

Uzaktan algılama görüntülerinin sınıflandırılması için sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması

N. Gökhan KASAPOĞLU*, Bingül YAZGAN, Okan K. ERSOY

İTÜ Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Programı, 34469, Ayazağa, İstanbul

Özet

Geleneksel görüntü işleme tekniklerinin direkt olarak uzaktan algılamaya uygulanması, sadece multispektral datalar için geçerli olabilir. Öznitelik vektörü boyutu 100-200 civarında olan hiperspektral dataların analizi için gelişmiş algoritmalara ihtiyaç vardır. Bununla birlikte, uzaktan algılamada, genellikle sınırlı sayıda eğitim örneğinin olması, özellikle öznitelik vektörünün boyutunun büyük olduğu hiperspektral datalarda, parametrik sınıflayıcıların kullanımını kısıtlar. Bu çalışmanın amacı, istatistiksel dağılıma bağlı olmayan, sadece eldeki eğitim örneklerine dayanan bir algoritma geliştirerek yukarıda özetlenen uzaktan algılama için genel sınıflandırma problemlerinin üstesinden gelmektir. Önerilen Sınır Özniteliklerinin Belirlenmesi ve Adaptasyonu (SÖBA) algoritması, karar yüzeylerine yakın sınır öznitelik vektörlerini kullanır ve bu sınır öznitelik vektörleri, maksimum marjin prensibini sağlayacak şekilde adapte edilerek, öznitelik uzayında doğru bölütlemenin yapılmasını sağlar. SÖBA algoritması iki bölümden oluşur. İlk aşamada sınır öznitelik vektörlerinin başlangıç değerleri uygun eğitim kümesi elemanlarından, yönetilebilir sayıda atanır. Daha sonra uygulanan adaptasyon işlemiyle, öğrenme süreci gerçekleştirilerek sınır özniteliklerinin, sonuç değerlerine ulaşması hedeflenir. Sınıflandırma sonuç sınır öznitelik vektörlerine olan en yakın 1 komşuluk (1-EK) kuralı uyarınca yapılır. Ek olarak, SÖBA algoritmasının sınır öznitelik vektörlerinin başlangıç değerlerine ve eğitim kümesi elemanlarının eğitimde kullanılma sırasına bağlı olarak her çalışmasında kabul edilebilir derecede farklı sınır karar yüzeyleri oluşturması, konsensüs yapılar da kullanılması için elverişli bir özelliktir. Böylece birçok defa çalıştırılan SÖBA kararlarının uygun kurallarla birleştirilmesiyle tek bir sınıflayıcının aldığı karardan çok daha doğru kararlar elde edilebilir.

Anahtar Kelimeler: *Uzaktan algılama, hiperspektral data sınıflandırma, konsensüs.*

*Yazışmaların yapılacağı yazar: N. Gökhan KASAPOĞLU. gokhank@itu.edu.tr; Tel: (212) 285 36 38.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Programında tamamlanmış olan "Sınır özniteliklerinin belirlenmesi ve adaptasyonu: Uzaktan algılama görüntülerinin sınıflandırılması için yeni bir algoritma" adlı doktora tezinden hazırlanmıştır. Makale metni 25.05.2007 tarihinde dergiye ulaşmış, 26.06.2007 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 01.03.2009 tarihine kadar dergiye gönderilmelidir.

Border feature detection and adaptation for classification of remote sensing images

Extended abstract

Various types of sensors collect very large amounts of data from the earth surface. The characteristics of the data are related to sensor type with its own imaging geometry. Consequently, sensor types affect processing techniques used in remote sensing. In general, image processing techniques used in remote sensing are usually valid for multispectral data which is relatively in a low dimensional feature space. Therefore, advanced algorithms are needed for hyperspectral data which have at least 100-200 features (attributes/bands). Additionally, the training process is very important and affects the generalization capability of a classifier in supervised learning. Enough number of training samples is required to make proper classification. In remote sensing, collecting training samples is difficult and costly. Consequently, a limited number of training samples is often available in practice.

Conventional statistical classifiers assume that the data have a specific distribution. For real world data, these kinds of assumptions may not be valid. Additionally, proper parameter estimation is difficult, especially for hyperspectral data. Normally, when the number of bands used in the classification process increases, precise detailed class determination is expected. For high dimensional feature space, when a new feature is added to the data, classification error decreases, but at the same time, the bias of the classification error increases. If the increment of the bias of the classification error is more than the reduction in classification error, then the use of the additional feature decreases the performance of the decision algorithm. This phenomenon is called the Hughes effect, and it may be much more harmful with hyperspectral data than with multispectral data.

Our motivation in this study is to overcome some of these general classification problems by developing a classification algorithm which is directly based on the available training data rather than on the underlying statistical data distribution. Our proposed algorithm, Border Feature Detection and Adaptation (BFDA), uses border feature vectors near the decision boundaries which are adapted to make a precise partitioning in the feature space by using maximum margin principle.

The BFDA algorithm well suited for classification of remote sensing images is developed with a new approach to choosing and adapting border feature vectors with the training data. This approach is especially effective when the information source has a limited amount of data samples, and the distribution of the data is not necessarily Gaussian. Training samples closer to class borders are more prone to generate misclassification, and therefore are significant feature vectors to be used to reduce classification errors. The proposed classification algorithm searches for such error-causing training samples in a special way, and adapts them to generate border feature vectors to be used as labeled feature vectors for classification.

The BFDA algorithm can be considered in two parts. The first part of the algorithm consists of defining initial border feature vectors using class centers and misclassified training vectors. With this approach, a manageable number of border feature vectors is achieved. The second part of the algorithm is adaptation of border feature vectors by using a technique which has some similarity with the learning vector quantization (LVQ) algorithm. In this adaptation process, the border feature vectors are adaptively modified to support proper distances between them and the class centers, and to increase the margins between neighboring border features with different class labels. The class centers are also adapted during this process. Subsequent classification is based on labeled border feature vectors and class centers. With this approach, a proper number of feature vectors for each class is generated by the algorithm. In supervised learning, the training process should be unbiased to reach more accurate results in testing. In the BFDA, accuracy is related to the initialization of the border feature vectors and the input ordering of the training samples. These dependencies make the classifier a biased decision maker. Consensus strategy can be applied with cross validation to reduce these dependencies.

In this study, major performance analysis and comparisons were made by using the AVIRIS data. Using the BFDA, we obtained satisfactory results with both multispectral and hyperspectral data sets. The BFDA is also a robust algorithm with the Hughes effect. Additionally, rare class members are more accurately classified by the BFDA as compared to conventional statistical methods.

Keywords: Remote sensing, hyperspectral data classification, consensual classification.

Giriş

İstatistiksel sınıflandırmada genellikle datanın sahip olduğu istatistiksel dağılımın önceden belli bir istatistiksel dağılıma uyduğu varsayımı altında sınıflandırma işlemi yapılır. Bu varsayım genellikle eğitim için kullanılan örneklerin sayısı istatistiksel olarak doğru bir yargıya varmamız için yeterli olmayacağından iyi sonuçlar almamıza engel olabilir. Bu durum hiperspektral datalar için daha da önemli bir problem olarak karşımıza çıkmaktadır. AVIRIS gibi 220 band içeren sensörlerden elde edilen dataların sınıflandırılmasında her bir sınıf için en azından öznitelik uzayının boyutu kadar eğitim kümesi elemanına ihtiyaç olacaktır. Bu durum sağlansa bile sınıflandırmada nadir görülen (az sayıda örnek içeren) sınıfların doğru sınıflandırılması pek mümkün olmayacaktır. Bu açıdan sınıfların başlangıç olasılık kabullerine ihtiyaç duymayan, parametrik olmayan sınıflayıcılara ihtiyaç vardır. Bu amaçla bu çalışmada Sınır Özniteliklerinin Belirlenmesi ve Adaptasyonu algoritması tanıtılmıştır (SÖBA).

Burada tanıtılan SÖBA algoritması iki bölüme ayrılabilir. Algoritmanın ilk kısmı iteratif olarak sınır özniteliklerinin başlangıç değerlerini varolan eğitim kümesi elemanlarından seçer. Bu belirleme işleminde uygun seçilecek sınır elemanının sayısı daha sonra uygulanacak adaptasyon süreci için önemlidir. Gereğinden fazla sayıda seçilecek sınır elemanlarının sayısı adaptasyon başarımını azaltacaktır. Sınır elemanlarının başlangıç değerleri atandıktan sonra temelde Learning Vector Quantization (LVQ) algoritmasına (Kohonen, 1990) benzeyen yeni bir adaptasyon yapısı kullanılır. Bu adaptasyon öznitelik uzayını daha önce belirlenmiş geometrik kısıtlar altında uygun şekilde bölütleyerek geleneksel yöntemlerle karşılaştırıldığında iyi başarımlar sağlar.

SÖBA algoritmasının sınır öznitelik elemanlarının başlangıç değerlerine ve eğitim kümesi elemanlarının eğitimde kullanılma sırasına bağlı olarak her çalışmada kabul edilebilir derecede farklı sonuçlar vermesi, konsensüs yapılar da kullanılması için elverişli bir özelliktir. Böylece birçok defa çalıştırılan SÖBA kararlarının bir-

leştirilmesiyle tek bir sınıflayıcının aldığı karardan çok daha doğru kararlar elde edilebilir.

Sınır özniteliklerinin belirlenmesi ve adaptasyonu algoritması

Öznitelik uzayının eğitim kümesinden seçilmiş bazı referans vektörler yardımıyla bölütlenmesi doku tanıma problemlerinde sıklıkla kullanılan bir yöntemdir. Gereğinden fazla sayıda seçilen referans vektörlerinin sınıflandırmada kullanılması genelleme başarımını düşürebilir. Çoğu kez genelleme başarımını arttırmak için gereksiz vektörlerin belirlenmesi ve referans vektör olarak kullanılmaması gerekir. Gereksiz vektörlerin belirlenmesi için ise budama yöntemleri uygulanabilmektedir (Alpaydın, 1991).

Bu çalışmada sınır özniteliklerinin belirlenmesi adı verilen yeni bir referans vektör seçme yaklaşımı önerilmiştir. Bu yaklaşımda referans vektörlerin seçimi belirli geometrik kısıtlar altında yapılır. Destek Vektör Makinalarında (DVM) olduğu gibi (Cristianini ve Taylor, 2000) seçilen referans vektörler öznitelik uzayında karar yüzeylerinin oluşmasını sağlar. Böylece seçilen referans vektörlerinin adaptasyon sonunda karar yüzeyine yakın olması sınıflandırma başarımını etkiler. Referans vektörlere eğitim kümesi içinden seçilen elemanların başlangıç değeri olarak atanması işlemine sınır özniteliklerinin belirlenmesi, referans vektörlere ise sınır öznitelik vektörleri adı verilir. Daha sonra uygulanan adaptasyon süreciyle sınır öznitelik vektörlerinin sonuç değerlerine ulaşarak öznitelik uzayını belirlenen geometrik kısıtlar altında düzgün bölütlemesi amaçlanır. Test için kullanılan örneklerle, adaptasyon sonucunda elde edilen sonuç sınır öznitelik vektörlerine dayanan en yakın 1 komşuluk (1-EK) karar kuralı uygulanarak, en yakın 1 komşuluklarındaki sınır öznitelik vektörlerinin etiketleri atanır.

Sınır özniteliklerinin belirlenmesi

Sınır özniteliklerinin belirlenmesi algoritması aşağıda belirtilen özellikler düşünülerek geliştirilmiştir.

1. Sınır öznitelik vektörleri adapte edilebileceğinden mümkün olduğu kadar karar yüzeylerine yakın olacak şekilde seçilmelidirler.

2. Sınır öznitelik vektörleri seçimi otomatik olarak yapılmalı ve uygun sayıda başlangıç öznitelik vektörü seçilebilmelidir.
3. Herbir sınıfı öznitelik uzayında dengeli biçimde temsil etmek için herbir sınıf uygun sayıda sınır öznitelik vektörüne sahip olmalıdır.

Sınır öznitelik vektörlerinin başlangıç değerlerinin seçimi için sınıf merkezleri kullanılır. Belirli bir sınıf merkezi ilgili sınıf ortalamasına en yakın vektör olarak tanımlanır. Sınıf ortalaması yerine sınıf merkezinin kullanılması, eğitim örneklerinin öznitelik uzayında içbükey şekilde dağılması durumu için bir önlemdir.

Etiketleriyle birlikte bir eğitim kümesi $\{(\bar{x}_1, y_1), (\bar{x}_2, y_2), \dots, (\bar{x}_n, y_n)\}$ şeklinde gösterilirse ve buradaki n adet eğitim kümesi vektörlerinin N boyutlu olduğu ve etiketlerinin $y_i \in \{1, 2, \dots, m\}$ şeklinde değiştiği kabul edilirse, m toplam sınıf sayısı olmak üzere sınıf ortalamaları aşağıdaki denklemde gösterildiği gibi hesaplanabilir:

$$\bar{m}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \bar{x}_j, \{\bar{x}_j | y_j = i, i = 1, \dots, m\} \quad (1)$$

Bu denklemde n_i i. sınıf için toplam örnek sayısıdır. i . sınıf için sınıf merkezi \bar{c}_i aşağıdaki denklemde gösterildiği gibi hesaplanabilir:

$$\left. \begin{aligned} \bar{c}_i &= \bar{x}_k, \\ \left\{ \begin{aligned} k &= \arg \min \{D_j\}, (1 \leq i \leq m), (1 \leq j \leq n) \\ D_j(\bar{m}_i, \bar{x}_j) &= \|\bar{m}_i - \bar{x}_j\| = \\ &= \sum_{d=1}^N \sqrt{(m_i(d) - x_j(d))^2}, \{\bar{x}_j | y_j = i\} \end{aligned} \right\} \end{aligned} \right\} \quad (2)$$

Sınır özniteliklerinin belirlenmesi algoritmasında herbir sınıf için uygun eğitim kümesi elemanları sınır öznitelik vektörlerinin başlangıç değeri olarak sınıf merkezleri yardımıyla seçilir. Sınır öznitelik vektörlerinin başlangıç değerleri

$\mathbf{B}^{t=0}$, sınıf merkezleri \mathbf{B}_0 ve herbir sınıf için sınıf merkezleri yardımıyla seçilen örnekler kümesinin, $\mathbf{B}_i, i = 1 \dots m$, birleşimidir.

$$\mathbf{B}^0 = \bigcup_{0 \leq i \leq m} \mathbf{B}_i \quad (3)$$

Sınır öznitelik vektörü $\bar{b}_j, j \leq m$ için $\bar{b}_j = \bar{c}_j$ olarak tanımlanır. Böylece b toplam belirlenen sınır öznitelik vektörü sayısı, sınıf merkezleri sayısı $m_0 = m$ ve sınıf merkezleri yardımıyla herbir sınıf için belirlenen sınır öznitelik vektörleri sayısının, $m_i, i = 1, \dots, m$, toplamı olur.

$$b = \sum_{i=0}^m m_i = m + \sum_{i=1}^m m_i \quad (4)$$


Sınır öznitelik belirleme algoritmasındaki amacımız öznitelik uzayını uygun sayıda sınır öznitelik vektörüyle temsil etmektir. Bu amaçla herbir sınıf için başlangıçta yalnızca sınıf merkezlerini referans vektörler olarak kabul eden bir belirleme algoritması uygulanır.

$$\mathbf{R}_i(t=0) = \mathbf{B}_0 \cup \mathbf{B}_i = \mathbf{B}_0 \quad (5)$$


Hangi sınıfa ait sınır öznitelikleri belirleniyorsa ilgili sınıfın tüm elemanları sadece bir kez olmak üzere rastgele seçilerek belirleme algoritmasında denenir. Seçilen eğitim kümesi örneğinin etiketi, bu eğitim kümesi örneğine en yakın bir komşuluğunda olan referans kümesi elemanının etiketinden farklı ise, kendi sınıfına ait yeni sınır öznitelik elemanı olarak \mathbf{B}_i kümesine ART1 algoritmasına benzer şekilde atanır (Carpenter ve Grosberg, 1987).

Örnek olarak bir ikili sınıflandırma problemi, iki boyutlu öznitelik uzayında Şekil 1'de gösterilmiştir. Bu şekilde 1. ve 2. sınıflara ait eğitim örnekleri sırasıyla + ve x sembolleriyle gösterilmiştir. Sınır öznitelik vektörlerine başlangıç değeri olarak atanan örnekler şekilde daire ile gösterilmiştir. Sadece sınıf merkezlerine, \mathbf{B}_0 , dayanan başlangıç karar yüzeyi ise iki boyutlu

örnek uzayda bir doğru ile gösterilmektedir. Sınıf merkezleri dışındaki sınır öznelik vektörleri, Şekil 1’de görüldüğü gibi hatalı karar verilen örnekler arasından seçilmiştir.



Şekil 1. İkili sınıflandırma problemi: sınıf merkezleri ve seçilen başlangıç sınır öznelikleri daire ile ve sadece sınıf merkezlerine dayanan karar kuralı, bir doğru ile gösterilmiştir.



Şekil 2. İki boyutlu öznelik uzayının, sınır özneliklerinin belirlenmesi işleminden sonra elde edilen başlangıç sınır öznelik vektörleriyle bölütlenmesi

Şekil 2’de ise başlangıçta seçilen tüm sınır öznelik vektörleri, \mathbf{B}^0 , öznelik uzayını bölütlemeye kullanıldığında oluşan karar sınırları görülmektedir. Bundan sonraki adım ise sınıf sınırlarını daha iyi temsil etmek için sınır

öznelik vektörlerinin adaptasyonudur. Ek olarak, adaptasyon sırasında yeni sınır öznelik vektörleri ihtiyacı ortaya çıkarsa, yeni sınır öznelik vektörleri, sınır öznelik vektörleri kümesine eklenir.

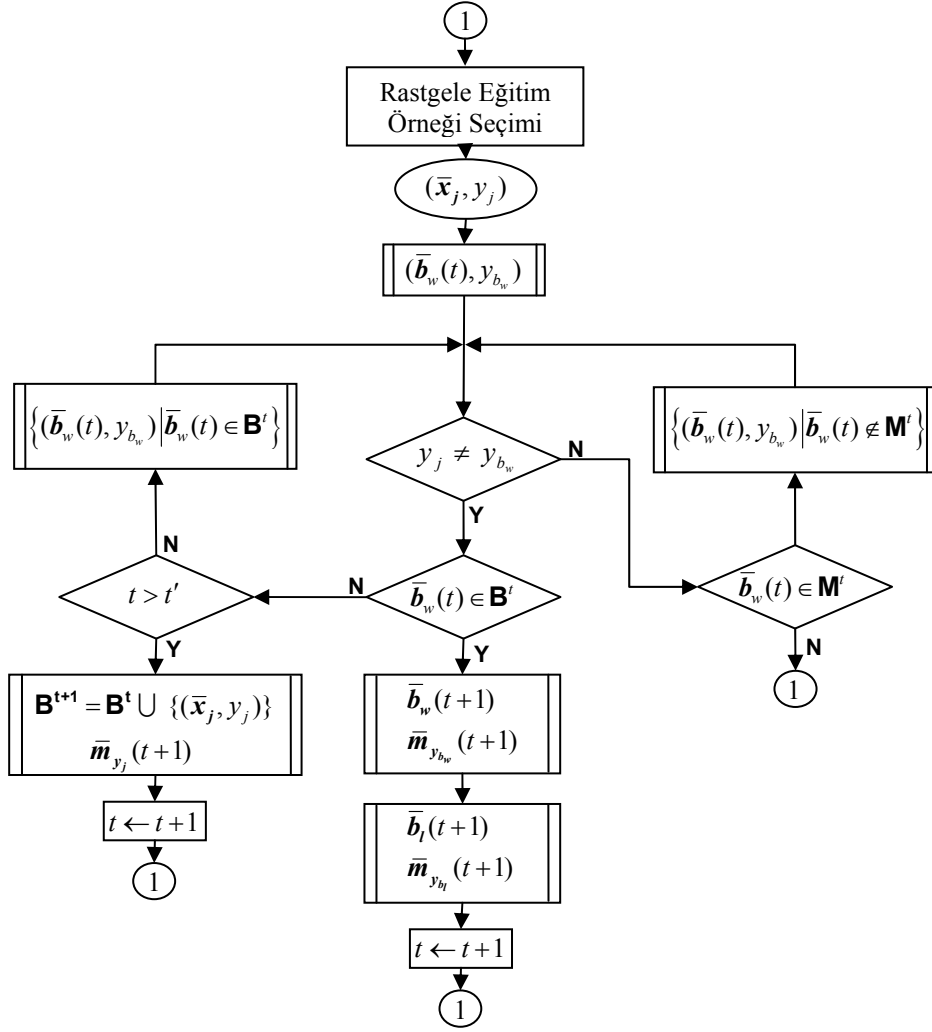
Adaptasyon işlemi

Adaptasyon işleminde yarışmacı öğrenme prensipleri aşağıda açıklandığı şekilde uygulanır: Sınır öznelik vektörlerinin başlangıç değeri, \mathbf{B}^0 , sınır öznelik vektörleri ve onların ortalamaları arasındaki mesafeyi maksimum yapmak, farklı etiketli komşu sınır öznelik vektörleri arasındaki marjini arttırmak için adaptif olarak güncellenir. Burada (3) numaralı denklemle tanımlanan sınır öznelik elemanlarının ortalaması aşağıdaki denklemle belirlenir:

$$\bar{\mathbf{m}}_i = \frac{1}{m_i + 1} \sum_{j=1}^b \bar{\mathbf{b}}_j, \{\bar{\mathbf{b}}_j | y_j = i, i = 1, \dots, m\} \quad (6)$$

$$\mathbf{M}^0 = \{(\bar{\mathbf{m}}_1, y_1), (\bar{\mathbf{m}}_2, y_2), \dots, (\bar{\mathbf{m}}_m, y_m)\} \quad (7)$$

Normal olarak sınır öznelik vektörlerinin ortalaması sonuç karar sürecinde kullanılmaz. Algoritmanın geometrik kısıtlarından ötürü sınır öznelik vektörlerinin ortalamalarının kullanılması gereksizdir. Yani sonuç karar sürecinde, test örneklerinin sınıflandırılmasında kullanılıp kullanılmaması başarıyı etkilemez. Eğitim sırasında ise sınır öznelik vektörlerinin ortalaması yeni sınır özneliğine ihtiyaç olup olmadığını gösteren kontrol vektörleri olarak düşünülebilir. Eğitim sırasında sınır öznelik vektörlerinin ortalaması hatalı karara neden oluyorsa sınırda bir açık olduğu düşünülerek eğitim sırasında hatalı karar verilen eğitim kümesi örneği sınırdaki açığı kapatmak için yeni sınır öznelik vektörü olarak sınır öznelik vektörleri kümesine eklenir. Sınır öznelik vektörlerinin adaptasyonunda, sınır öznelik vektörlerinin ortalaması da sınır öznelik vektörlerinin değişimine bağlı olarak güncellenir. Adaptasyon için uygulanan strateji aşağıdaki gibi açıklanabilir: hatalı karara neden olan en yakın sınır öznelik vektörü $\bar{\mathbf{b}}_w(t)$ hatalı karar verilen eğitim kümesi örneğinden uzaklaşmalı, seçilen eğitim kümesi



Şekil 3. SÖBA algoritması adaptasyon aşaması akış diyagramı

örneğiyle aynı etikete sahip sınır öznelik elemanı $\bar{b}_l(t)$ ise, seçilen eğitim elemanına yaklaşmalıdır. Learning vector quantization (LVQ) algoritmasına benzeyen bir adaptasyon yapısı kullanılmaktadır. Adaptasyon işlemi akış diyagramı şeklinde Şekil 3'te gösterilmiştir. \bar{x}_j 'nin y_j etiketine sahip bir eğitim kümesi örneği olduğunu varsayalım. y_{b_w} etiketli sınır öznelik vektörü $\bar{b}_w(t)$ 'nin \bar{x}_j 'ye en yakın sınır öznelik vektörü olduğunu kabul edelim. Bu durumda eğer $y_j \neq y_{b_w}$ ise adaptasyon aşağıda gösterildiği şekilde uygulanır:

$$\bar{b}_w(t+1) = \bar{b}_w(t) - \eta(t) \cdot (\bar{x}_j - \bar{b}_w(t)) \quad (8)$$

$$\bar{m}_{y_{b_w}}(t+1) = \left(m_{y_{b_w}} \bar{m}_{y_{b_w}}(t) - \eta(t) \cdot (\bar{x}_j - \bar{b}_w(t)) \right) / m_{y_{b_w}} \quad (9)$$

Eğer y_{b_l} etiketli $\bar{b}_l(t)$, eğitim için seçilen ve hatalı karar verilen \bar{x}_j ile aynı etikete sahip, $y_j = y_{b_l}$, sınır öznelik vektörleri içinde en yakında olan sınır öznelik vektörü ise, adaptasyon işlemi aşağıda ifadelerle belirlendiği şekliyle uygulanır:

$$\bar{b}_l(t+1) = \bar{b}_l(t) + \eta(t) \cdot (\bar{x}_j - \bar{b}_l(t)) \quad (10)$$

$$\bar{m}_{y_{b_l}}(t+1) = \left(m_{y_{b_l}} \bar{m}_{y_{b_l}}(t) + \eta(t) \cdot (\bar{x}_j - \bar{b}_l(t)) \right) / m_{y_{b_l}} \quad (11)$$

Adaptasyon ifadelerindeki $\eta(t)$ zamanla azalan bir fonksiyon olup öğrenme hızı olarak adlandırılır. $\eta(t)$ için iyi bir seçim aşağıdaki ifade de verilmiştir.

$$\eta(t) = \eta_0 e^{-t/\tau} \quad (12)$$

Adaptasyon sırasında t' gibi önceden belirlenmiş bir iterasyon sayısına ulaşıldıktan sonra, \mathbf{M}^t ve \mathbf{B}^t kümelerinin birleşimi referans düğümler olarak giriş eğitim vektörlerinin sınıflandırılması için kullanılır. Eğer y_j etiketli seçilmiş \bar{x}_j eğitim kümesi örneği için en yakın referans düğüm y_{m_w} etiketli bir sınır özniteliklerinin ortalaması kümesi elemanı $\bar{m}_w(t > t')$ ise ve $y_j \neq y_{m_w}$ durumunda hatalı karar verilen eğitim örneği \bar{x}_j , yeni sınır öznitelik vektörü olarak eklenir.

$$\mathbf{B}^{t+1} = \mathbf{B}^t \cup \{(\bar{x}_j, y_j)\}, \quad (t > t') \quad (13)$$

Bu durumda ilgili ortalama vektörü de aşağıdaki şekilde güncellenecektir.

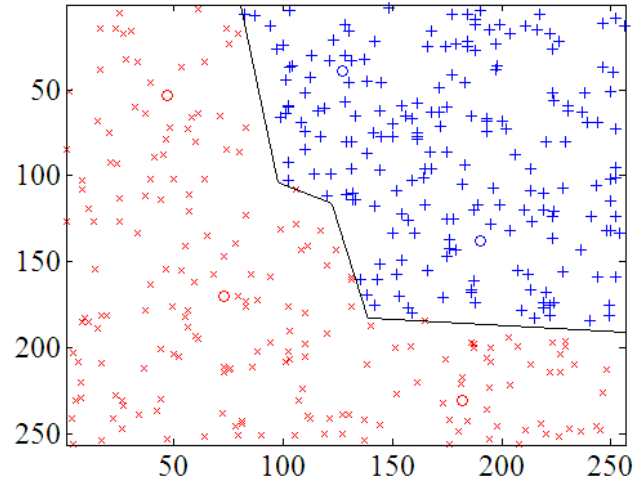
$$\bar{m}_{y_j}(t+1) = \left(m_{y_j}(t) \cdot \bar{m}_{y_j}(t) + \bar{x}_j \right) / (m_{y_j}(t) + 1) \quad (14)$$

(14) ifadesinde $m_{y_j}(t)$, t iterasyonu anında y_j etiketli sınır öznitelik vektörlerinin sayısıdır. Bundan dolayı $m_{y_j}(t+1)$ eklenen yeni sınır öznitelik vektöründen sonra sonra y_j etiketli sınır öznitelik vektörleri sayısını gösterir.

Şekil 1'de gösterilen iki boyutlu öznitelik uzayında ikili sınıflandırma için adaptasyon neticesinde elde edilen sonuç karar sınırları, doğru parçalarının bir birleşimi şeklinde Şekil 4'de gösterilmiştir. Şekilde adaptasyon neticesinde elde edilen sınır öznitelik vektörleri ise daire şeklinde gösterilmişlerdir.

Test kümesi örneklerinin sınıflandırılması, seçilen örneğin adaptasyon sonucunda elde edilen sınır öznitelik vektörlerine olan en yakın bir komşuluğu dikkate alınarak yapılır. Sadece bir komşuluğun dikkate alınması sınır öznitelik vektörlerinin sınırlarda karşılıklı olarak yer alması istendiğinden anlamlıdır. Yapılan deneme-

lerden elde edilen sonuçlara göre bu öngörünün gerçekleştiği gösterilmiştir.

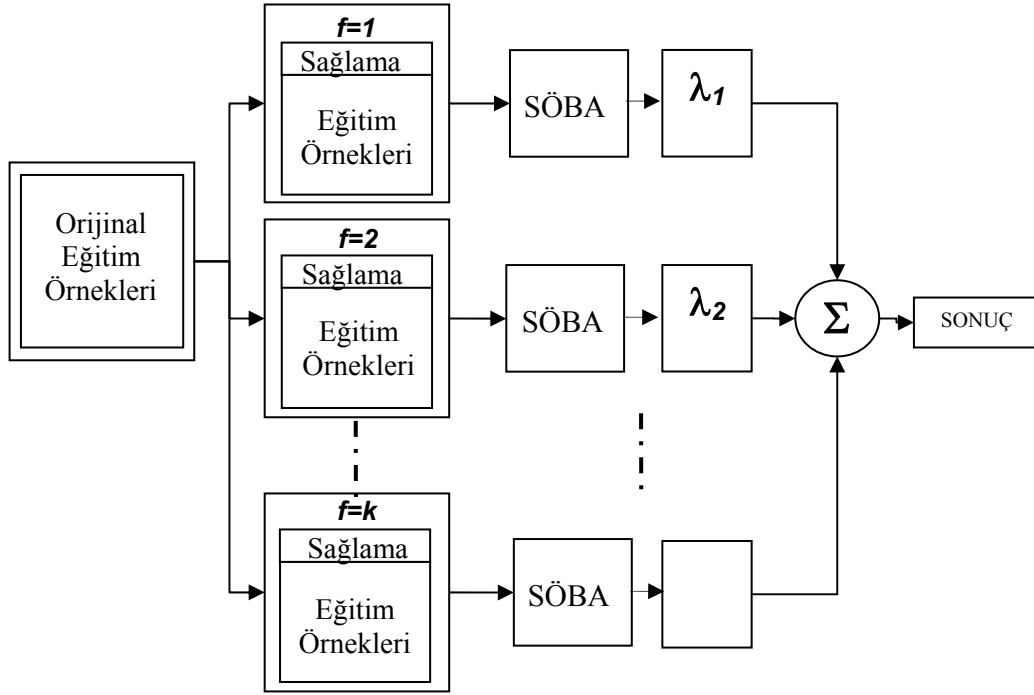


Şekil 4. İki boyutlu öznitelik uzayının, adaptasyon işleminden sonra elde edilen sonuç sınır öznitelik vektörleriyle bölütlenmesi

SÖBA sonuçlarının konsensüs karar verici yapılarda kullanılması

SÖBA algoritmasının sonucu, hem sınır özniteliklerinin belirlenmesi, hem de adaptasyonu sırasında kullanılan eğitim kümesi örneklerinin seçilme sırasıyla yakından ilgilidir. SÖBA'nın farklı her koşuturulmasında, rastgele seçilen eğitim kümesi örnekleri nedeniyle, öznitelik uzayı yaklaşık benzer başarımlar sağlayarak farklı şekilde bölütlenebilmektedir. Daha önce sıkça kullanılan hem parametrik hem de parametrik olmayan sınıflayıcıların kararlarının birleştirilmesiyle karşılaştırıldığında sistem yaklaşımı açısından, SÖBA'nın farklı sonuçlarının birleştirilmesi tatminkar sonuçlar vermektedir. Konsensüs karar verici kuralları ise maksimum kuralı, minimum kuralı, ortalama kuralı ve çoğunluk oylaması kuralı olabilmektedir (Benediktsson vd., 1997; Jimenez vd., 1999). Bunlara ek olarak en küçük kareler analizi yöntemiyle de birleştirilecek kararlar için optimal ağırlık katsayıları belirlenebilmektedir (Lee ve Ersoy, 2006). Hatta yapay sinir ağları ve SÖBA algoritması da kararların birleştirilmesi için kullanılabilir.

Şekil 5'te, bu çalışmada önerilen konsensüs yapısı gösterilmiştir. Konsensüs yapısında, çapraz sağlama yöntemi yansız kararlar verilmesi için



Şekil 5. k parçalı çapraz sağlama kullanılarak oluşturulan konsensüs stratejisi blok şeması

konsensüs ile birlikte kullanılmıştır. Yine kaç farklı kararın birleştirilmesi gerektiği, çapraz sağlama yöntemi sayesinde daha doğru bir biçimde belirlenebilmektedir. Konsensüs kuralı olarak çoğunluk oylaması yöntemi ile birlikte, güvenilirlik faktörüne bağlı olarak elde edilen her bir karar için farklı ağırlıkların kullanılması da çapraz sağlama sayesinde mümkün olmaktadır. Bu yöntemlere ek olarak ağırlık katsayılarının, λ_i , $i=1\dots k$ bulunması için ortalama karasel hatanın minimize edilmesi de önerilen konsensüs yapısı sayesinde gerçekleştirilebilir. Bu çalışmada çoğunluk oylaması kuralı sonuçları verilmiştir. Sonuçlarda görülen konsensüs SÖBA neticeleri, 10 parçalı çapraz sağlama yöntemiyle birlikte kullanılan SÖBA'nın, 10 kez çalıştırılması ile elde edilen 10 farklı sonucun, herbir piksel için karar verilirken, çoğunluk oylaması yöntemi kullanılarak elde edilmiştir.

Deneysel Sonuçlar


Kullanılan data ve kurulan deneyler

Deneylerde, kuzeybatı Indiana'dan 1992 Haziran ayında toplanan AVIRIS datası kullanılmıştır (Langrebe ve Biehl, 1992). Şekil 6'da gösterilen bu data çok iyi bilinen bir test datasıdır ve sıklıkla hiperspektral dataların sınıflandırılma

algoritmalarını test etmek için kullanılmaktadır. Kullanılan data setinin boyutları 145x145 piksel olup, iki farklı sınıf ve iki farklı spektral band kombinasyonu için deneyler kurulmuştur. 17 sınıflık eğitim kümesi örnekleri (değişik sınıfların bir karışımı olan bazı örnekler karışım tip sınıf örnekleri olarak ele alınmıştır) ve 9 sınıflık örnekler (istatistiksel olarak anlamlı 9 sınıf ele alınmıştır), 9 spektral band (multispektral dataları temsil etmesi için) ve 190 spektral band (30 spektral band orijinal band sayısı 220 olan AVIRIS datasından atmosferik etkilerden ötürü çıkarılarak kullanılmamıştır) için oluşturulmuştur. Özetle 17 sınıf, 9 ve 190 boyutlu örnekler data kümeleri 1 ve 2, 9 sınıf, 9 ve 190 boyutlu örnekler ise data kümeleri 3 ve 4 olarak isimlendirilmiştir.

Karşılaştırma

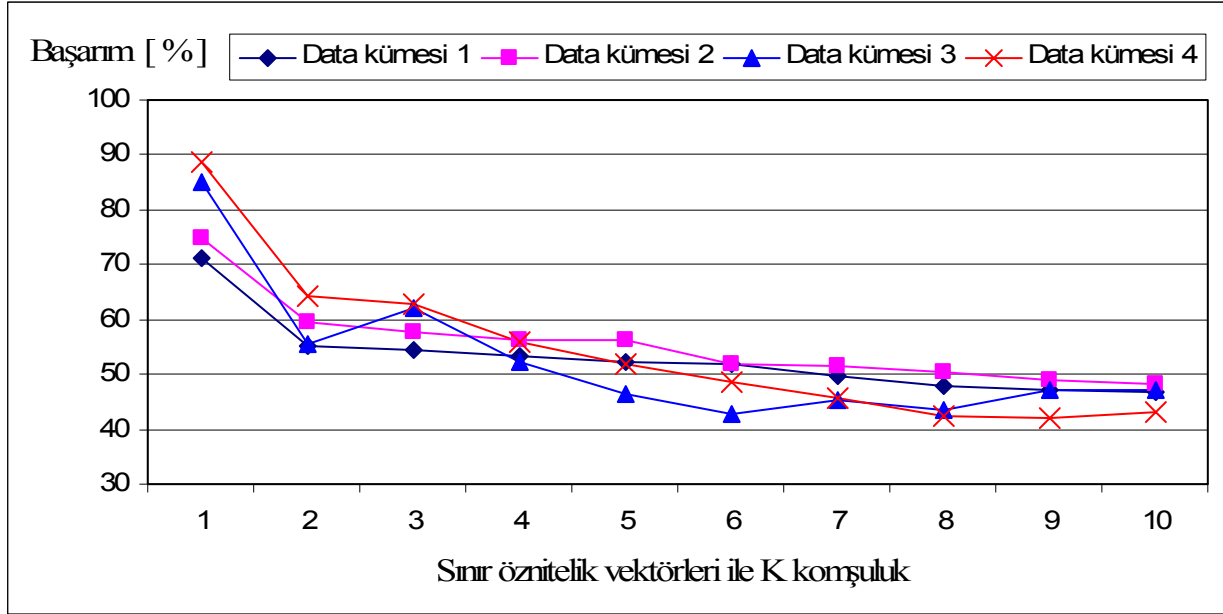
SÖBA algoritmasının başarımı, destek vektör makinalarının (Melgani, ve Bruzzone, 2004) yanında maksimum olabilirlik, Fisher doğrusal olabilirlik, ilinti ve uyumlu süzgeçleme gibi istatistiksel sınıflayıcılar ve parametrik olmayan K en yakın komşuluk (K-EK) algoritması da dahil olmak üzere karşılaştırmalı olarak verilmiştir. Tablo 1'de ortalama eğitim, test başarımları, 4 farklı data kümesi için, kappa istatistiği de



Şekil 6. AVIRIS datası a) 50, 27 ve 17. bandlar için görüntü b) 17 sınıf için referans yer verisi

Tablo 1. Ortalama eğitim test başarımları ve kappa istatistiği

Data Kümesi	Metod	Eğitim		Test	
		Başarım %	κ	Başarım %	κ
1	Maksimum Olabilirlik	84.83	0.82	67.56	0.63
	Fisher Doğrusal Olabilirlik	63.7	0.59	47.3	0.42
	İlinti	48.4	0.43	37.2	0.31
	Uyumlu Süzgeçleme	32.8	0.24	36.1	0.29
	K-EK	89.01	0.87	68.06	0.63
	RTF-DVM	86.10	0.83	71.73	0.67
	SÖBA	94.05	0.89	70.82	0.66
Konsensüs SÖBA	96.41	0.95	73.36	0.69	
2	K-EK	90.71	0.89	70.01	0.65
	RTF-DVM	87.54	0.86	77.64	0.74
	SÖBA	99.46	0.99	76.40	0.73
	Konsensüs SÖBA	100	1	78.71	0.75
3	Maksimum Olabilirlik	86.99	0.85	77.07	0.74
	K-EK	93.69	0.92	83.04	0.80
	RTF-DVM	90.93	0.89	84.74	0.81
	SÖBA	99.15	0.99	84.98	0.82
	Konsensüs SÖBA	99.68	0.99	87.98	0.86
4	Maksimum Olabilirlik	100	1	67.00	0.57
	Fisher Doğrusal Olabilirlik	91.3	0.90	81.8	0.78
	İlinti	45.4	0.39	47.7	0.40
	Uyumlu Süzgeçleme	78.1	0.75	72.6	0.67
	K-EK	95.08	0.94	84.31	0.81
	RTF-DVM	100	1	91.39	0.89
	SÖBA	100	1	88.58	0.86
Konsensüs SÖBA	100	1	90.18	0.88	



Şekil 7. K'ya bağlı SÖBA başarımı

dahil olmak üzere gösterilmiştir. Kappa istatistiği genel sınıflandırma başarımının yanında her bir sınıf için verilen kararların güvenilirliğinin de bir göstergesidir. Öyle ki azınlık sınıflarının korunup korunmadığı hakkında bize güvenilir bilgiler sunar. Tablo 1'de data kümesi 4 için maksimum olabilirlik sınıflayıcı sonuçlarından anlaşılacağı gibi kappa istatistiğinin test başarımından çok düşük olduğu durumda sadece fazlaca eğitim örneği içeren sınıfların korunduğu anlaşılabilir. Data kümeleri 1 ve 2 için sınıflandırma probleminin karmaşıklığı data kümeleri 3 ve 4'e göre nispeten fazladır. Ayrıca data kümesi 1'de karışım tipli bir sınıf da mevcuttur. Data kümeleri 1 ve 2 için az sayıda örnek içeren azınlık sınıfları da bulunmaktadır. Data kümeleri 2 ve 4 için ise istatistiksel olarak anlamlı sınıfların ele alındığı söylenebilir. SÖBA algoritmasının başarımı geleneksel istatistiksel yöntemlere nazaran tüm data kümeleri için oldukça iyidir. Özellikle azınlık sınıflarını da içeren karmaşık problemlerde, data kümeleri 1 ve 2'de olduğu gibi, SÖBA algoritması destek vektör makinalarıyla birlikte en iyi sonuçları vermektedir. Problemin karmaşıklığı azaldığında, radyal tabanlı fonksiyon - destek vektör makinalarının (RTF-DVM) başarımının yükseldiği söylenebilir. Elde edilen sonuçlar göstermiştir ki bu çalışmada tanıtılan SÖBA algorit-

ması hem multispektral hem de hiperspektral datalar için sınıfların istatistiğine bağlı kalmaksızın tutarlı sonuçlar üretmektedir. Konsensüs SÖBA için ise verilen sonuçlar, SÖBA'nın 10 parçalı çapraz sağlama kullanılarak çalıştırılması sonucu elde edilen sonuçların çoğunluk uygulaması yöntemiyle birleştirilmesiyle elde edilmiştir. Konsensüs SÖBA algoritması için sonuçlar, tüm data kümeleri için oldukça tatminkardır. Şekil 7'de ise adaptasyon sonucu elde edilen sonuç sınır öznelik elemanlarına uygulanan K-EK'de K'ya bağlı başarımın değişimi görülmektedir. Bu beklenen sonuç neticesinde SÖBA'da K=1 alınmalıdır.

Kaynaklar

- Alpaydin, E., (1991). GAL: networks that grow when they learn and shrink when they forget, Technical Report 91-032, International Computer Science Institute, Berkeley, CA.
- Benediktsson, J.A., Sveinsson, J.R., Ersoy, O.K. ve Swain, P.H., (1997). Parallel consensual neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, **8**, 1, 54-64.
- Carpenter, G.A. ve Grosberg, S., (1987). A massively parallel architecture for a self organizing neural pattern recognition machine, *Computer Vision, Graphics, and Image Processing*, **37**, 54-115.
- Chee, H.M. ve Ersoy, O.K., (2005). A statistical self-organizing learning system for remote sens-

- ing classification, *IEEE Transactions on Geoscience and Remote Sensing*, **432**, 1890-1900.
- Cristianini, N. ve Taylor, J.S., (2000). *Support Vector Machines*, Cambridge University Press, Newyork.
- Duda, R.O., Hart, P.E. and Stork, D.G., (2001). *Pattern Classification*, John Wiley & Sons, New York.
- Foody, G.M. ve Mathur, A., (2006). The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM, *Remote Sensing of Environment*, **103**, 179-189.
- Fukunaga, K., (1990). *Introduction to Statistical Pattern Recognition*, Academic Press, San Diego.
- Jimenez, L.O., Morell, A.M. ve Creus, A., (1999). Classification of hyperdimensional data based feature and decision fusion approaches using projection pursuit, majority voting, and neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, **37**, 1360-1366.
- Joachims, T., (1999). *Making large-Scale SVM Learning Practical. Advances in Kernel Methods* in Schölkopf, B., Burges, C., ve Smola, A., eds, *Support Vector Learning*, MIT-Press, Newyork.
- Kasapoğlu, N.G., Ersoy, O.K. ve Yazgan B., (2006). Border feature detection and adaptation for classification of remote sensing images, *Proceeding of IGARSS 06*, Denver, USA.
- Kasapoğlu, N.G. ve Ersoy, O., (2007). Border feature detection and adaptation for classification of multispectral and hyperspectral remote sensing images, Technical Report TR-ECE-07-06, Purdue University, W. Lafayette, IN.
- Kohonen, T., (1990). The self-organizing map, *Proceedings of the IEEE*, **78**, 9.
- Langrebe D. ve Biehl, L., (1992). Multispec and AVIRIS NW Indiana's Indian Pines data set. <http://www.ece.purdue.edu/~biehl/MultiSpec/index.html>.
- Landgrebe, D.A., (2003). *Signal Theory and Methods in Multispectral Remote Sensing*, John Wiley & Sons, New Jersey.
- Lee, J. ve Ersoy, O., (2006). Consensual and hierarchical classification of remotely sensed multispectral images, *Proceedings of IGARRS 06*, Denver, USA.
- Melgani, F. ve Bruzzone, L., (2004). Classification of hyperspectral remote sensing images with support vector machines, *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1778-1790.
- Richards, J.A., (1993). *Remote Sensing Digital Image Analysis, An Introduction*, Springer-Verlag, New York.
- Vapnik, V.N., (1998). *Statistical Learning Theory*, Wiley, New York.