, TBA ve YDG'ye göre daha iyi olduğunu deneylerle göstermişlerdir.

YDG'de anomali tespitinde arka plan istatistiğinin doğru bir şekilde tahmin edilmesi gerekmektedir. Bu problemi çözmek için gürbüz yerel doğrusal gömme algoritması geliştirilmiştir [4]. Ma ve diğerleri [5] gürbüz yerel doğrusal gömme algoritmasını hiperspektral görüntülerde anomali tespiti için kullanmışlardır. Yerel doğrusal gömme ve temel bileşen analizinden daha iyi sonuçlar vermiştir.

Fang ve diğerleri [6] komşuluk bilgisini kullanan gürbüz yerel doğrusal gömme algoritması ile sınıflandırma yapmışlardır. Komşuluk bilgisine dayanan yerel doğrusal gömme algoritması performans başarısını diğer yerel doğrusal gömme algoritmalarına göre geliştirmiştir.

Bu çalışmada LWIR ve MWIR alıcısından alınan veriler kullanılarak boyut indirgeme algoritmaları ile çok bantlı görüntü daha az banda indirgenmiştir. Boyutu indirgenen veriler üzerinde hedef tespit algoritmaları çalışılmıştır. Gürültü miktarına göre hangi algoritmanın kullanılabileceği belirlenmiştir. Bölüm II'de temel bileşen analizi, bölüm III'te yerel doğrusal gömme algoritması, bölüm IV'te algoritmaları karşılaştırmak için kullanılan çift pencere RX yöntemi anlatılmaktadır. Bölüm V'te ise deney sonuçları değerlendirilmektedir.

II. TEMEL BİLEŞEN ANALİZİ

Temel bileşen analizi çok farklı amaçlar için de kullanılmasına rağmen aslında boyut azaltma algoritmasıdır. d-boyutlu X görüntüsünün, n boyutlu bir Y görüntüsüne en az kayıpla geçiş yapmasını sağlayan algoritmadır.

Temel bileşen analizindeki temel prensip varyansın en büyük olduğu yöne doğru izdüşüm vektörlerinin belirlenmesidir. Bulunan izdüşüm vektörleri farklı bir uzayda birbirlerinden bağımsız değerler ile ifade edilmektedir.

İzdüşüm vektörleri veriden elde edilen kovaryansa özdeğer - özvektör dönüşümü yapılarak elde edilmektedir. Özdeğerler büyükten küçüğe doğru sıralanır. Bu sıralı d tane özdeğerlere karşılık gelen özvektörlerden ilk n tanesi kullanılarak matrisin sütunları dizilir. Böylece en iyi izdüşümü gerçekleştiren W izdüşüm matrisi elde edilir. İzdüşüm matrisi ile verinin eşitlik 1'deki gibi çarpılması sonucunda boyutları azaltılmış veri elde edilmektedir:

$$Y = W^T X \quad (1)$$

Sonuç olarak, boyut indirme aslında basit bir matris çarpımıdır ve bu ağırlık matrisi W'yu başka yöntemlerle elde etmek de mümkündür. Bir sonraki bölümde W matrisi YDG yöntemi ile bulunmaktadır.

III. YEREL DOĞRUSAL GÖMME

Yerel doğrusal gömme algoritması gözetimsiz öğrenme algoritmasıdır. Çok boyutlu verileri kullanarak daha az boyuta indirger. Bu yöntemin temeli özvektör yöntemine dayanmaktadır. Doğrusal olmayan bir yöntem olan yerel doğrusal gömme algoritması yerel topolojiyi koruyarak boyut indirgeme işlemi yapmaktadır [7].

Yerel doğrusal gömme algoritması üç adımda gerçekleştirilmektedir.

- Komşuluk hesabı
- Ağırlık matrisi hesabı
- Boyutu azaltılmış verinin elde edilmesi [7].

X verisi $\{x_1, x_2, \dots, x_n\}$ d- boyutludur. Y verisi $\{y_1, y_2, \dots, y_n\}$ de m boyutludur. X verisinden Y verisi elde etmek için, x_i 'nin diğer tüm x_j 'lere uzaklıkları hesaplanır. Öklit uzaklığı kullanılarak her bir pikselin diğer piksellerle uzaklığı hesaplanır. Uzaklıkları hesaplandıktan sonra k en yakın komşulukları belirlenmektedir.

Her pikselin en yakın k komşulukları değerlendirilerek lokal kovaryans bilgisi elde edilir. Lokal kovaryans bilgisini kullanarak ağırlık matrisi hesaplanmaktadır. Eşitlik 2'deki maliyet fonksiyonunu en küçükleyerek en iyi ağırlık matrisi hesaplanmaktadır.

$$\varepsilon(W) = \sum_i |x_i - \sum_j w_{ij} x_j|^2 \quad (2)$$

Burada ε yeniden oluşturma hatasını (reconstruction error), ve W da aranan ağırlık matrisini belirtmektedir.

Düşük boyutlu gömme sonucu elde edilen y_i yerel geometriyi koruyacak şekilde oluşturulur. Eşitlik 3'teki maliyet fonksiyonu hesaplanarak yerel geometriyi koruması sağlanır.

$$\varphi(Y) = \sum_i |y_i - \sum_j w_{ij} y_j|^2 \quad (3)$$

Yerel doğrusal gömme algoritmasını özetlemek gerekirse çok boyutlu X veri setleri haritalanarak daha düşük boyutlu Y vektörünün içine gömülmektedir.

IV. ÇİFT PENCERE-RX

Çift pencere RX yöntemi, çift pencere tabanlı öz ayrışım dönüşümü ile RX'in beraber uygulandığı bir yöntemdir [8]. Anomali ve arka planı birbirinden olabildiğince ayırmak amacıyla iç pencerenin anomaliyi, dış pencerenin de arka planı modellediği iki yerel pencere oluşturulur [9]. İlgili pikselin etrafındaki bu pencerelerin ortalama farkları ve dış pencerenin kovaryans matrisi kullanılır [10]. Çift pencere RX

yöntemi ile, test edilen bir r pikselinin arka plandan uzaklığı δ eşitlik 4 ve 5'teki gibi hesaplanmaktadır. Eşitlikte $C_{dış}$ dış pencere ile iç pencere arasındaki kovaryans matrisidir. $\mu_{dış}$ dış pencere ile iç pencere arasındaki ortalama, $\mu_{iç}$ ise iç pencerenin ortalamasıdır.

$$\delta^{RX-DW}(r) = |\mu_{fark}(r)^T [C_{dış}^{-1}(r)] \mu_{fark}(r)| \quad (4)$$

$$\mu_{fark}(r) = \mu_{dış}(r) - \mu_{iç}(r) \quad (5)$$


V. DENEY SONUÇLARI

Kullanılan veriler (256x320xn) boyutlarındadır. Toplamda n bant vardır ve her bir bant 256x320 boyutlarındadır. Her bir verinin bant sayıları farklıdır. MWIR görüntülerinde ise soğurma bantları çıkarılmıştır. 2000cm⁻¹ ile 3307cm⁻¹ arasına karşılık gelen dalgaboylu bantlardır. Görüntüler sabit bir yer platformunun üzerine yerleştirilen LWIR ve MWIR alıcı ile elde edilmiştir.


Tüm verilerden elde edilen sonuçların aynı bant sayısında olması istenmiştir. Temel bileşen analizi %95 güven aralığında (confidence interval) yaklaşık olarak 5 bantlı veri döndürdüğü için tüm verilerdeki sonuçlarda 5 bant olacak şekilde ayarlanmıştır. Ayrıca, ROC hesaplaması için çoklu eşik değerine ile elde edilen sonuçlar ile incelenen verilerin ÇPRX sonuçları piksel piksel karşılaştırılmıştır.

MWIR Sonuçları: Şekil 1'de MWIR kamerasından alınan verinin, YDG ve TBA ile elde edilen ÇPRX sonuçları görülmektedir. MWIR verisinde alınan görüntüde sigara içen bir adam vardır. Sigara anomali olarak tespit edilmeye çalışılmıştır. Şekil 2'de ÇPRX'in ROC eğrisi görülmektedir. ROC eğrisinin altında kalan alanlara bakıldığında YDG'nin daha başarılı olduğu görülmektedir.

Tablo 1'de 11 farklı MWIR verilerinden elde edilen sonuçlar görülmektedir. Bu sonuçlar ROC'un altında kalan alanlardır. Bu tablo incelendiğinde 7 veride YDG, TBA'ya göre daha başarılı olmuştur. 4 veride de TBA, YDG'ye göre daha başarılı olmuştur. Tablo 2'de de 11 MWIR verisinin ortalama ROC'un altında kalan alan görülmektedir. Tablo 2'de de görüldüğü gibi YDG TBA'ya göre daha başarılıdır.



Şekil 1. MWIR kamera ile elde edilen hiperspektral görüntünün ÇPRX sonucu, YDG'nin ÇPRX sonucu, TBA'nın ÇPRX sonucu. Bu görüntülerde sigara içen bir adamın sigarası anomali olarak tespit edilmektedir.



Şekil 2. MWIR verisinin ROC eğrisi

YDG	TBA	Hiperspektral Görüntü
0.982324	0.96325	0.83452
0.959108	0.98362	0.899239
0.850638	0.703488	0.759573
0.85861	0.736226	0.794143
0.963114	0.98322	0.933952
0.992983	0.980001	0.928202
0.83328	0.94851	0.796515
0.456269	0.471274	0.416042
0.42307	0.344551	0.407549
0.861122	0.826906	0.787511
0.869445	0.814436	0.81931


Tablo 1. MWIR görüntülerinde YDG, TBA ve boyut azaltma yapılmadan kullanılan hiperspektral verilerin DW-RX sonuçlarına göre ROC'un altında kalan alan

YDG	TBA	Hiperspektral Görüntü
0.814322	0.774519	0.77837


Tablo 2. MWIR görüntülerinde YDG, TBA ve boyut azaltma yapılmadan kullanılan hiperspektral verilerin DW-RX sonuçlarına göre ortalama ROC'un altında kalan alan

LWIR Sonuçları: 7 farklı LWIR görüntüsünün analizi yapılmıştır. Tablo 3'te LWIR verilerinden elde edilen ROC eğrisinin altında kalan alan sonuçları görülmektedir. 5 veride YDG, TBA'ya göre daha başarılı olmuştur. 2 veride de TBA, YDG'ye göre daha başarılı olmuştur. Tablo 4'te de 7 LWIR verisinin ortalama ROC'un altında kalan alan görülmektedir. Tabloya bakıldığında YDG'nin TBA'ya göre daha başarılı sonuçlar verdiği görülmektedir.

Şekil 3 ve 4'te iki farklı görüntünün ROC eğrileri görülmektedir. İlk ROC eğrisinin elde edildiği veri 131 bantlıdır. İkinci ROC eğrisinin elde edildiği veri 81 bantlıdır. Verilerde bant sayısı azaldıkça gürültü de azalmaktadır. Gürültünün azaldığı verilerde TBA ile YDG yaklaşık olarak aynı sonucu vermektedirler. Gürültü azaldıkça TBA'nın performansında artış olmaktadır.



Şekil 3. 131 bantlık LWIR görüntüsünün ROC eğrisi



Şekil 4. 81 bantlık LWIR görüntüsünün ROC eğrisi

YDG	TBA	Hiperspektral görüntü
0.890922	0.92861	0.860946
0.879271	0.868525	0.837244
0.839286	0.846451	0.817185
0.917698	0.887833	0.86163
0.765945	0.653126	0.762822
0.66477	0.541117	0.609651
0.742362	0.69597	0.699114

Tablo 3. LWIR görüntülerinde YDG, TBA ve boyut azaltma yapılmadan kullanılan hiperspektral verilerin DW-RX sonuçlarına göre ROC'un altında kalan alanlar

YDG	TBA	Hiperspektral görüntü
0.822724	0.795953	0.761505

Tablo 4. LWIR görüntülerinde YDG, TBA ve boyut azaltma yapılmadan kullanılan hiperspektral verilerin DW-RX sonuçlarına göre ortalama edilen ROC'un altında kalan alan

VI. SONUÇ

LWIR 8-15µm, MWIR veriler 3-8µm dalga boylarındadır. MWIR verileri radyansın salıcılık etkisinden çok yansıtıcılıktan etkilenmeye başladığı bir frekans tayfındadır.

Bundan dolayı MWIR verileri çok fazla gürültü içerir. MWIR verilerinde 2000cm⁻¹ ile 3307cm⁻¹ arasına karşılık gelen dalgaboyları soğurma bantları olduğu için çıkartılmıştır Aynı zamanda bant sayısının artmasına paralel olarak bant aralığının da çok artması ve ölçülecek bant sayısındaki artış dolayısıyla ölçme süreleri artmaktadır. Bu artışın sonucu veriler hem uzamsal hem de spektral olarak daha fazla gürültülü olmaktadır. Gürültü arttıkça iyi tanımlanmış bir altuzaydan daha muğlak sınırlara sahip bir altuzaya geçildiği için TBA'nin performansı düşmektedir. YDG'de TBA gibi altuzaya geçiş olmadığı için performansında değişim belirgin şekilde daha az olmaktadır. YDG piksellerin komşuluk matrisine baktığı için piksel sayısının artması hesaplama zamanını $O(n^2)$ ile etkiler. Bundan dolayı verinin piksel boyutlarının artması YDG'nin hesaplama maliyeti artırmaktadır. YDG'nin hesaplama maliyetini azaltmak için paralel programlama yapılabilir. Bu iki boyut azaltma algoritması kullanım amacına göre birbirinin yerine kullanılabilir. Daha hızlı olması istenirse TBA, çok gürültülü verilerde kullanılmak istenirse de YDG tercih edilebilir. Bu çalışmanın devamında LWIR ile MWIR verilerinin farklı gürültü seviyelerinde TBA ile YDG performansı karşılaştırılacaktır.

REFERENCES

- [1] Kim, D. H., and Finkel, L. H., "Hyperspectral image processing using locally linear embedding," Proceedings of the 1st international IEEE EMBS conference on Neural Engineering, pp. 316-319, March 2003.
- [2] Mohan, A., Sapiro, G., and Bosch, E., "Spatially-coherent non-linear dimensionality reduction and segmentation of hyper-spectral images," IEEE Transaction on Geoscience and Remote Sensing Letter, vol. 4, no. 2, pp. 206-201, Apr 2007.
- [3] Chen, G., and Qian, S-E., "Dimensionality reduction of hyperspectral imagery using improved locally linear embedding," Journal of Applied Remote Sensing, vol. 1, March 2007.
- [4] Chang, H. and Yeung, D. Y., "Robust locally linear embedding," Pattern Recognition, vol 39, no. 6, pp. 1053-1065, 2006.
- [5] Ma, L., Crawford, M. M., and Tian, J., "Anomaly detection for hyperspectral images based on robust locally linear embedding," Springer, 2010.
- [6] Fang, Y., Li, H., Ma, Y., Liang, K., Hu, Y., Zhang, S., and Wang, H. "Dimensionality reduction of hyperspectral images based on robust spatial information using locally linear embedding," IEEE Geosci. and Rem. Sens. Letters, vol.11, pp. 1712-1716, October 2014.
- [7] Saul, L. K. and Roweis S: T "An Introduction to locally linear embedding," .
- [8] Soofbaf, S. R.; ValadanZoej, M. J.; Fahimnejad, H. & Ashoori, H. , "Efficient detection of anomalies in hyperspectral images" The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B7. Beijing 2008.
- [9] Schaum, A. P. "Hyperspectral anomaly detection: Beyond RX", Proc. of SPIE Vol. 6565 656502, 2007.
- [10] Li, J. & Bioucas-Dias, J., "Minimum volume simplex: A fast algorithm to unmix hyperspectral data," in [Proc. IEEE IGARSS], III, 250-253, Aug 2008.