

# Destek Vektör Veri Tanımı ile Hiperspektral Görüntü Sınıflandırma

## Hyperspectral Image Classification via Support Vector Data Description

Hüseyin Emre Mutlu, Seniha Esen Yüksel Erdem  
Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye  
emre.mutlu@hacettepe.edu.tr, eyuksel@ee.hacettepe.edu.tr

**Özetçe**—Bu çalışmada hiperspektral görüntülerin sınıflandırılmasında Destek Vektör Veri Tanımı (DVVT) yöntemi kullanılmış ve DVVT'nin başarısını arttırmak için yeni bir aykırı değer ayıklama yöntemi önerilmiştir. Yöntem, Pavia Üniversitesi (İtalya) üzerinde yapılan uçuşlarla alınmış, doğru yer bilgisi bulunan hiperspektral veriye uygulanmıştır. Başarım dayanağı olarak literatürde bilinen ve yaygın olarak kullanılan “İzgesel Açı Haritalayıcı” (İAH), “İzgesel Eşlenmiş Süzgeç” (İES), “Kısıtlanmalı Eneji Azaltma” (KEA) ve “Uyarlanmalı Eşvresellik/Kosinüs Kestirici” (UKK) algılama algoritmaları tercih edilmiştir. DVVT sınıflandırıcı ve diğer dört algoritmanın aynı veri üzerinde gösterdiği başarım kıyaslanmıştır. DVVT ile elde edilen sınıflandırıcı, diğer algoritmalar kadar başarılı olmasa da, bu çalışmada önerilen aykırı değer ayıklama yöntemi kullanıldığında, diğer algoritmaların başarımlarına yaklaştığı ve geliştirilmeye açık bir sınıflandırıcı olduğu gözlenmiştir.

**Anahtar Kelimeler** — destek vektör veri tanımı; sınıflandırıcı; hiperspektral görüntüleme; aykırı değer ayıklama.

**Abstract**—In this study, Support Vector Data Description (SVDD) method is used for the classification of hyperspectral data, and a new outlier detection method is proposed to increase the classification rates of the SVDD. The method is applied to the Pavia University (Italy) hyperspectral data which was acquired by flights over the university campus and has ground truth. Well-known and commonly applied detection algorithms “Spectral Angle Mapper” (SAM), “Spectral Matched Filter” (SMF), “Constrained Energy Minimization” (CEM) and “Adaptive Coherence/Cosine Estimator” (ACE) were preferred as performance reference. Performance of the SVDD classifier and these four algorithms was compared. Although the SVDD could not perform as well as the others, its performance was significantly improved by the proposed outlier removal method.

**Keywords** — support vector data description; classifier; detection algorithm.

### I. GİRİŞ

Hiperspektral görüntüler; elektromanyetik spektrumun, görünür ışığın ve kızılaltı bandın da dahil olduğu geniş bir bölümü üzerinde sık aralıklarla çok sayıda banttan alınan görüntüler bütünüdür. Bu görüntüleme teknolojisi; madencilikte, çevresel konularda, tarımda, kimyada, astronomide ve askerî alanda yoğun bir şekilde kullanılmaktadır. Bir uzaktan algılama teknolojisi olan hiperspektral görüntüleme ile görüntülenen bölge hakkında, görünür ışıkla elde edilen görüntülere göre çok daha ayrıntılı bilgi elde edilebilmektedir.

Eldeki hiperspektral görüntüden bilgi elde etmek amacıyla çeşitli algılama ve sınıflandırma algoritmaları geliştirilmiştir. Fakat bu algoritmaların başarımları, görüntülerin istatistiksel çeşitliliği ve gürültü içermesi sebebiyle her zaman tam doğru sonuç vermemektedir. Dolayısıyla bir algoritmanın başarımı, veri içeriğine bağlı olmakla birlikte, algoritma üzerinde yapılan değişiklikler başarımı etkileyebilmektedir. Dolayısıyla, sınıflandırma ve algılama algoritmaları, her zaman daha da geliştirilmeye açıktır.

Çalışmamızda geliştirilen sınıflandırıcı, tek bir sınıfa ait veri kümesinin sınırlarını belirlemek için kullanılan DVVT metodunun, çok sayıda sınıf için kullanılmak üzere uyarlanmasıyla elde edilmiştir. Karşılaştırma amaçlı kullanılan algılama algoritmalarının (İAH, İES, KEA ve UKK [4]) başarımları ile karşılaştırıldığında çok geride kalan DVVT sınıflandırıcı, eğitimi sırasında veri kümesindeki aykırı değerlerin tespit edilip çıkarılmasıyla çok daha yüksek bir sınıflandırma başarımına ulaşmıştır.

### II. DESTEK VEKTÖR VERİ TANIMLAMA

#### A. Teori

Bu metotta yapılan iş, belirli bir sınıfa ait veri kümesinin, nitelik uzayındaki sınırlarını belirlemekten ibarettir. Yani destek vektörleri kullanılarak bu sınırları ifade eden bir tanım oluşturulmaktadır. Sınıfı belirten bu tanım en basit anlamda 2 boyutlu uzay için bir daire, 3

boyutlu uzay için bir küre ve daha çok boyutlu uzaylar için ise bir hiperküre olup bu tanımlar, merkez vektörü ( $\mathbf{a}$ ) ve yarıçap ( $R$ ) ile ifade edilmektedir. Dolayısıyla, bu sınıfa ait veriler, belli bir hacim içinde bulunmaktadır. Bir örnek vektörünün ( $\mathbf{z}$ ) bu sınıfa ait olup olmadığını test etmek için sınıfın merkezine ( $\mathbf{a}$ ) olan Öklid uzaklığına bakılır. Örnek bu sınıfa aitse, sınıfı tanımlayan hacim içinde bulunmalı, diğer bir deyişle, hiperkürenin merkezine olan Öklid uzaklığı, hiperkürenin yarıçapından küçük olmalıdır.

$$\|\mathbf{z} - \mathbf{a}\| \leq R \quad (1)$$

Böyle bir sınıflandırma yapabilmek için öncelikle tanımlanmış bir sınıfın var olması gerekmektedir. Bu sınıfın tanımlanması da bir verisi kümesi ile eğitim gerektirmektedir. Sınıflandırıcıyı oluşturabilmek için öncelikle eğitim veri kümesi kullanarak bu veri kümesinin destek vektörlerini bulmak gerekmektedir. Bu destek vektörleri kullanılarak hiperkürenin merkezi ve yarıçapı bulunur ve eğitim tamamlanmış olur [1].

Eğitim için kullanılacak  $\{x_1, x_2, \dots, x_N\}$  veri kümesi verilmiş olsun. Amaç, bu veri kümesini kapsayan en küçük hacmi bulmaktır. Bunun için en küçük değerini bulmak üzere bir  $F$  fonksiyonu tanımlanır:

$$F(R, \mathbf{a}) = R^2 \quad (2)$$

$F$  fonksiyonunu küçültürken aşağıdaki kısıt uygulanır:

$$\|\mathbf{x}_i - \mathbf{a}\|^2 \leq R^2, \quad \forall i. \quad (3)$$

Veri setinde bulunan aykırı değerli örnekler, tanım bölgesinin gereğinden daha geniş olmasına sebep olacaktır. Dolayısıyla yarıçap  $R$ 'den biraz büyük olabilir fakat buna sebep olan aykırı değerler için bunun bir maliyeti olacaktır. Bu durumda küçültme fonksiyonu aşağıdaki hali alacaktır:

$$F(R, \mathbf{a}) = R^2 + C \sum_i \xi_i \quad (4)$$

Burada  $\xi_i$ , serbestlik değişkeni ve  $C$  de hata miktarı ile hacim arasındaki takası kontrol eden parametredir. Bu küçültme probleminin kısıtları (5)'teki gibidir.

$$\|\mathbf{x}_i - \mathbf{a}\|^2 \leq R^2 + \xi_i, \quad \xi_i \geq 0, \quad \forall i. \quad (5)$$

Bu problem Lagrange çarpanları yöntemi ile çözüldüğünde nihai olarak elde (6) kalmaktadır.

$$L = \sum_{i,j} \alpha_i \alpha_j (\mathbf{x}_i^T \mathbf{x}_j) - \sum_i \alpha_i (\mathbf{x}_i^T \mathbf{x}_i) \quad (6)$$

Lagrange çarpanı olarak gelen  $\alpha_i$  değişkenleri, destek vektörü olan  $\mathbf{x}_i$ 'ler için pozitif olup diğer veriler için sıfırdır. Ayrıca (7), (8) ve (9)'da verilen kısıtlar da çözümlerle beraber gelmektedir. Burada amaç, denklem (6)'yı en küçük yapan  $\alpha_i$  değerlerini, (7) ve (8)'i sağlayacak şekilde bulmaktır. Bu problem, MATLAB®'in karesel (kuadratik, quadprog) programlama fonksiyonu kullanılarak çözülebilmektedir. Çözüm için gereken  $C$  parametresi  $C=1$  olarak belirlenmiştir.  $\alpha_i$ 'ler bulunduğundan sonra sınıfı

tanımlayan hiperkürenin merkezi denklem (9) kullanılarak bulunur.


$$\sum_i \alpha_i = 1, \quad (7)$$

$$0 \leq \alpha_i \leq C, \quad \forall i. \quad (8)$$

$$\mathbf{a} = \sum_i \alpha_i \mathbf{x}_i. \quad (9)$$

Destek vektörlere karşılık gelen  $\alpha_i$  değerlerinin sıfırdan büyük olacaktır. Burada dikkat edilmesi gereken nokta, karesel programlama ile bulunan  $\alpha_i$ 'lerin tamamının sıfırdan büyük gelmesidir. Fakat destek vektörlere denk gelen  $\alpha_i$ 'ler diğerlerinden katbekat büyük olup kolaylıkla ayıklanabilir. Destek vektörleri de tespit ettikten sonra denklem (3)'ü kullanarak hiperkürenin yarıçapı bulunabilir. Bu denklemde destek vektörleri, eşitliği sağlamaktadırlar.

Böylece, hiper-kürenin merkezi  $\mathbf{a}$  ve yarıçapı  $R$ 'yi bularak sınıfımız tanımlanmış olur. Verilen yeni bir test örneğinin, yalnızca denklem (1) kullanılarak bu sınıfa ait olup olmadığı söylenebilir. Aşağıdaki şekil, iki boyutlu sentetik verinin (siyah çarpılar); destek vektörler (kırmızı çemberler), merkez nokta (mavi kare) ve yarıçap kullanarak tanım bölgesini sınırlarını (yeşil çember) göstermektedir.



Şekil 1. 2 Boyutlu sentetik verinin DVVT ile tanımlanması

## B. Çok Sınıfta Uygulama

Çalışmada amacımız, farklı sınıflara ait verileri doğruluk oranı en yüksek olacak şekilde sınıflandırmaktır. Bunun için her sınıfın tanımını oluşturmak gerekmektedir. Eğitim verileri kullanılarak tanımlar oluşturulduktan sonra her örnek, her sınıf için denklem (1) kullanılarak test edilir. Veri, denklem (1)'i hangi sınıf için sağlamışsa, o sınıfa atanır. Sınıf tanım bölgelerinin birbirine yakın olması durumunda bir örnek birden fazla sınıf için denklem (1)'i sağlayabilir. Bu durumda hangi sınıfın merkez noktasına en yakınsa, o sınıfa atanır.

### C. Aykırı Örneklerin Ayıklanması

Veri kümesi içinde aykırı örneklerin bulunması muhtemel bir durumdur. Fakat bu değerlerin varlığı, sınıfı tanımlayan hacmin gereğinden büyük olmasına sebep olur. Dolayısıyla eğitim sırasında bu değerlerin ayıklanması gerekir. Bu işlem şöyle sağlanmıştır:

1. Veri kümesinin ortalaması hesaplanır.
2. Karesel programlama ile merkez noktası bulunur.
3. Merkez noktası ile ortalama noktası arası Öklid uzaklığı test edilir.
4. Test edilen mesafe eşik değerinin üzerinde ise, ortalama noktasına en uzak destek vektörünü veri kümesinden çıkartılır ve 2. adıma gidilir.

Deneyler sonucunda bu yöntemin hata oranını düşürdüğü, Tablo 1'de görülmektedir.

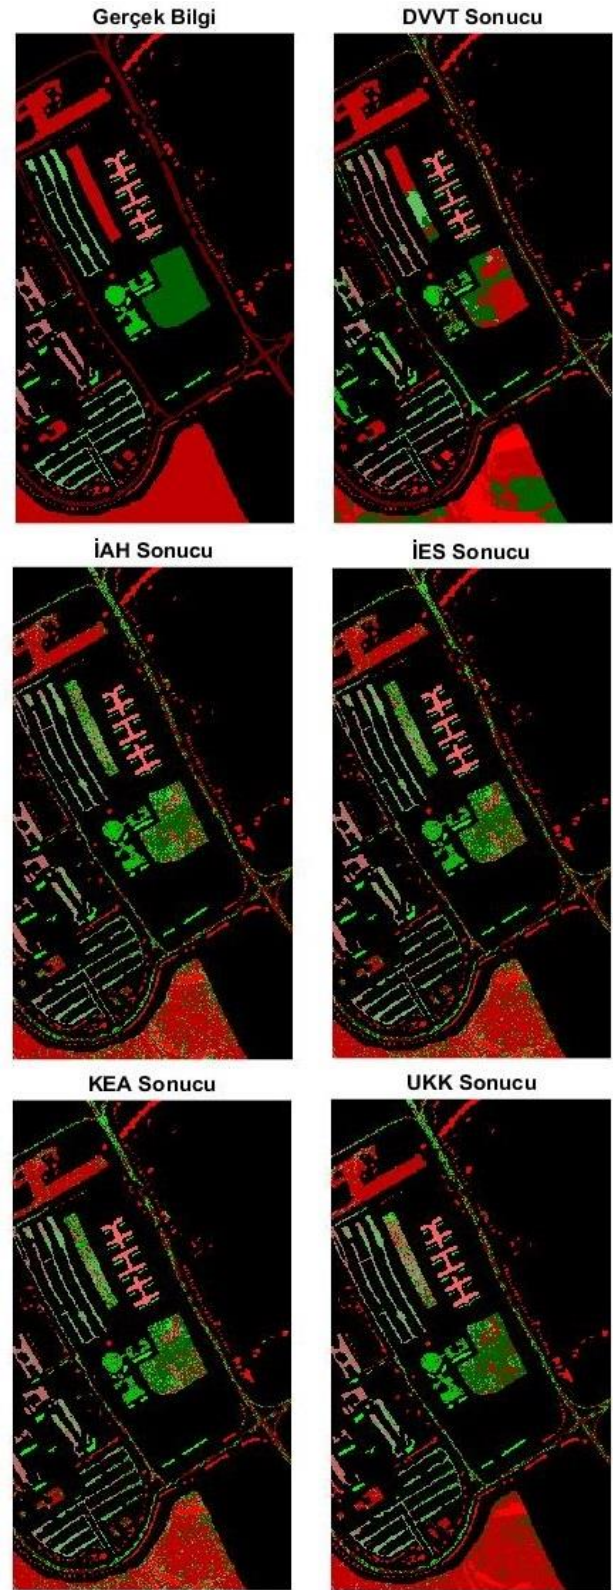
### III. HİPERSPEKTRAL VERİ DENEYLERİ

Pavia Üniversitesi (İtalya) üzerinden alınan hiperspektral görüntü 610 x 340 piksel çözünürlüğünde 103 spektral banttan alınmıştır. Veri kümesinde deneyde kullanılan tüm piksellerin doğru sınıf bilgisi mevcut olup, sınıfı belli olmayan kesimler hiç bir işleme dahil edilmemiştir. Veride toplam 9 sınıf bulunmaktadır. DVVT eğitimi için her sınıftaki verinin %20'si kullanılmış ve her sınıf için bir DVVT oluşturulmuştur.

İlk etapta yalnızca DVVT algoritması veri üzerinde koşurulmuştur. Daha sonra, farklı eşik değerlerinde aykırı değer ayıklama ile denemeler yapılmış, sonuçlar algılama algoritmalarından elde edilenlerle karşılaştırılmıştır. Karşılaştırılmada kullanılan algoritmalarının matematiksel ifadeleri Tablo 2'de verilmiştir. Algılama algoritmalarına hedef imzası olarak; her sınıftan verinin, eğitim için kullanılan kısmının ortalama vektörü verilmiştir. Elde edilen en iyi DVVT sınıflandırma sonucu, gerçek sınıf bilgisi ve algılama algoritmaları sonuçları ile birlikte şekil 2'de gösterilmiştir. Yanlış sınıflandırılmış bölgeler bu şekillerde açıkça görülmektedir. Deneyler sonucunda elde edilen hata oranları ise Tablo 1'de gösterilmiştir. Tabloda sonuçlar, en başarılı algoritmadan başarısız doğru sıralanmıştır. UKK algoritması başta olmak üzere algılama algoritmalarının DVVT sınıflandırıcıdan üstün olduğu, fakat parametre değişimiyle DVVT sınıflandırıcının da başarımının iyileştiği görülmektedir.

### IV. DEĞERLENDİRME

Bu çalışmada; destek vektör veri tanımlama kullanılarak hiperspektral görüntüleri sınıflandıran yeni bir yöntem gerçekleştirilmiş ve veri üzerinde denenmiştir. Çalışma sonunda iki temel durum gözlenmiştir. İlk olarak, küçük değişikliklerle sınıflandırıcının hata oranında



Şekil 2. Veri gerçek bilgisi, DVVT sınıflandırma sonucu ve algılama algoritmaları ile elde edilen sonuçlar

Algoritma Hata Oranı Tablosu		
Algoritma	Eşik Değeri (DVVT için)	Hata Oranı
UKK	-	0,2753
İAH	-	0,3572
İES	-	0,3572
KEA	-	0,3572
DVVT	1000	0,3780
	600	0,3826
	800	0,3849
	1250	0,4580
	1500	0,4786
	2000	0,4862
	yok	0,5245

**Tablo 1.** Algılama algoritmaları ve farklı eşikdeğerlerinde DVVT sınıflandırıcının hata oranları ( $\frac{\text{yanlış sınıflandırılan piksel sayısı}}{\text{sınıflandırılan toplam piksel sayısı}}$ )


İAH	$r_{İAH}(x) = \frac{(s^T x)^2}{(s^T s)(x^T x)}$
İES	$r_{İES}(x) = (s - \tilde{\mu})\tilde{\Sigma}^{-1}(x - \tilde{\mu})^T$
KEA	$r_{KEA}(x) = \frac{s^T R^{-1} x}{s^T R^{-1} s}$
UKK	$r_{UKK}(x) = \frac{((s - \tilde{\mu})\tilde{\Sigma}^{-1}(x - \tilde{\mu})^T)^2}{(s - \tilde{\mu})\tilde{\Sigma}^{-1}(x - \tilde{\mu})^T (s - \tilde{\mu})\tilde{\Sigma}^{-1}(x - \tilde{\mu})^T}$

**Tablo 2.** Algılama algoritmalarının matematiksel ifadeleri.  $x$ : test edilen piksel,  $s$ : aranan spektral imza,  $\tilde{\mu}$ : veri ortalaması,  $\tilde{\Sigma}$ : veri kovaryans matrisi,  $R$ : veri korelasyon matrisi

değişimler elde edilmiştir. İkinci durum ise, istatistiksel bilgi kullanan algoritmaların, sadece geometrik ölçütler kullanan yöntemlere önemli ölçüde üstünlük sağlamış olmasıdır. Bu bağlamda, sonraki çalışmalarda destek vektör veri tanımlama yöntemine eklenenecek olan çekirdek (kernel) fonksiyonlarının istatistiksel bilgi içerecek şekilde düzenlenmesi gerektiği anlaşılmıştır.

Bu çalışmada önerilen aykırı değerlerin ayıklanması yöntemi, DVVT sınıflandırıcının hata oranını %52 seviyelerinden %37 seviyelerine kadar indirmiştir. Bu yöntemin başarımında önemli rol oynayan, veri ortalama noktası ile tanım bölgesi merkez noktası arasındaki Öklid uzaklığının eşik değeri farklı değerlerde denenmiştir. Elde edilen sonuçlar tablo 1’de listelenmiş, şekil 3’te de grafik

halinde gösterilmiştir. Grafiğin şekline bakacak olursak algoritma başarımının en az indiği eşik değerleri bulmanın mümkün olabileceği düşünülebilir. Sınıflandırıcının başarımına etki eden bu eşik değerinin en uygun değerinin otomatik olarak kestirilmesi ise sonraki çalışma konularından birisi olacaktır.



**Şekil 3.** DVVT sınıflandırıcının hata oranının eşik değerine göre değişimi

## TEŞEKKÜR

Bu çalışma, TÜBİTAK tarafından desteklenen 115E318 numaralı “Hiperspektral Görüntüler ile LiDAR Verilerinin Kaynaştırılması” projesi kapsamında yürütülmüştür.

## KAYNAKÇA

- [1] Tax, D. M. J. and Duin, R. P. W., “Data Domain Description using Support Vectors”, *ESANN’1999 proceedings – European Symposium on Artificial Neural Networks Bruges (Belgium), 21-23 April 1999, pp.251-256.*
- [2] Tax, D. M. J. and Duin, R. P. W., “Support Vector Data Description”, *Machine Learning, 54, 45-66, 2004, Kluwer Academic Publishers.*
- [3] Sakla, W. A., Sakla, A. A., Chan, A., “A Support Vector Data Description Approach to Target Detection in Hyperspectral Imagery”, *Proc. of SPIE Vol. 7335, 73350C, 2009.*
- [4] Glenn, T. C., “Context-Dependent Detection in Hyperspectral Imagery”, *Ph.D. Dissertation, University of Florida, 2013*
- [5] T. Glenn, A. Zare, P. Gader, D. Dranishnikov. (2013). Bullwinkle: Scoring Code for Sub-pixel Targets (Version 1.0) [Software]. Available from <http://engineers.missouri.edu/zarea/code>.
- [6] Duda, R. O., Hart, P. E., Stork, D. G., “Pattern Classification”, 2<sup>nd</sup> Edition, Wiley, 2000