

**KOCAELİ ÜNİVERSİTESİ \*FEN BİLİMLERİ ENSTİTÜSÜ**

**AKILLI HİPERSPEKTRAL SINIFLANDIRMA**

**YÜKSEK LİSANS TEZİ**

**Elektronik ve Haberleşme Mühendisi Begüm DEMİR**

**Anabilim Dalı: Elektronik ve Haberleşme Mühendisliği**

**Danışman: Doç. Dr. Sarp Ertürk**

**KOCAELİ, 2007**

**KOCAELİ ÜNİVERSİTESİ\*FEN BİLİMLERİ ENSTİTÜSÜ**

**HİPERSPEKTRAL GÖRÜNTÜLERDE AKILLI  
SINIFLANDIRMA YÖNTEMLERİ**

**YÜKSEK LİSANS TEZİ**

**Elektronik ve Haberleşme Mühendisi Begüm DEMİR**

**Tezin Enstitüye Verildiği Tarih : 04.06.2007**

**Tezin Savunulduğu Tarih : 13.07.2007**

**Tez Danışmanı**

**Üye**

**Üye**

**Doç. Dr.**

**Sarp ERTÜRK**

  
(.....)

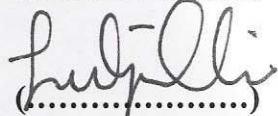
**Yrd. Doç. Dr**

**Cabir VURAL**

  
(.....)

**Yrd. Doç. Dr.**

**M. Kemal GÜLLÜ**

  
(.....)

**KOCAELİ, 2007**

## ÖNSÖZ ve TEŞEKKÜR

Bu tez çalışması, Türkiye Bilimsel ve Teknik Araştırma Kurumu, TÜBİTAK tarafından "Hiperspektral Sınıflandırma, Bölütleme ve Tanıma" (HİSSET) isimli araştırma projesi kapsamında desteklenmiştir. Askeri, savunma, medikal, tarım, hayvancılık, tekstil, çevre, madencilik, kimlik tespiti gibi birçok alanda uygulaması bulunan hiperspektral görüntüleme üzerine özellikle ülkemizde yapılmış olan çalışmaların yetersiz düzeyde olması nedeni ile hiperspektral görüntülerin akıllı sınıflandırılması ile ilgili gerçekleştirdiğim çalışmanın bu konuda çalışmak isteyenlere faydalı olmasını temenni ederim.

Lisans yıllarından itibaren kendisiyle çalışmanın hayalini kurduğum, kendisiyle çalıştığım için hep şanslı olduğumu düşündüğüm ve bir gün umarım onun gibi olabilirim diye daha çok çalıştığım danışman hocam Doç. Dr. Sarp Ertürk'e, tezim ile ilgili yoğun çalışmalarım sırasında Kulis'de olmamalarına rağmen desteklerini hep hissettiren Yrd. Doç. Oguzhan Urhan, Yrd. Doç. Kemal Güllü ve Arş. Gör. Anıl Çelebi'ye teşekkür ederim.

Tezim ile ilgili yaşadığım sorunları benim ile birlikte yaşayarak, mutlu olabilmem için ellerinden geleni yapan aileme ve Ceyhan ailesine göstermiş oldukları tüm fedakarlıklar için ne kadar teşekkür etsem azdır. Yoğun çalışmalarım sırasında vakit ayıramadığım, ama onlarla gecirdiğim 4 yılın her dakikasını özlediğim lisans arkadaş grubuma anlayışlarından dolayı teşekkür ederim.

## İÇİNDEKİLER

ÖNSÖZ ve TEŞEKKÜR.....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ.....	iii
TABLolar DİZİNİ .....	iv
SİMGELER DİZİNİ .....	v
KISALTMALAR .....	v
ÖZET .....	vi
İNGİLİZCE ÖZET.....	vii
1. GİRİŞ .....	1
2. UZAKTAN ALGILAMA .....	4
2.1 Giriş .....	4
2.2 Pankromatik Görüntüleme.....	6
2.3 Multispektral Görüntüleme.....	6
2.4 Hiperspektral Görüntüleme .....	6
3. HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA .....	11
3.1 Eğitimsiz (Denetimsiz) Sınıflandırma .....	13
3.2 Eğitilmiş (Denetimli) Sınıflandırma .....	15
4. AKILLI HİPERSPEKTRAL SINIFLANDIRMA YÖNTEMLERİ .....	17
4.1 Destek Vektör Makinaları .....	17
4.1.1 Doğrusal ayrılabilir D.V.M ile sınıflandırma .....	18
4.1.2 Doğrusal olarak ayrılamayan D.V.M ile sınıflandırma .....	20
4.2 İlgililik Vektör Makinaları Kullanılarak Sınıflandırma.....	24
4.3 İlgililik Vektör Makinaları ile Destek Vektör Makinalarının Karşılaştırılması	26
4.4 Çoklu Sınıf Sınıflandırması .....	27
4.5 Deneysel Sonuçlar .....	31
5. SEYREKLİK-SINIFLANDIRMA BAŞARIMI DEĞİŞ TokuŞU .....	36
5.1 Faz Korelasyonu Kullanarak Bölütleme.....	36
5.2 K-Ortalama Bölütlemesi .....	37
5.3 Rasgele Örnek Onaylaşım Yaklaşımı.....	38
5.4 Deneysel Sonuçlar .....	39
6. SONUÇLAR VE ÖNERİLER .....	44
KAYNAKLAR .....	46
KİŞİSEL YAYINLAR ve ESERLER.....	52
ÖZGEÇMİŞ .....	53

## ŞEKİLLER DİZİNİ

Şekil 1.1: Uzaktan algılama yöntemleri ile elde edilen görüntüler: (a) 17 Ağustos depreminden sonra Kocaeli [1] , (b) Esperanza yangını, California [2] .....	2
Şekil 2.1: (a): Pankromatik görüntülerde (b): multispektral görüntülerde (c): hiperspektral görüntülerde dalga boyuna göre elde edilen ortalama bant miktarları... 5	5
Şekil 2.2: Hiperspektral küp.....	7
Şekil 2.3: Hiperspektral görüntülerdeki her piksel için dalga boyuna bağlı spektrumun elde edilmesi.....	7
Şekil 2.4: Aynı ve farklı malzemelerin spektral imzaları .....	9
Şekil 2.5: Multispektral ve hiperspektral görüntülerin karşılaştırılması.....	9
Şekil 2.6: Farklı algılayıcılar ile elde edilen hiperspektral görüntüler.....	10
Şekil 3.1: Üç bantlı veri için sınıflandırma sonucu.....	12
Şekil 3.2: Şubat 2004’de Stennis uzay merkezinde alınan görüntü.....	12
Şekil 3.3: (a) Mineral (cuprite) bölgesinden bir görüntü (b) faz korelasyonu bölütleme sonucu (her renk farklı bir sınıfı göstermektedir) [41].....	14
Şekil 3.4: (a) orijinal hiperspektral görüntü, (b) hiperspektral görüntünün polinom kerneli ile D.V.M sınıflandırılması (c) hiperspektral görüntünün radyal temel fonksiyonu (R.T.F) kerneli ile D.V.M sınıflandırılması .....	16
Şekil 4.1: (a) İki sınıflı veriyi ayıran bir alt düzlem, (b) en iyi alt düzlem .....	19
Şekil 4.2: Her özellik vektörüne ait $\alpha$ değerleri.....	20
Şekil 4.3: Doğrusal olarak ayrılabilen veri.....	21
Şekil 4.4: (a) doğrusal ayrılabilir veri (b) doğrusal ayrılabilir yüksek boyutlu uzayda ayrılabilir veri .....	23
Şekil 4.5: Yüksek boyutlu uzayda doğrusal olarak ayrılabilir veri.....	23
Şekil 4.6: Bire-hepsi çoklu D.V.M sınıflandırma .....	29
Şekil 4.7: Bire-bir çoklu D.V.M sınıflandırma .....	30
Şekil 4.8: Çoklu sınıflandırma için paralel yaklaşım blok diyagramı.....	31
Şekil 4.9: Hiperspektral görüntünün tek bandı (b): sınıf bilgisi verisi (c) R.T.F kernel ( $\gamma =1$ , $C=65$ ) kullanılarak D.V.M ile elde edilen sınıflandırma haritası (d) R.T.F kernel ( $\gamma =1$ ) kullanılarak İ.V.M ile elde edilen sınıflandırma haritası. ....	33
Şekil 5.1: R.T.F kerneli kullanılarak (a) D.V.M ( $\gamma=2$ , $C=40$ ) sonucu oluşan sınıf haritası (b) İ.V.M ( $\gamma =2$ ) sonucu oluşan sınıf haritası (e) $K$ -ortalama D.V.M ( $\gamma=2$ , $C=40$ ) sonucunda oluşan sınıf haritası (f) $K$ -ortalama İ.V.M ( $\gamma =2$ , $C=40$ ) sonucunda oluşan sınıf haritası .....	43

## TABLolar DİZİNİ

Tablo 4.1: Eğitim ve test örneklerinin miktarları.....	34
Tablo 4.2 : İ.V.M sınıflandırma sonuçları.....	34
Tablo 4.3: D.V.M sınıflandırma sonuçları.....	34
Tablo 4.4: Farklı boyutlarda eğitim verisi kullanılarak elde edilen D.V.M ve İ.V.M sınıflandırma sonuçları.....	35
Tablo 5.1: Eğitim verisinde % 88 oranında örnek seyreltimi sonucu elde edilen sonuçlar.....	41
Tablo 5.2: Eğitim verisinde % 78 oranında örnek seyreltimi sonucu elde edilen sonuçlar.....	41
Tablo 5.3: Eğitim verisinde % 66 oranında örnek seyreltimi sonucu elde edilen sonuçlar.....	41
Tablo 5.4: Eğitim verisinde % 50 oranında örnek seyreltimi sonucu elde edilen sonuçlar.....	41
Tablo 5.5: Eğitim verisinde % 25 oranında örnek seyreltimi sonucu elde edilen sonuçlar.....	42
Tablo 5.6: Farklı kernel parametreleri için sonuçlar.....	42
Tablo 5.7: Farklı kernel parametreleri için sonuçlar.....	42

## SİMGELER DİZİNİ

$C$	: Düzenleme parametresi
$d$	: Çokterimli kernel fonksiyonu kernel parametresi
$f$	: Sınıflandırma fonksiyonu
$F$	: İki boyutlu ayrık Fourier dönüşümü
$F^{-1}$	: İki boyutlu ters ayrık Fourier dönüşümü
$I$	: İmge çerçevesi
$k$	: Sınıf sayısı
$K$	: Küme Sayısı
$K()$	: Kernel fonksiyonu
$r_i$	: $x_i$ verisinin sınıf bilgisi
$S_i$	: $i$ . sınıf
$x_i$	: Eğitim setindeki $i$ . veri
$w$	: Ağırlık vektörü
$\alpha$	: Lagrange çarpanı
$\varepsilon$	: Yapay değişken
$\Sigma$	: Kovaryans matrisi
$\phi()$	: Doğrusal olmayan dönüşüm
$\gamma$	: Radyal temel fonksiyonu ve çokterimli kernel fonksiyonu kernel parametresi
$\sigma()$	: Lojistik sigmoid bağlantı fonksiyonu

## KISALTMALAR

A.F.D	: İki boyutlu ayrık Fourier dönüşümü
A.V.I.R.I.S	: Visible/Infrared Imaging Spectrometer
Ç.T.K	: Çokterimli kernel fonksiyonu
D.V	: Destek vektörleri
D.V.M	: Destek vektör makinaları
F.K	: Faz korelasyonu
I.S.O.D.A.T.A	: Iterative Self Organizing Data Analyses Tecnique
İ.V.M	: İlgililik vektör makinaları
İ.V	: İlgililik vektörleri
RAS.ÖR.ON	: Rasgele örnek onaylaşım
R.T.F	: Radyal temel fonksiyonu
S.B	: Sınıflandırma başarımı
T.B.A	: Temel bileşen analizi

## AKILLI HİPERSPEKTRAL SINIFLANDIRMA

Begüm DEMİR

**Anahtar Kelimeler:** Uzaktan Algılama, Hiperspektral Görüntüleme, Hiperspektral Görüntülerde Sınıflandırma, Destek Vektör Makinaları, İlgililik Vektör Makinaları, RAS.ÖR.ON, Faz Korelasyonu, *K*-Ortalama Bölütlemesi.

**Özet:** Hiperspektral görüntüleme birçok dar dalga boyu bandına ait imge verilerini elde etmekte ve dalga boyuna göre bir ayrışım sağlamaktadır. Hiperspektral görüntülerde her piksel için dalga boyuna bağlı bir spektrum bilgisi elde edilmesi ile piksellerin değişimi, benzerlikleri ve farklılıklarının algılanabilmesi sonucu, bölgelerin sınıflandırılması standart görüntü algılayıcılarına oranla çok daha yüksek bir başarımla sağlanabilmektedir. Bu tezde hiperspektral görüntülerin akıllı sınıflandırılması yöntemleri üzerinde çalışılmıştır. Akıllı sınıflandırma yöntemleri olarak destek vektör makinaları ve ilgililik vektör makinaları kullanılmıştır. Destek vektör makinalarının hiperspektral görüntüye uygulanması ile ilgili çalışmalar literatürde olmasına rağmen ilgililik vektör makinalarının hiperspektral görüntülerin sınıflandırılmasında kullanılması özgün olarak bu çalışma kapsamında gerçekleştirmiştir. İlgililik vektör makinaları kullanılarak hiperspektral görüntülerin sınıflandırılması, destek vektör makinaları kullanılarak gerçekleştirilen sınıflandırma ile karşılaştırıldığında daha az kernel fonksiyonu kullanılarak yaklaşık benzer sınıflandırma başarımı elde edildiği görülmüştür. Ayrıca özgün olarak, sınıflandırmadaki hesapsal yükün eğitim ve test sürelerine bağlı olarak azaltılması amacı ile *K*-ortalama ve faz korelasyonu temelli bölütleme yöntemleri ve Rastgele Örnek Onaylaşım (RAS.ÖR.ON) bağımsızlık geçerlilik sınaması (cross-validation), hiperspektral görüntülerin ilgililik vektör makinaları ve destek vektör makinaları kullanılarak sınıflandırılması öncesi ön işlem olarak hiperspektral görüntüye uygulanmıştır. Ön-işlem uygulanarak gerçekleştirilen ilgililik/destek vektör makinaları ile sınıflandırma, doğrudan ilgililik /destek vektör makinaları kullanılarak gerçekleştirilen sınıflandırma ile karşılaştırıldığında, daha küçük oranda ilgililik /destek vektörleri kullanılarak benzer sınıflandırma başarımı elde edilebileceği gösterilmiştir.



# SMART HYPERSPECTRAL CLASSIFICATION

**Begüm DEMİR**

**Keywords:** Remote Sensing, Hyperspectral Imaging, Hyperspectral Image Classification, Relevance Vector Machines, Support Vector Machines, RANSAC, Phase Correlation, *K*-means clustering.


**Abstract:** Hyperspectral imaging systems provide many images corresponding to narrow spectral bands and therefore they provide decomposition with respect to wavelength. The corresponding spectrum information is obtained for every pixel within the image. It is possible to determine changes, similarities and differences using the spectral information for each pixel within the hyperspectral image. Hence it becomes possible to classify the regions within the image with much higher accuracy compared to standard vision sensors. Smart classification methods of hyperspectral images namely: relevance vector machines and support vector machines are studied in this thesis. Although support vector machine classification has recently been proposed for hyperspectral image classification and raised important interest, relevance vector machine classification of hyperspectral images is genuinely proposed in this thesis. It is shown that similar accuracy results are obtained with a smaller relevance vector rate and faster testing time compared with support vector machine classification. In addition two different unsupervised segmentation methods namely: *K*-means and phase correlation as well as RANSAC (RANdom SAmple Consensus) are applied to hyperspectral images before relevance vector machine and support vector machine classification. Approximately similar hyperspectral data classification accuracy is obtained with a smaller relevance vector rate/support vector rate and faster training time for the proposed pre-segmented relevance vector machine /support vector machine classification approach compared with direct relevance vector machine /support vector machine classification.

## 1. GİRİŞ


Hızlı nüfus artışı, kısıtlı doğal kaynaklar ve çevre kirliliği, yeryüzü hakkında hızlı ve doğru bilgiye olan ihtiyacın artmasına neden olmaktadır. Hava ve uydu görüntüleri kullanılarak bu problemler çözülmeye çalışılmaktadır. Bu görüntüleri elde etmek amacı ile özellikle havadan ve uzaydan cisimlerin özelliklerini kaydetme ve inceleme tekniği olarak tanımlanan uzaktan algılama yöntemleri önem kazanmaktadır. Şekil 1.1'de uzaktan algılama yöntemleriyle oluşturulan görüntüler gösterilmektedir. Bu görüntülerde her bir renk ayrı bir nesneyi temsil etmektedir. Şekil 1.1 (a)'da 17 ağustos 1999'da meydana gelen depremden sonraki Kocaeli iline ait görüntü gösterilmektedir. Yeşil renkler ormanlık alanı, mavi renkler su yüzeylerini, kırmızı alanlar tarım alanlarını, sarı alanlar da yerleşim yerlerini göstermektedir [1]. Şekil 1.1 (b)'de ise Esperanza yangınına ait görüntü gösterilmektedir. Kırmızı yerler yanan bölgeleri göstermektedir [2].

Gerçekleştirilen tez kapsamında dar bantlı ve sürekli aralıklandırılmış yüzlerce spektral bantta veri toplayan hiperspektral algılayıcılar kullanılarak elde edilen uzaktan algılama görüntülerinin akıllı sınıflandırma yöntemleri ile sınıflandırılması ve sınıflandırılma öncesinde eğitimsiz sınıflandırma yöntemleri kullanılarak hiperspektral verinin sıkıştırılması gerçekleştirilmiştir.

Hiperspektral görüntüleme, imge verilerini dar birçok dalga boyu bandında elde etmektedir ve dalgaboyuna göre bir ayrışım sağlamaktadır. Hiperspektral görüntüleme, inceleme alanının jeofizik, jeokimya, mineralojik-petrografik özellikleri tanımlanmadan alan hakkında geniş bir bilgi sahibi olmamıza yaramaktadır. Uçak veya uyduya monte edilen hiperspektral görüntüleme algılayıcıları kullanılarak mineral (kayaç ve toprak) haritalaması yapılabilmektedir ve bu nedenle hiperspektral görüntüleme, maden yataklarının tespitinde son yıllarda kullanılmaktadır. Bölüm 2'de hiperspektral, multispektral ve pankromatik görüntü algılayıcıları ile ilgili detaylı bilgiler verilmiştir.



(a)



(b)

Şekil 1.1: Uzaktan algılama yöntemleri ile elde edilen görüntüler: (a) 17 Ağustos depreminden sonra Kocaeli [1] , (b) Esperanza yangını, California [2]

Hiperspektral görüntülerde her bir görüntü elemanının değişimi, benzerlikleri ve farklılıkları piksel değerlerinin dalgaboyuna göre değişimi incelenerek algılanabilmektedir. Bu sayede hiperspektral görüntülerin sınıflandırılması ve nesnelerin tanınması standart görüntü algılayıcılarına oranla çok daha yüksek bir başarımla sağlanabilmektedir. Hiperspektral görüntülerin eğitimsiz ve eğitilmiş sınıflandırılması ile ilgili gerçekleştirilen literatürdeki yöntemler Bölüm 3'de incelenmiştir.

Hiperspektral görüntülerin sınıflandırılmasında verinin yüksek boyutundan dolayı özellik çıkartımı ve özellik azaltımı yöntemleri sınıflandırılma öncesi veriye uygulanabilmektedir. Hiperspektral verilerin sınıflandırılmasında destek vektör makinalarının ve ilgililik vektör makinalarının kullanımı, bant sayısına bağlı

olmadığı için, sınıflandırma öncesi gereken özellik çıkartımı/özellik azaltımı işlem yükünü ortadan kaldırmaktadır. Hiperspektral verilerin akıllı sınıflandırma yöntemleri kullanılarak sınıflandırılması Bölüm 4’de anlatılmıştır. Hiperspektral görüntülerin ilgililik vektör makinaları kullanılarak sınıflandırılması bu tez kapsamında özgün olarak gerçekleştirilmiştir. Hiperspektral verinin, ilgililik vektör makinaları ve destek vektör makinaları ile sınıflandırma sonuçları Bölüm 4’de incelenmiştir.

Hiperspektral görüntülerin ilgililik vektör makinaları (İ.V.M) ve destek vektör makinaları (D.V.M) ile sınıflandırılmasından önce, sınıflandırma (test) süresini ve hesapsal yükü azaltmak amacı ile kullanılan farklı iki eğitimsiz bölütleme yöntemi ve Rastgele Örnek Onaylaşım (Random Sample Consensus) yaklaşımı Bölüm 5’de anlatılmıştır. Hiperspektral görüntülerde eğitim verisinin azaltılarak sınıflandırma başarımı/seyreklik değiş tokuşu, sınıflandırma öncesi  $K$ -ortalama veya faz korelasyonu temelli bölütleme yöntemleri veya Rastgele Örnek Onaylaşım (RAS.ÖR.ON) bağımsız geçerlilik sınaması (cross-validate) yaklaşımı kullanılarak sağlanmıştır. Sınıflandırma öncesi ön-işlem kullanılarak elde edilen verilerin sınıflandırma başarımları Bölüm 5’de değerlendirilmiştir.

Sonuçlar ve ileriki çalışmalarda yapılması planlananlar Bölüm 6’da anlatılmıştır.

## 2. UZAKTAN ALGILAMA

### 2.1 Giriş


Uzaktan algılama elektromanyetik spektrumun mor ötesi ve mikrodalga bantlarında havadan ve uzaydan cisimlerin özelliklerini kaydetme ve inceleme tekniği olarak tanımlanmaktadır. Uzaktan algılama, nesnelerin belirli bir uzaklıktan mekanik veya elektronik cihaz kullanılarak gözlenmesi sonucu yeryüzünün ve yer kaynaklarının fiziksel bağlantı kurmadan incelenmesini sağlamaktadır. Yeryüzünün fiziksel yapısı hakkındaki pek çok bilgi uzaktan algılama teknikleri ile elde edilmektedir. Hızlı nüfus artışı, kısıtlı doğal kaynaklar ve çevre kirliliği, yeryüzü hakkında hızlı ve doğru bilgiye olan ihtiyacın artmasına neden olmaktadır. Temel veri kaynakları hava fotoğrafları, hava tarayıcıları ve uydu görüntüleridir. Bu tür veriler için kullanıcı ihtiyaçları gittikçe artmaktadır. Bu nedenlerden dolayı, uzaktan algılama özellikle gelişmekte olan ülkeler için değerli bir veri kaynağı oluşturmaktadır [3-5].

Ülkelerin ekonomik gelişmesinin temeli, doğal kaynaklarının verimli olarak kullanılmasına bağlıdır. Gelişmiş ülkeler kaynaklarını bu şekilde kullanırken, gelişmekte olan ülkeler genellikle doğal kaynaklarının nitelik ve niceliklerine ilişkin yeterli bilgilerden henüz yoksundurlar. Bu nedenle, özellikle az gelişmiş ülkelerde doğal kaynakların yeterli biçimde haritalanmamış olması sonucu, toprak ve su kaynakları, işlenen toprakların dağılımı, orman ve otlaklar ile madenlerin yerleri ve miktarları hakkında tam ve kesin veriler bulunmamaktadır.

Doğal çevrenin önemli bir bölümünün dinamik nitelikte olması, bunların bir kez belirlenmesi ile yetinilmeyip takip edilmelerini gerektirmektedir. Bunun için de, modern havacılık ve uzay teknolojilerinden yararlanılmaktadır. Uzaktan algılama yöntemleriyle havadan ve uzaydan elde edilen görüntüler yorumlanabilmektedir. Hava fotoğrafları, fotogrametrik yöntemle harita yapımında kullanılmakla birlikte, çeşitli mühendislik çalışmaları ve özellikle foto-yorumlama yöntemi ile doğal

kaynakların bulunmasında da kullanılmakta ve böylece, uzaktan algılama yönteminin en önemli verilerinden birini oluşturmaktadır. Uzaktan algılamanın en önemli kaynağını uzay fotoğrafları ve uydular oluşturmaktadır. Uzaktan algılama yöntemi; otoyol, devlet yolu, demiryolu ve boru hattı koridor seçimleri, sulama, baraj, madencilik ve ormancılık ön etüdlerinde, stereo uydu görüntülerinden etüd haritaları ve 3 boyutlu sayısal arazi modellerinin hazırlanmasında, deniz ve kıyı kirliliği etüdlerinde, uydu görüntülerinin işlenip uygun filitremeler yapılarak kirlilik haritalarının yapımında, tarımsal amaçlı, arazi kullanım ve toprak haritalarının etüdünde, orman kaynaklarının ön dökümlerinin yapımı ve haritalanmasında, orman yangınlarının yaptığı hasarların tespitinde ve görüntülerin işlenmesi-haritalandırılmasında, maden aramalarında, jeolojik etüdlerin yapımında, yer çalışmalarını süre ve maliyet açısından en aza indirmek amacıyla ve bunlara benzer daha birçok çalışmada başarıyla uygulanmaktadır.

Pankromatik, multispektral, hiperspektral, algılayıcılar ile elde edilen görüntülere ait yaklaşık bant sayıları Şekil 2.1’de gösterilmektedir ve elde edilen görüntüler ile ilgili detaylı bilgi Bölüm 2.1, 2.2 ve 2.3’de sırasıyla anlatılmaktadır.



Şekil 2.1: (a): Pankromatik görüntülerde (b): multispektral görüntülerde (c): hiperspektral görüntülerde dalga boyuna göre elde edilen ortalama bant miktarları

## 2.2 Pankromatik Görüntüleme

Pankromatik görüntüler [6] elektromanyetik spektrumun geniş bir bölümünden yansıyan enerjiyi ölçebilen algılayıcılar tarafından elde edilmektedir. Birçok pankromatik algılayıcılar için elde edilen tek bant genellikle spektrumun görünen (visible) ile yakın kızılötesi bölümünü kapsamaktadır.

## 2.3 Multispektral Görüntüleme


Multispektral görüntüler [7-9], elektromanyetik spektrumdaki birden fazla bantta ölçüm alan sensörlerle elde edilmektedir. Örneğin; alıcıların bir bölümü görünür kırmızı bölgesinde yansıyan enerjiyi ölçerken, diğer bir grup yakın kızılötesi enerjiyi ölçmektedir. Aynı iki algılayıcı dizilimi, aynı dalga boyunun değişik bölümlerindeki enerjiyi ölçebilmektedir. Bu şekilde elde edilen çoklu yansıma değerleri; renkli görüntü oluşturmak için birleştirilmektedir.

## 2.4 Hiperspektral Görüntüleme


Günümüzde yaygın olarak kullanılan standart görüntü algılayıcıları (örneğin optik kamera veya kızılötesi kameralar) oldukça geniş bir dalga boyunda yansıyan ışığı tek bir imge üzerine düşürmektedir. Uydu ya da uçak üzerine yerleştirilmiş algılayıcılardan elde edilen hiperspektral görüntüler [10,11] ile birçok dar dalga boyu bandına ait imge verileri elde edilmekte ve bunun sonucunda dalga boyuna göre bir ayrışım sağlanmaktadır. Şekil 2.2’de birçok banttan oluşan örnek bir hiperspektral küp gösterilmektedir.

Hiperspektral görüntülerde her imge noktası, yani görüntü elemanı (piksel) için dalga boyuna bağlı bir spektrum bilgisi elde edilmektedir ve Şekil 2.3’de hiperspektral görüntülerdeki her piksel için dalga boyuna bağlı olarak elde edilen spektrum gösterilmektedir. Hiperspektral algılayıcılar ile dar bantlı ve sürekli aralıklandırılmış yüzlerce spektral bantta veri toplanabilmektedir. Farklı nesnelere farklı dalga boylarında, farklı yansıma özellikleri gösterir. Bu özellik sayesinde cisimler birbirlerinden ayırt edilebilmektedir. Hiperspektral sınıflandırma ve tanıma

yöntemlerinin, askeri ve savunma [12], medikal [13-15], tarım [16,17], hayvancılık [18], tekstil [19], çevre [20,21], madencilik [22,23], kimlik tespiti [24] alanlarında uygulamaları bulunmaktadır.



Şekil 2.2: Hiperspektral küp



Şekil 2.3: Hiperspektral görüntülerdeki her piksel için dalga boyuna bağlı spektrumun elde edilmesi



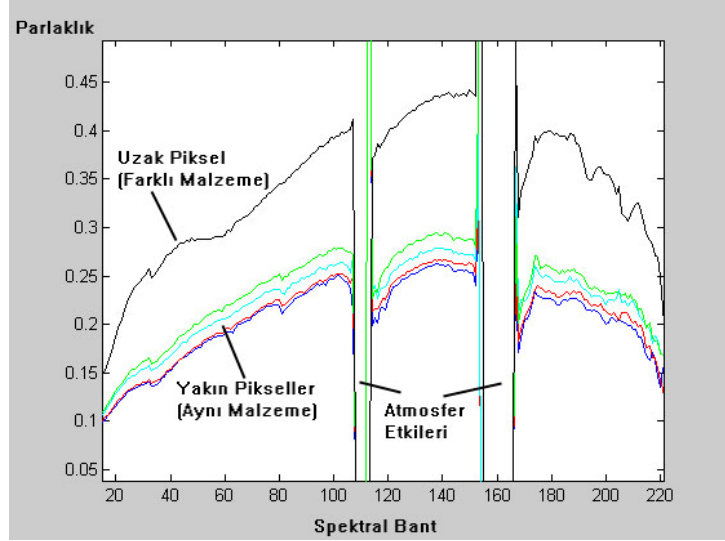
Hiperspektral görüntülerde piksel değerlerinin dalga boyuna göre değişimi elde edildiği için sınıflandırma ve tanıma yöntemlerinde oldukça başarılı sonuçlar elde edilmektedir. Sınıflandırma ve tanıma işlemleri standart görüntü algılayıcılarına oranla çok daha yüksek bir başarımla sağlanabilmektedir. Bu tez kapsamında hiperspektral görüntüler kullanarak akıllı sınıflandırma ve tanıma yöntemleri geliştirilmiştir.

Hiperspektral görüntüleme, görüntü elemanı başına çok yüksek bir bilgi miktarı yakalanabildiği için, özellikle algılama uygulamaları ve örselemeyen (non-destructive) incelemeler için çok kullanışlıdır [10]. Hiperspektral algılama, tüm malzemelerin moleküler birleşimlerine bağlı olarak belirli dalga boylarında farklı görüntülerde elektromanyetik enerji yansıtma, soğurma ve yayma özelliklerine sahip olması gerçeğini kullanmaktadır. Hiperspektral görüntüleme sistemleri, tipik olarak görünür bölge, yakın kızılötesi ve orta kızılötesi bölgelerinde çok dar bantlı spektral bantları görüntülemekte olup bu sayede görüş alanındaki her bir görüntü elemanı için neredeyse sürekli bir yansıma spektrumu bilgisi elde edilmektedir [11].

Tezde geliştirilen yöntemlerin uygulanması için NASA'nın ücretsiz sağladığı A.V.I.R.I.S (Airborne Visible/Infrared Imaging Spectrometer) hiperspektral verisinden faydalanılmıştır (bu veriler 400nm-2500nm dalga boyu arasını kapsamaktadır). Şekil 2.4'de A.V.I.R.I.S veri tabanından alınan örnek hiperspektral görüntülerde aynı ve farklı malzemelerin spektral verileri gösterilmektedir. Aynı malzemeye ait spektral verideki değişkenlik bu şekilde açıkça görülmekte, farklı malzemenin ise farklı bir spektral özellik sergilediği açıkça gözlenmektedir. A.V.I.R.I.S algılayıcılarının dışında Hyperion, CASI, SFSI, Orbimage sensörlerinden elde edilen hiperspektral görüntüler de literatürdeki çalışmalarda kullanılmıştır.


Hiperspektral görüntüler multispektral görüntülere göre Şekil 2.5'de gösterildiği gibi daha çok bant sayısı içermektedir ve dolayısıyla daha iyi sınıflandırma başarımı sağlamaktadır [25]. Multispektral görüntüler farklı türlerin (örneğin orman, su...) sınıflandırılmasında başarılı olmasına rağmen, sınıflandırma kapasitesi, aynı türlerin

farklı durumlarının (örneğin ormandaki farklı ağaç çeşitlerinin) tanınmasında oldukça sınırlıdır.




Şekil 2.4: Aynı ve farklı malzemelerin spektral imzaları

Hiperspektral görüntülerde birçok dar dalga boyu bandına ait verileri olduğu için sınıflandırmadaki hassasiyet artmaktadır. Şekil 2.6'da Hyperion, Hymap, A.V.I.R.I.S algılayıcıları kullanılarak elde edilen örnek hiperspektral görüntüler gösterilmektedir.



Şekil 2.5: Multispektral ve hiperspektral görüntülerin karşılaştırılması



Şekil 2.6: Farklı algılayıcılar ile elde edilen hiperspektral görüntüler

### 3. HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA

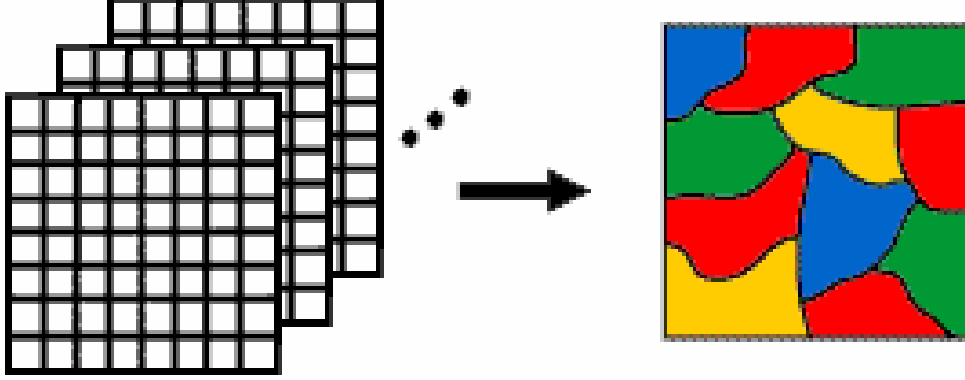
Sınıflandırma yöntemlerinin amacı veri kümesini sahip olduğu özelliklere göre sınıf ya da kategorilere ayırmaktır. Hiperspektral verinin yüksek boyutu nedeniyle tanımlama için sınıflandırma algoritmaları gerekmektedir. Hiperspektral görüntülerde sınıflandırma yöntemleri spektral sınıfları çeşitli istatistiksel yöntemler ile belli kategorilere ayırmaktadır. Hiperspektral görüntüleme sistemleri her piksel için sürekli yansıtılık spektrumu sağlamaktadır ve hiperspektral görüntülerin sınıflandırılmasında her piksel için elde edilen yansıma spektrumu kullanılarak tanımlamalar gerçekleştirilmektedir.

Sınıflandırma yöntemleri eğitilmiş (supervised) ve eğitimsiz (unsupervised) sınıflandırma olarak farklı iki kategoride incelenebilmektedir. Görüntü sınıflandırma kurallarının ana hedefi; alanı kapsayan sınıflar ve konulara göre bütün pikselleri ayrıştırmaktır. Sınıflandırma işleminde amaca yönelik sınıflandırma algoritmalarının seçimi ve sonuç görüntülerinde doğruluk analizlerinin yapılması gerekmektedir.


Şekil 3.1’de 3 banttan oluşan bir görüntü için sınıflandırma sonucunu gösterilmektedir ve her renk farklı sınıfları temsil etmektedir. Sınıflandırmaların sonucunda piksellerin yer alması gerekenden farklı bir sınıfa atanması sınıflandırma başarımını olumsuz yönde etkilemektedir. Sınıflandırma işleminde oluşacak hatayı (yanlış sınıflandırma) en aza indirecek olan sınıflandırma yönteminin seçilmesi gerekmektedir. Şubat 2004’de Stennis uzay merkezinde alınan görüntü ve sınıf bilgisi Şekil 3.2’de gösterilmektedir.

Hiperspektral verinin yüksek boyutu nedeniyle, yaygın olarak kullanılan sınıflandırma yöntemlerinde sınıflandırma işlemleri öncesinde veri boyutunun azaltılması yoluna gidilmekte, bunun için de özellik çıkartımı ve özellik seçimi yöntemlerinden faydalanılmaktadır. Bu özellik çıkartımı için, gürültüye karşı duyarlı

olması ve tüm veri kümesine uygulanmasının gerekmesi gibi dezavantajları olan temel bileşen analizi (T.B.A) kullanılabilir [26].



Şekil 3.1: Üç bantlı veri için sınıflandırma sonucu



Şekil 3.2: Şubat 2004'de Stennis uzay merkezinde alınan görüntü

[27,28]' de ayrımsal analiz özellik çıkartımı önerilmiştir. Özellik çıkartımı yönteminde, sadece belirli sayıda farklı sınıf oluşturulabilmekte ve ayrıca farklı sınıfların ortalama değerleri yakın olduğunda özellik vektörleri hatalı olabilmektedir. Karar sınırları tabanlı özellik çıkartımı [29] ise, hem yüksek hesap yükü gerektirmekte hem de ikiden fazla sınıf için en iyi sonuçtan uzaklaşmaktadır.

Zaman/frekans yerseme (localization) özellikleri nedeniyle dalgacık dönüşümleri birçok işaret işleme alanında olduğu gibi hiperspektral görüntülerde de özellik ayrıştırımı için yakın zamanda kullanılmaya başlanmıştır [30-32]. Dalgacık dönüşümünün uyumlamalı takip ile birleştirilmesi de [33]'de önerilmiştir. [34]'de hiperspektral bantların ağırlıkları bağımsız bileşen analizi ile tespit edilmekte ve bu sayede verinin boyutu azaltılmaktadır. Boyut azaltımı için parametrelizasyon izdüşüm takibi ise [35]'de önerilmiştir. Özellik seçimi ise var olan örneklerden, tüm boyutta sınıflandırma yapılması durumunda elde edilen başarıyı çok etkilemeyecek örnekleri çıkararak sınıflandırma yapmaktadır. Özellik seçimi yöntemi olan alt-küme seçimi (subset selection) yöntemi [36], özellik kümelerinden en iyi alt-küme bulmaya çalışır. En iyi alt-küme, başarıyı iyi yönde etkileyen düşük boyut sayısı içeren kümedir.


### 3.1 Eğitimsiz (Denetimsiz) Sınıflandırma

Denetimsiz sınıflandırma, piksellerin, kullanıcı müdahalesi olmadan algoritmalar yardımı ile otomatik olarak kümelendirilmesi temeline dayanmaktadır. Eğitimsiz sınıflama yöntemlerinde, sınıflandırılacak bölgenin tüm pikselleri kullanılarak kümelemeler elde edilmektedir [37]. Eğitimsiz sınıflandırma; görüntüdeki veri tanımlanamadığında başvurulan yöntemdir.


Denetimsiz sınıflandırma yöntemleri içerisinde en yaygın olarak kullanılan yöntem  $K$ -ortalama ( $K$ -means) yöntemidir [38]. Bu sınıflandırma yönteminde, her bir kümenin ortalaması hesaplanmaktadır. Piksel değerlerinin her bir küme ortalamasına uzaklığı bulunmakta ve piksel değerleri en yakın küme yerleştirilmektedir. Sınıflandırma için oluşturulan veri kümelerinin sayısına göre sınıf oluşturulmaktadır ve her sınıfın ortalaması alınarak işlemler tekrar edilmektedir. ISODATA (Iterative Self Organizing Data Analyses Technique) yöntemi [39], tekrarlı olarak sınıflandırmayı gerçekleştirme ve uygulanan her iterasyon sonrasında yeniden istatistik hesaplamasını temel almaktadır. Öz düzenleme (self organizing) ise, minimum girdi ile kümelerin oluşturulmasını sağlamaktadır. Bu yöntem karar kuralı olarak, minimum uzaklığı kullanmaktadır. Pikseller, görüntünün sol üst köşesinden başlanarak soldan sağa ve satır satır analiz edilmektedir. Aday piksel ile her bir küme

ortalaması arasında spektral uzaklık hesaplanmakta ve aday piksel en yakın kümeye atanmaktadır. Öncelikle, istenilen sınıf sayısı kadar oluşturulan kümelerin ortalaması hesaplanmakta ve her iterasyondan sonra, her bir kümenin yeni ortalaması hesaplanılarak, bu ortalamalar bir sonraki iterasyon kümelerinin tanımlanmasında kullanılmaktadır.

Hiperspektral görüntülerin denetimsiz sınıflandırılmasında kullanılan  $K$ -ortalama algoritması [40]'da önerilmiştir. Faz korelasyonu kullanılarak hiperspektral görüntülerin denetimsiz sınıflandırılması [41]'de gerçekleştirilmiştir ve Şekil 3.3 (a)'da mineral (cuprite) bölgesinden bir görüntü (b)'de faz korelasyonu bölütleme sonucu gösterilmektedir (her renk farklı bir sınıfı göstermektedir). Çoklu eşikli, iso-bölütleme ve histogram temelli bölütleme yöntemlerinin spektral görüntüye uygulanışı [42]'de çalışılmıştır. [43]'de öz bölge temelli bölütleme yöntemi önerilmiştir. [44]'de hiperspektral veriler ana-bileşenlerin histogramı temelli bölütleme yöntemi ile sınıflandırılmıştır. Saklı markov zincirlerinin (hidden markov chains) hiperspektral verilerin bölütlemesinde kullanılması [45]'de çalışılmıştır. [46]'da hiperspektral görüntüler için gauss karışım modellerinin kullanılması temeline dayanan istatistiksel bölütleme yöntemi önerilmiştir.



(a)



(b)

Şekil 3.3: (a) Mineral (cuprite) bölgesinden bir görüntü (b) faz korelasyonu bölütleme sonucu (her renk farklı bir sınıfı göstermektedir) [41].

### 3.2 Eğitimi (Denetimli) Sınıflandırma


Eğitim ve test işlemlerinden oluşan denetimli sınıflandırma yöntemlerinde görüntünün hangi sınıflara ayrılacağı, ya da görüntüden hangi sınıfların elde edilmek istendiği önceden bilinmektedir [37]. Denetimli sınıflandırma için eğitim ve sınıflandırma verileri bulunmaktadır. Eğitim aşamasında eğitim verileri kullanılarak geliştirilen model sayesinde daha önceden görülmemiş giriş verilerinin hangi sınıfta olduğu bulunmaktadır. Test aşamasında yeni giriş verileri, eğitim işlemi sonucunda elde edilen model parametreleri kullanılarak sınıflandırılmaktadır. Test (sınıflandırma) aşamasında eğitim verileri artık kullanılmamakta sadece elde edilen parametreler kullanılmaktadır. İkili sınıflandırma problemi için eğitim seti  $((x_1, r_1), \dots, (x_i, r_i) \in R^n \times \{\pm 1\})$  kullanılarak oluşturulan  $f: R^n \rightarrow \{\pm 1\}$  sayesinde yeni giriş değerlerinin hangi sınıfta olduğu tahmin edilmektedir. Burada  $x_i$  eğitim setindeki  $i$ . veriyi ve  $r_i$  bu verinin ait olduğu sınıfın bilgisini göstermektedir. İkili sınıflandırma problemi için  $r_i$ , +1 ya da -1 olarak düşünülebilmektedir.

Sınıflandırılma algoritmalarında D.V.M ve İ.V.M kullanılarak sınıflandırılması hiperspektral verinin boyutuna bağlı değildir. D.V.M [47-51], sınıflandırma ve regresyon işlemleri için multispektral [52-54] ve hiperspektral [55-58] görüntülere uygulanmıştır. D.V.M sınıflandırma yönteminin A.V.I.R.I.S görüntüsüne uygulanması [55]'de önerilmiştir. Özellik çıkartım yöntemleri ile D.V.M'in birleştirilmesi [56]'da çalışılmıştır ve iki adet parametrik olmayan  $k$ -en yakın komşu algoritması ve radyal temel fonksiyon nöral ağ yöntemleriyle karşılaştırma yapılmıştır. Hiperspektral görüntülerde D.V.M sınıflandırma öncesi yumuşatma işlemi için anizotropik difüzyon doğrusal olmayan süzgeçleme işleminin vektörel ifadesinin kullanılması [57]'de önerilmiştir. Hiperspektral görüntülerin sınıflandırılması için farklı kernel tabanlı yaklaşımlar ve özellikleri [58]'de incelenmiştir. Yüksek boyutlu özellik uzayında verimli D.V.M sınıflandırma sonuçları kernel tabanlı yaklaşımlar [59] kullanılarak elde edilmiştir. Şekil.3.4 (a)'da orijinal hiperspektral görüntüsü ve hiperspektral görüntünün (b)'de polinom kerneli ve (c)'de radyal temel fonksiyon kerneli (R.T.F) kullanılarak D.V.M ile sınıflandırılması sonuçları gösterilmektedir.






(a)



(b)



(c)

Şekil 3.4: (a) orijinal hiperspektral görüntü, (b) hiperspektral görüntünün polinom kerneli ile D.V.M sınıflandırılması (c) hiperspektral görüntünün radyal temel fonksiyonu (R.T.F) kerneli ile D.V.M sınıflandırılması

İ.V.M, D.V.M'nin genelleştirilmiş doğrusal bir biçimi olup D.V.M'nin istatistiksel çıkış verememe, ödünleşim (trade-off) parametre ihtiyacı ve 'Mercer' kernel fonksiyonlarının kullanılması zorunluluğu gibi dezavantajlarını ortadan kaldırmaktadır [60,61]. İ.V.M ile sınıflandırma yönteminde, D.V.M ile sınıflandırmaya göre daha az kernel fonksiyonu kullanımı mümkün olmaktadır. Bu neden ile test aşamasında daha hızlı sonuç elde edilmektedir. D.V.M hiperspektral görüntüye uygulanmış olup [55-58], İ.V.M'nin hiperspektral görüntülerde sınıflandırma amaçlı kullanılması ilk kez bu tez kapsamında gerçekleştirilmiştir. D.V.M ve İ.V.M ile ilgili detaylı bilgi sırasıyla Bölüm 4.1 ve Bölüm 4.2 'de verilmiştir

## 4. AKILLI HİPERSPEKTRAL SINIFLANDIRMA YÖNTEMLERİ

Hiperspektral görüntülerin sınıflandırılma uygulamalarında destek vektör makinaları temelli sınıflandırma yönteminin kernel fonksiyonları kullanılarak [56] 'da yüksek başarımlar sağladığı gösterilmiştir. Bu tez kapsamında daha etkili akıllı yöntemlerin sınıflandırma ve tanıma amacıyla ilgililik vektör makinalarının [60,61] kullanılması öngörülmektedir.

### 4.1 Destek Vektör Makinaları

Destek vektör makinaları (D.V.M), sınıflandırma ve uyumlama problemlerini çözmek için [47-51]'de önerilmiştir. Multispektral ve hiperspektral görüntülerin sınıflandırılması, el yazısı tanıma [62], yüz tanıma [63], ve kanser hücrelerinin tanınması [64] gibi farklı alanlarda uygulamaları bulunmaktadır ve yapısal risk en küçültme prensibi [65] ile formülize edilmiştir.

D.V.M, henüz karşılaşmadığı örnekleri doğru sınıflandırabilmek için eğitim kümesini  $x_i, r_i \quad i \in 1, 2, \dots, N \quad r_i \in \{-1, +1\}$  kullanarak bir model geliştirmektedir. Burada,  $r_i$ , giriş değeri  $x_i$  ile ilişkili sınıf bilgisini göstermektedir. D.V.M'ler, öğrenme boyunca, ayırma düzlemi (aşırı düzlem) ile bunun her iki tarafında bulunan veri örnekleri arasındaki mesafenin maksimum olması için düzlemin pozisyonunu optimize etmektedir. D.V.M iki sınıfa ait örnek noktalar arasındaki karar yüzeyini oluştururken yüzeyin iki sınıfa olan uzaklığını en yüksek dereceye çıkarmaya çalışmaktadır.

İki sınıflı sınıflandırmada iki sınıf için  $-1/+1$  sınıf etiketleri kullanılabilir. Bu durumda örneğin  $X = \{x_i, r_i\}$  için eğer  $x_i \in S_1$  ise  $r_i = +1$  ve  $x_i \in S_2$  ise  $r_i = -1$  olmaktadır. İki sınıflı sınıflandırma problemi, iki sınıftan oluşan bir veri kümesindeki verileri (4.1) ile ayırmaktadır. Aşırı düzlem üzerindeki bütün noktalar (4.1)'i sağlamaktadır. Burada  $w$  ağırlık vektörü, aşırı düzleme olan normaldir.

$$f(x) = \mathbf{w}x + b \quad (4.1)$$


#### 4.1.1 Doğrusal ayrılabilir D.V.M ile sınıflandırma

Doğrusal ayrılabilir sınıfları birbirinden ayıran pek çok karar düzlemini bulmak mümkündür. D.V.M bu karar düzlemlerinden her iki sınıfa uzak olanını yani iki sınıf arasındaki sınırı büyüleyen en uygun ayırt etme yüzeyini belirlemektedir. Bu düzleme en yakın vektörler de destek vektörleri olarak isimlendirilmektedir. Eğitim örneklerinden elde edilen destek vektörleri sınıflandırma için önemlidir. Karar (test) aşamasında ise destek vektörleri kullanılarak daha önceden görülmemiş giriş değerlerinin hangi sınıfta olduğu ile ilgili kestirim yapılmaktadır. En yakın noktaların (destek vektörleri) en uygun hiper düzleme uzaklığı  $1/\|\mathbf{w}\|$ 'dir. En uygun ayırım hiper düzlemi, uzaklığı büyüleyen dolayısıyla  $\|\mathbf{w}\|^2$  değerini küçükleyen düzlem olarak bulunmaktadır. Böyle bir düzlemin bulunması aşağıdaki en uygun şekle sokma problemi olarak ifade edilebilmektedir.

$$\begin{aligned} \text{küçükle: } & \frac{1}{2}\|\mathbf{w}\|^2 \\ \text{sınırlamalar: } & r_i(\mathbf{w}x_i + b) \geq 0, \quad i = 1, 2, \dots, N \end{aligned} \quad (4.2)$$

Şekil 4.1 (a)'da iki sınıflı veriyi ayıran bir düzlem, Şekil 4.1 (b)'de ise en iyi alt düzlem ve daire içerisine alınan destek vektörleri gösterilmektedir. (4.2) ile gösterilen küçükleme problemi, hesapsal karmaşıklığı eğitim veri sayısına ( $N$ ) bağlı olacak şekilde Lagrange denklemi ile ifade edilebilmektedir.

$$\begin{aligned} L_p &= \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N a_i[r_i(\mathbf{w}x_i + b) - 1] \\ &= \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N a_i r_i(\mathbf{w}x_i + b) + \sum_i a_i \end{aligned} \quad (4.3)$$



Şekil 4.1: (a) İki sınıflı veriyi ayıran bir alt düzlem, (b) en iyi alt düzlem

(4.3)  $w$ ,  $b$ 'ye bağlı olarak küçüklenmeli ve  $a_i \geq 0$  olacak şekilde büyükenmelidir. Bu işlem ana terimin ve doğrusal kısıtlamaların dışbükey olması nedeni ile dışbükey karesel programlama problemidir. (4.3) ile gösterilen Lagrange denkleminin  $w$ ,  $b$ 'ye göre türevi alınarak elde edilen (4.4)'deki tanımlamalar (4.3)'de yerine konularak (4.5) ile gösterilen ikili büyükleme problemi elde edilmektedir.

$$\frac{\partial L_p}{\partial w} = 0 \rightarrow w = \sum_i a_i r_i x_i \quad (4.4)$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow \sum_i a_i r_i = 0$$

$$\text{büyükle: } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (4.5)$$

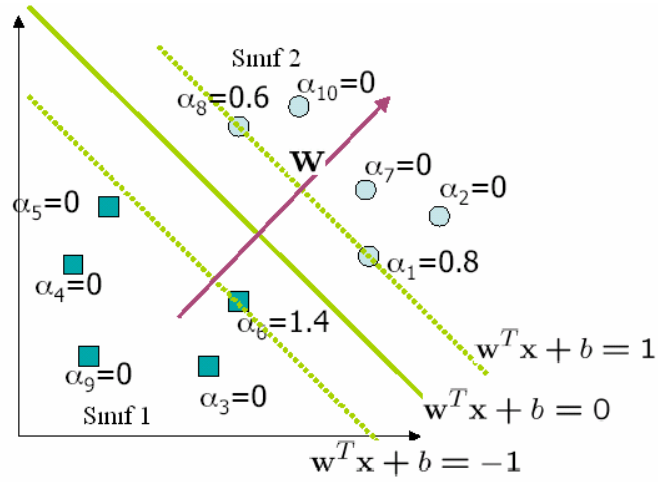
$$\text{kısıtlamalar: } \sum_{i=1}^N \alpha_i y_i = 0 \text{ and } \alpha_i \geq 0, \quad i = 1, 2, \dots, N$$

Lagrange ifadesi yazıldığında (4.5)'de görüldüğü gibi bir karesel programlama problemi elde edilmektedir. Bu problem herhangi bir karesel programlama çözücü algoritmayla çözülebilmektedir. Bu çözümde bazı  $\alpha$  değerleri sıfır olmaktadır ve sıfırdan farklı  $\alpha$  değerlerine sahip her  $x$  vektörü destek vektörüdür. Örnek veri için

her bir özellik vektörüne ait  $\alpha$  değerleri Şekil 4.2’de gösterilmektedir. Hiç görülmemiş giriş değerleri için sınıflandırma (4.6) kullanılarak hesaplanmaktadır.

$$f(x) = \sum_{i=1}^n \alpha_i y_i x_i^t x \quad (4.6)$$

Burada  $x$  giriş vektörü,  $n$  toplam destek vektör sayısı ve  $x_i$  destek vektörlerini göstermektedir.



Şekil 4.2: Her özellik vektörüne ait  $\alpha$  değerleri


#### 4.1.2 Doğrusal olarak ayrılamayan D.V.M ile sınıflandırma

Eğer veri doğrusal olarak ayrılamıyor ise düzenleme parametresi  $C$  ve arttıran yapay değişken  $\varepsilon_i$  (slack variable) tanımlanmaktadır.  $C$  parametresinin değerinin büyük olması hatalara daha yüksek ceza atanmasına neden olmaktadır. Çoğu zaman veri sınıflarının doğrusal olmaması nedeniyle doğrusal ayrılmaz veri genelde bulunmamaktadır. Doğrusal olarak ayrılamayan örnek veri Şekil 4.3’de gösterilmektedir. Verilerin doğrusal ayrılmama durumunda problem iki sınıflı veriyi, aynı sınıfa ait verinin mümkün olan en büyük oranını alt düzlemin aynı tarafında bırakacak şekilde ayıran alt düzlemi bulmaktır ve böyle bir düzlemin bulunması aşağıdaki en uygun şekle sokma problemi olarak ifade edilmektedir.

$$\text{küçük: } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \varepsilon_i \quad (4.7)$$

$$\text{kısıtlamalar: } r_i(\mathbf{w}\mathbf{x}_i + b) \geq 1 - \varepsilon_i, \quad i = 1, 2, \dots, N \quad \varepsilon_i \geq 0$$

(4.7)'de  $C$  parametresi kullanıcı girişlidir. En uygun şekilde sokma problemindeki ilk terim doğrusal ayrılabilir durumdaki ile aynı ifadedir. İkinci terim ise yanlış sınıflandırma noktasını kontrol etmektedir.



Şekil 4.3: Doğrusal olarak ayrılamayan veri

Diğer bir çözüm yolu olarak doğrusal olarak ayrılamayan sınıflardaki her bir vektör, doğrusal olmayan  $\phi()$  gibi bir dönüşümle daha yüksek boyutlu bir uzaya taşınarak elde edilen yeni  $\phi()$  vektörlerinden elde edilen sınıflar doğrusal ayrılabilir olmaktadır. Doğrusal olarak ayrılabilir veri için yazılmış olan formüllerdeki iç çarpımlarda  $\mathbf{x}_i \mathbf{x}_j$  yerine  $\phi(\mathbf{x}_i) \phi(\mathbf{x}_j)$  yazılarak bu formüller kullanılmaktadır. Buradaki güçlük, nitelik uzayındaki iç çarpımın gerçekleşmesidir, ancak bu güçlük kernel (çekirdek) yaklaşımıyla çözülmektedir. Kernel fonksiyonu genelde  $K()$  ile gösterilmektedir. Kernel fonksiyonu, nitelik uzayındaki iç çarpımı gerçekleştirdiğinden  $\phi()$  dönüşümünün analitik olarak bilinmesine gerek yoktur. Sadece  $K()$  'nın belirlenmesi yeterlidir.  $K(\mathbf{x}_i, \mathbf{x}_j)$  fonksiyonu benzerlik kavramını temsil etmektedir. Yüksek boyutlu uzayda, verilerin doğrusal olarak ayrılabilmesinin sezgisel açıklaması Cover teoremi [77] ile gösterilmektedir. Cover teoremi  $N$  özellik vektörünün yüksek boyutlu uzayda doğrusal olarak ayrılabilme olasılığını göstermektedir.

$$P(N, d) = \begin{cases} 1 & , \quad N \leq d + 1 \\ \frac{1}{2^{N-1}} \sum_{i=0}^d \binom{N-1}{i} & , \quad N \geq d + 1 \end{cases} \quad (4.8)$$

Burada  $d$  yüksek boyutu göstermektedir. Cover teoremi [77]  $d$  boyutunun artması ile verinin doğrusal olarak ayrılma olasılığının artacağını göstermektedir.

$$\text{büyükle: } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (4.9)$$

$$\text{sınırlamalar: } \sum_{i=1}^N \alpha_i y_i = 0 \text{ and } 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N$$

Mercer koşullarını sağlayan ve simetrik kesin pozitif olan kernel fonksiyonları kullanılarak doğrusal olmayan sistemin doğrusal olan bir uzaya dönüştürülmesi sağlanır. Literatürde değişik uygulamalar için çok çeşitli kernel fonksiyonları vardır ama yaygın olarak üç temel çekirdek kullanılmaktadır.

Doğrusal kernel fonksiyonu:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j \quad (4.10)$$

Çokterimli kernel fonksiyonu (Ç.T.K):

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i \cdot \mathbf{x}_j)^d \quad (4.11)$$

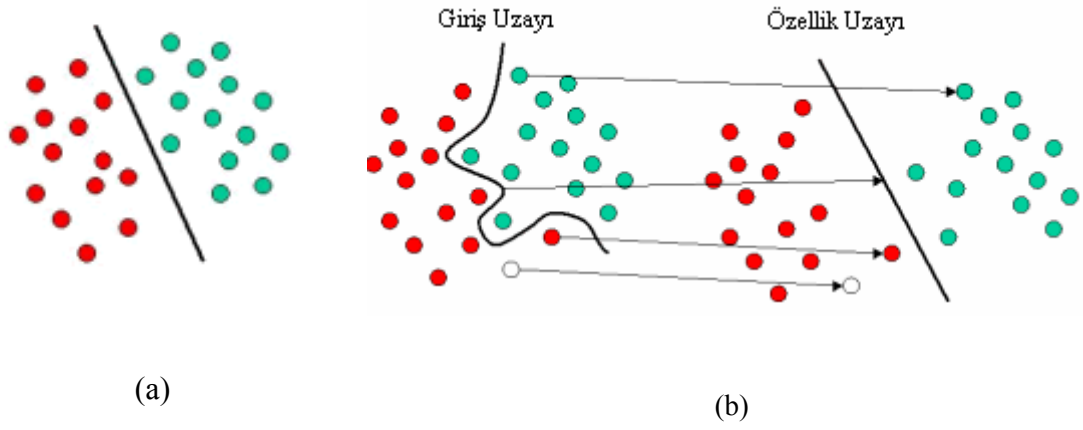
Radyal taban fonksiyonu (R.T.F) :

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (4.12)$$


Yukarıdaki denklemlerde ‘.’ içsel çarpımı göstermektedir. Kernel parametreleri ve uygun kernel tipi seçerek başarılı sınıflandırma sonuçları elde edilmektedir. Burada  $\gamma, d$  parametreleri kullanıcı girişli kernel parametrelerdir. Sonuç olarak, karar fonksiyonu (4.13) ile ifade edilmektedir.

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (4.13)$$

Şekil 4.4 (a)'da doğrusal ayrılabilir veri, Şekil 4.4 (b)'de ise doğrusal ayrılamayıp yüksek boyutlu uzayda ayrılabilir veri gösterilmektedir. D.V.M yönteminin bir dezavantajı olarak sadece Mercer koşullarını sağlayan çekirdek fonksiyonları kullanılabilir. Doğrusal ayrılamayıp yüksek boyutlu uzayda ayrılabilir başka bir veri Şekil 4.5'de gösterilmektedir.



Şekil 4.4: (a) doğrusal ayrılabilir veri (b) doğrusal ayrılamayıp yüksek boyutlu uzayda ayrılabilir veri



Şekil 4.5: Yüksek boyutlu uzayda doğrusal olarak ayrılabilir veri



## 4.2 İlgililik Vektör Makinaları Kullanılarak Sınıflandırma

Destek vektör makinaleri denetimli sınıflandırma için oldukça gelişmiş bir yöntem olmasına rağmen olasılıksal çıkış verememe, ödünleşim parametre hesabı gereksinimi (örneğin  $C$  değeri) ve Mercer kernel fonksiyonlarına bağımlılık gibi dezavantajları vardır. D.V.M için bahsedilen dezavantajlar, D.V.M'nin Bayes davranış gösteren biçimi olan İ.V.M sınıflandırma yöntemi kullanılarak çözülmektedir. Ayrıca İ.V.M daha az sayıda kernel fonksiyonu gerektirmektedir. Destek vektör makineleri ile karşılaştırıldığında sınıflandırma (test) süresi İ.V.M kullanılarak, daha az kernel fonksiyonu kullanılması nedeni ile azalmaktadır.

Denetimli sınıflandırmada eğitim seti olarak isimlendirilen giriş vektörleri ve ilgili çıkışlar (uyumlamada gerçek değerler, sınıflandırmada sınıf numaraları) kullanılarak daha önceden görülmemiş giriş verilerinin hangi sınıfta ait olduğu bilgisi öğrenilmektedir. Kestirim işlemi için gerekli olan denklemin parametreleri eğitim aşaması ile elde edilir ve (4.14) ile gösterilmektedir. Eğitim aşamasında amaç, daha önceden görmediği giriş vektörlerinin hangi sınıfta olduğunu doğru kestirecek eğitim verisindeki her  $x_i$  ile ilişkili  $w_i$  parametrelerini bulmaktır. Eğitim işlemi sırasında  $w_i$  parametrelerin çoğunluğu otomatik olarak sıfırlanır. Sıfırlanmayan  $w_i$  değerleri ile ilişkili giriş vektörleri ilgililik vektörleridir ve test aşamasında kullanılmaktadır [60].

$$y(x; w) = \sum_{i=1}^M w_i \psi_i(x) = \mathbf{w}^T \boldsymbol{\phi}(x), \quad (4.14)$$

İki sınıflı sınıflandırma için sınıf bilgisi  $t_n \in \{0,1\}$  olarak alınabilmektedir. Burada sadece iki değer (0 ve 1) olduğundan dolayı  $p(t|w)$  için Bernoulli dağılımı kullanılmaktadır. Lojistik sigmoid bağlantı fonksiyonu  $\sigma(y) = 1/(1 + e^{-y})$  doğrusal model üretmek amacı ile  $y(\mathbf{x})$ 'e uygulanmaktadır. Bernoulli dağılımı kullanılarak benzerlik ifadesi  $t_n \in \{0,1\}$  için (4.15)'de gösterildiği gibi ifade edilmektedir [60].

$$p(\mathbf{t}|\mathbf{w}) = \prod_{n=1}^N \sigma\{y(x_n; \mathbf{w})\}^{t_n} [1 - \sigma\{y(x_n; \mathbf{w})\}]^{1-t_n} \quad (4.15)$$

Ağırlık parametrelerinin önsel olasılığı (4.16) ile gösterilmektedir ve ağırlık vektörünün bileşenlerinin istatistiksel bağımsız olduğu varsayılmaktadır [60].

$$p(\mathbf{w}|\boldsymbol{\alpha}) = \prod_{i=1}^N \frac{\sqrt{\alpha_i}}{\sqrt{2\pi}} \exp\left(-\frac{\alpha_i w_i^2}{2}\right) \quad (4.16)$$

Burada  $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_N)^T$  hiperparametreleri ifade etmektedir. Bayes teoremi kullanılarak ağırlık parametrelerinin sonsal olasılıkları hesaplanmaktadır.

$$p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha}) = \frac{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})}{p(\mathbf{t}|\boldsymbol{\alpha})} \quad (4.17)$$

Burada  $p(\mathbf{t}|\mathbf{w})$  benzerliği,  $p(\mathbf{w}|\boldsymbol{\alpha})$  önsel olasılığı,  $p(\mathbf{t}|\boldsymbol{\alpha})$  ise kanıtı (evidence) göstermektedir.  $\mathbf{w}$  değerleri analitik olarak elde edilemez. Bu nedenle [66]'da kullanılan Laplace yaklaşım prosedürü  $\mathbf{w}$  değerlerini elde etmek için kullanılmaktadır. Geçerli  $\alpha$  değerleri ile ilişkili  $w$  ağırlık değerleri sonsal (posterior) dağılım kullanılarak bulunmaktadır.  $p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha})$  doğrusal olarak  $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})$  ile orantılıdır. Bu nedenle maksimum  $\mathbf{w}$ 'yi bulmak için (4.18) kullanılabilir.

$$\log\{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})\} = \sum_{n=1}^N [t_n \log y_n + (1-t_n) \log(1-y_n)] - \frac{1}{2} \mathbf{w}^T \mathbf{A} \mathbf{w} \quad (4.18)$$

Burada  $y_n = \sigma\{y(x_n; \mathbf{w})\}$ ,  $\mathbf{A} = \text{diag}(a_1, a_2, \dots, a_N)$  'dir ve  $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})$  ifadesindeki bileşenler olasılıksal yoğunluk fonksiyonu olup negatif olmadıklarından  $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})$  'nın maksimum olması  $\log\{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})\}$  'nın maksimum olmasına eşittir. Sonsal olasılık ifadesi geçerli  $\boldsymbol{\alpha}$  değerlerini kullanarak en olası  $\mathbf{w}$  değerlerini bulmak için aşamalı çözüm kullanılmaktadır [60]. (4.18) düzenlenmiş logistik logaritmik benzerlik fonksiyonudur ve aşamalı en büyükmeyi gerektirmektedir. En

olası  $\mathbf{w}$  değerlerini bulmak için aşamalı yeniden ağırlıklandırılmış en yakın kareler yöntemi ('iteratively-reweighed least-squares') [67] kullanılmaktadır. (4.18) ile gösterilen ifadenin iki kere  $\mathbf{w}$ 'ye göre iki kez türevi alınarak Hessian matrisi elde edilmektedir ve elde edilen ifade (4.19) ile gösterilmektedir.

$$\nabla_{\mathbf{w}} \nabla_{\mathbf{w}} \log p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}) \Big|_{\mathbf{w}_{MP}} = -(\boldsymbol{\Phi}^T \mathbf{B} \boldsymbol{\Phi} + \mathbf{A}) \quad (4.19)$$

Burada  $\mathbf{B}$  ( $\mathbf{B} = \text{diag}(\beta_1, \beta_2, \dots, \beta_N)$ ) köşegen matrisidir ve  $\beta_n = \sigma \{y(\mathbf{x}_n)\} [1 - \sigma \{y(\mathbf{x}_n)\}]$  ile ifade edilmektedir. Hessian denkleminin negatifi alınarak ve terslenerek kovaryans matrisi  $\boldsymbol{\Sigma}$  elde edilmektedir.

$$\begin{aligned} \boldsymbol{\Sigma} &= (\boldsymbol{\Phi}^T \mathbf{B} \boldsymbol{\Phi} + \mathbf{A})^{-1} \\ \mathbf{w}_{MP} &= \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \hat{\mathbf{t}} \\ \hat{\mathbf{t}} &= \boldsymbol{\Phi} \mathbf{w}_{MP} + \mathbf{B}^{-1} (\mathbf{t} - \mathbf{y}) \end{aligned} \quad (4.20)$$

Yukarıdaki denklemler genelleştirilmiş yakın kareler probleminin çözülmesi sonucu oluşmaktadır.  $\mathbf{w}_{MP}$  değerlerini elde ettikten sonra  $\alpha_i$  değerleri  $\alpha_i^{yeni} = \frac{\gamma_i}{w_i^2}$ , denklemini kullanarak güncellenmektedir. Burada  $w_i$ ,  $i$ . ortalama sonsal ağırlık ve  $\gamma_i = 1 - \alpha_i N_{ii}$ , 'dir.  $N_{ii}$  kovaryans matrisinin  $i$ . köşegen elemanıdır. Optimizasyon işlemleri sırasında birçok  $\alpha_i$  yüksek değerler almakta ve bu nedenle ilişkili ağırlık parametreleri atılmaktadır ve seyreklik sağlanmaktadır.

### 4.3 İlgililik Vektör Makinaları ile Destek Vektör Makinalarının Karşılaştırılması

D.V.M sınıflandırma da eğitim setinin büyümesi durumunda kullanılan destek vektörlerinin sayısı artmakta ve bu durum hesapsal yükü azaltmak için ek işlem gerektirmektedir. Ayrıca D.V.M sınıflandırmada kestirimler olasılıksal değildir. İlgililik vektör makineleri ile sınıflandırmada ise kestirim işleminde  $p(t|\mathbf{x})$  hesaplanır [60, 61]. D.V.M için gerekli olan kullanıcı girişli  $C$  parametresinin

seçimi, hesapsal yük getiren bağımsız geçerlilik sınaması (cross-validation) gerektirmektedir ve D.V.M ile sınıflandırmada kullanılan kernel fonksiyonu  $K(\mathbf{x}, \mathbf{x}_i)$  destek vektör makinelerinde pozitif integral operatörün sürekli simetrik kerneli şeklinde (Mercer kernel) olması gerekmektedir. İ.V.M de ise her kernel fonksiyonu kullanılabilir. İ.V.M yaklaşımı sınıflandırmadaki benzer doğruluk oranlarını daha az kernel fonksiyonu ile sağlamaktadır [60, 61]. D.V.M sonucu elde edilen destek vektörü sayısı, İ.V.M sonucu elde edilem ilgililik vektör sayısından çok daha fazladır. Doğruluk oranı veriden veriye değişmekle birlikte bazı verilerde İ.V.M daha iyi sonuç vermektedir. Yalnız tez kapsamında çalışılan hiperspektral görüntüde sınıflandırma sonucu İ.V.M sınıflandırmada daha az ilgililik vektörüne karşılık doğrulukta düşük miktarda azalma olmaktadır.

#### 4.4 Çoklu Sınıf Sınıflandırması

D.V.M ikili sınıflandırma için tasarlanmıştır ve çoklu sınıflandırmaya etkin olarak nasıl uyarlanacağı devam eden araştırma konusudur. Çoklu D.V.M sınıflandırmayı gerçekleştirmek amacıyla ikili sınıflandırmayı birleştiren birçok yöntemler ve bütün verilerin aynı anda kullanılarak tek aşamada çoklu sınıflandırma probleminin çözümüne yönelik yöntemler literatürde bulunmaktadır. Çoklu sınıflandırma problemini özellikle tek aşamada çözmek büyük optimizasyon problemi gerektirmektedir. Bu yaklaşım için çoklu D.V.M sınıflandırma probleminin çözüm formülü sınıf sayısı ile orantılı değişkenler içermektedir. D.V.M çoklu sınıflandırma, ya ikili D.V.M'ler belirli kurallar çerçevesinde birleştirilerek ya da büyük optimizasyon problemi çözülerek gerçekleştirilebilmektedir. Aynı veri miktarı için optimizasyon probleminin çözümü ikili sınıflandırmaların çözümüne göre daha fazla hesapsal yük gerektirmektedir. En yaygın kullanılan ikili sınıflandırma yöntemleri bire-bir D.V.M [51], bire-hepsi D.V.M[50], doğrudan çevrimsiz grafik (directed acyclic graph) D.V.M [49] yöntemleridir.

Bire-hepsi çoklu sınıflandırma yöntemi [51] D.V.M için kullanılan en eski ve en yaygın yöntemdir. Bire-hepsi çoklu D.V.M sınıflandırma yöntemi paralel yapıya sahiptir ve  $k$  sınıf sayısı olmak üzere  $k$  tane D.V.M modeli geliştirmektedir.  $i$ . D.V.M modelinde  $i$ . sınıfın bütün elemanları pozitif etiketli sınıfın, kalan diğer

sınıfların bütün elemanları negatif etiketli sınıfın elemanları olmak üzere eğitim işlemi gerçekleştirilmektedir. Sınıflandırma aşamasında ise yeni giriş değeri bütün modeller kullanılarak test işlemine sokulmakta ve karar için en çok oyu alan kazanır yaklaşımı kullanılmaktadır. Yeni giriş verilerinin hangi sınıfa ait olduğu en çok oyu alıp kazanan sınıfa göre belirlenmektedir. Şekil 4.6'da bire hepsi sınıflandırma yöntemi ile çoklu D.V.M problemini çözmek için kullanılan yaklaşım gösterilmektedir.

Bire-hepsi yaklaşımında Şekil 4.8'de gösterilen paralel yaklaşım blok diyagramı için  $M$  sınıf sayısı,  $k$  değerine eşittir.  $l$  eğitim verisi  $(x_1, y_1), \dots, (x_l, y_l)$ ,  $x_i \in R^n, i = 1, \dots, l$  ve  $y_i \in \{1, \dots, k\}$   $x_i$ 'nin hangi sınıfa ait olduğunu göstermektedir.  $i$ . D.V.M (4.21) ile gösterilen problemi çözmektedir.

$$\begin{aligned} \min_{w^j, b^j, \varepsilon^j} & \frac{1}{2} ((w^j)^T w^j) + C \sum_{j=1}^l \varepsilon_j^i (w^j)^T \\ (w^j)^T \phi(x_j) + b^j & \geq 1 - \varepsilon_j^i, \quad \text{eğer } y_i = i \\ (w^j)^T \phi(x_j) + b^j & \leq -1 + \varepsilon_j^i, \quad \text{eğer } y_i \neq i \\ \varepsilon_j^i & \geq 0, \quad j = 1, \dots, l \end{aligned} \quad (4.21)$$

Burada  $\phi$  fonksiyonu ile eğitim verisi  $x_i$  yüksek boyutlu uzaya yansıtılmaktadır ve

$C$  ceza parametresidir.  $\frac{1}{2} ((w^j)^T w^j)$  ifadesini küçükmek, iki sınıf arasındaki uzaklığı

$(2 / \|w^j\|)$  büyükmek anlamına gelmektedir. Veri doğrusal olarak ayrılmadığında

ceza ifadesine eğitim hatasını azaltan ceza parametresi  $(C \sum_{j=1}^l \varepsilon_j^i (w^j)^T)$  eklenmektedir.

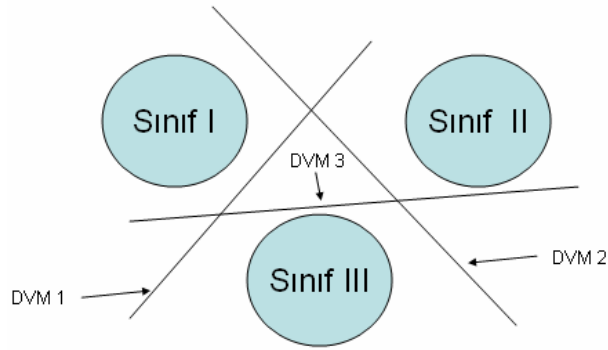
D.V.M'in temeli düzenleme parametresi  $\frac{1}{2} ((w^j)^T w^j)$  ve eğitim hatası arasında bir denge aramasıdır.

(4.21) çözüldükten sonra,  $k$  adet karar fonksiyonu oluşmaktadır.

$$\begin{aligned}
& (w^1)^T \phi(x) + b^1 \\
& \bullet \\
& \bullet \\
& (w^k)^T \phi(x) + b^k
\end{aligned} \tag{4.22}$$

(4.22) hesaplandıktan sonra,  $x$ 'in hangi sınıfa ait olduğu denklem 4.21 kullanılarak hesaplanmaktadır. (4.23)'den görüldüğü gibi  $x$  en yüksek değerli karar fonksiyonuna sahip sınıftadır.

$$x\text{'in sınıf bilgisi} = \arg \max_{i=1,\dots,k} ((w^i)^T \phi(x) + b^i) \tag{4.23}$$

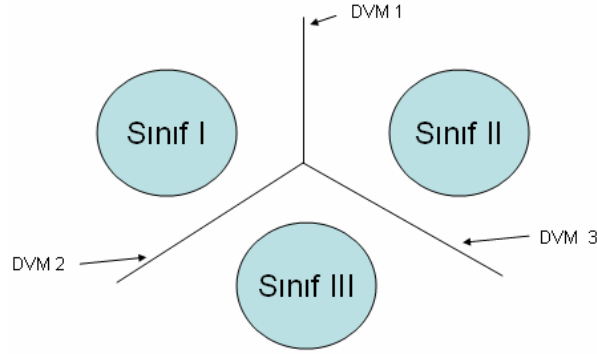


Şekil 4.6: Bire-hepsi çoklu D.V.M sınıflandırma

Bire-bir yöntemi [51] bütün ikili sınıflandırmalar için bir model geliştirerek,  $k$  sınıf sayısı olmak üzere  $k(k-1)/2$  tane D.V.M modeli geliştirmektedir. Şekil 4.7'de bire-bir çoklu sınıflandırma yönteminin yapısı gösterilmektedir. Şekil 4.8'de gösterilen paralel yaklaşım blok diyagramı için  $M$ ,  $k(k-1)/2$  değerine eşittir. İkili sınıflandırma problemi  $i$ . ve  $j$ . sınıflarının eğitim dizisi için (4.24) ile gösterilen denklem ile çözülmektedir.

$$\begin{aligned}
& \min_{w^{ij}, b^{ij}, \varepsilon^{ij}} \frac{1}{2} ((w^{ij})^T w^{ij}) + C \sum_t \varepsilon_t^{ij} (w^{ij})^T \\
& (w^{ij})^T \phi(x_t) + b^{ij} \geq 1 - \varepsilon_t^{ij}, \text{ eğer } y_t = i \\
& (w^{ij})^T \phi(x_t) + b^{ij} \leq -1 + \varepsilon_t^{ij}, \text{ eğer } y_t \neq i \\
& \varepsilon_t^{ij} \geq 0
\end{aligned} \tag{4.24}$$

$x$ 'in hangi sınıfa ait olduğunu bulmak için  $\text{sgn}((w^{ij})^T \phi(x_i) + b^{ij})$  değerine bakılır. Eğer  $(w^{ij})^T \phi(x_i) + b^{ij}$  denkleminin işareti  $x$ 'in  $i$ . sınıfta olduğunu gösterirse,  $i$ . sınıfın oyu bir artar, değilse  $j$ . sınıfın oyu bir artmaktadır.  $x$ 'in hangi sınıfta olduğunun tahmini ise en yüksek oy alan sınıfa göre gerçekleştirilmektedir. Eğer iki sınıf aynı oya sahip ise küçük indisli sınıf tercih edilmektedir.

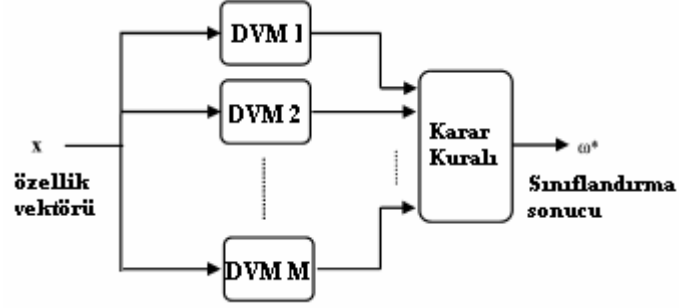


Şekil 4.7: Bire-bir çoklu D.V.M sınıflandırma

Doğrudan çevrimsiz grafik yönteminde [49] eğitim aşaması bire-bir çoklu D.V.M sınıflandırma yöntemi ile aynıdır, ve  $k(k-1)/2$  tane ikili D.V.M modeli geliştirilmektedir. Sınıflandırma (test) aşamasında doğrudan çevrimsiz grafik yöntemi  $k(k-1)/2$  iç düğüme ve  $l$  adet düğüme sahip köklü doğrudan çevrimsiz grafik kullanılmaktadır. Her düğüm  $i$ . ve  $j$ . sınıflar arasındaki ikili D.V.M'dir. Verilen test örneği  $x$  için kök düğümden başlanarak ikili karar fonksiyonu hesaplanmaktadır. Sonra çıkış değerine bağlı olarak sağa veya sola hareket etmektedir. Bu yüzden tahmin edilen sınıfı gösteren yaprak düğüme ulaşmadan önce yol izlenmektedir.

[68], [69]'da bir tek optimizasyon problemini çözerek çoklu D.V.M sınıflandırılması gerçekleştirilmiştir. Kullanılan yaklaşım bire-hepsi yöntemine benzerdir.  $k$  adet karar fonksiyonları tek optimizasyon problemi çözülerek elde edilmektedir. [70]'te tek optimizasyon problemi çözülerek çoklu D.V.M sınıflandırma gerçekleştirilmiştir. Hata düzeltme çıkış kodları kullanılarak çoklu sınıflandırma çözümü [71]'de önerilmiştir. Hiperspektral görüntülerin D.V.M ile çoklu sınıflandırılmasında [56]'da bire-bir, bire-hepsi ve iki tane hiyerarşik ağaç tabanlı sınıflandırma yöntem olmak üzere dört farklı çoklu sınıflandırma yaklaşımı karşılaştırılmıştır.

Bu tez kapsamında, çoklu sınıflandırmayı gerçekleştirmek amacı ile bire-bir çoklu sınıflandırma yöntemi uygulanmıştır. Hiperspektral görüntülerde çoklu D.V.M sınıflandırma için bire-bir yöntemi literatürdeki çalışmalarda uygulanmış olup, hiperspektral görüntülerin İ.V.M kullanılarak sınıflandırılması ilk defa bu tez kapsamında gerçekleştirilmiştir.




Şekil 4.8: Çoklu sınıflandırma için paralel yaklaşım blok diyagramı

#### 4.5 Deneysel Sonuçlar

Gerçekleştirilen yöntemler için 220 bant içeren 1992 yılının Haziran ayında kuzeybatı Indiana'nın Indian Pine test alanında alınan hiperspektral görüntü [76] kullanılmıştır. Atmosferik gürültü içeren bantlar atılarak 200 bant bırakılmıştır. Kullanılan hiperspektral görüntünün tek bandının görüntüsü ve sınıf bilgilerinin içeren görüntü (ground truth) Şekil 4.9 (a) ve Şekil 4.9 (b)'de sırasıyla gösterilmektedir. Orijinal sınıf bilgisi verisinde 16 sınıf bulunmaktadır. Fakat veri miktarı büyük olan 9 sınıf seçilerek, bu sınıflar 4757 eğitim verisi ve 4588 test verisi elde etmek için kullanılmıştır. Her sınıf için seçilen eğitim ve test verilerinin miktarları Tablo 4.1'de gösterilmektedir. Hızlı eğitim süresi sağladığı için çoklu D.V.M ve İ.V.M sınıflandırma için bire-bir çoklu sınıflandırma kullanılmıştır. İVM yöntemi ikili sınıflandırma ile sınırlandırılmadığı halde pratikte çoklu sınıflandırma kullanımı azdır ve Hessian matrisinin boyutu sınıf sayısı arttıkça arttığı için işlem yükünü arttırmaktadır. D.V.M ve İ.V.M sınıflandırma için en sık kullanılan kerneller doğrusal, çok terimli ve radyal taban kernel fonksiyonlarıdır. Bu bölümde İ.V.M ve D.V.M sınıflandırma için R.T.F kerneli kullanılmıştır.



Kullanılan hiperspektral görüntünün [76] İ.V.M ve D.V.M ile akıllı sınıflandırılması sonucu elde edilen sınıflandırma başarımları ve İ.V.M sınıflandırma için kullanılan İ.V sayısı D.V.M sınıflandırma için kullanılan D.V sayısı, farklı kernel parametreleri için sırasıyla Tablo 4.2 ve Tablo 4.3’de gösterilmektedir. Burada S.B sınıflandırma başarımını göstermektedir. Hiperspektral görüntülerde İ.V.M sınıflandırma kullanılarak daha az kernel fonksiyonu eğitim aşamasında elde edilmiştir ve D.V.M sınıflandırma ile karşılaştırıldığında yaklaşık benzer sınıflandırma başarımı elde edilmiştir. Tablo 4.4’de İ.V.M ve D.V.M performansı farklı boyutlardaki eğitim verisi kullanılarak karşılaştırılmıştır. Eğitim verisi azaldıkça elde edilen destek /ilgililik vektör sayısı azalmakta ve sınıflandırma başarımı düşmektedir. Şekil 4.9 (c)’de R.T.F kernel ( $\gamma=1$ ) kullanılarak D.V.M (C=65) ile elde edilen sınıflandırma haritası Şekil 4.9 (d)’de ise R.T.F kernel ( $\gamma =1$ ) kullanılarak İ.V.M ile elde edilen sınıflandırma haritası gösterilmektedir. Elde edilen sonuçlar, gerçek zamanlı sistemler için İ.V.M sınıflandırma yönteminin D.V.M’ye göre daha uygun olduğunu göstermektedir. İ.V.M sınıflandırma yöntemi test aşamasında daha az kernel fonksiyonu kullandığı için hızlı işlem süresi ve test aşamasında düşük hesapsal maliyet elde etmesi nedeni ile sınıflandırma başarımındaki düşüş karşılığında D.V.M’ye göre tercih edilebilmektedir. İ.V.M eğitim aşaması D.V.M’den 7–8 kat yavaş olmasına rağmen sınıflandırma (test) aşaması D.V.M’den 7–8 kat daha hızlıdır.



(a)



(b)



(c)



(d)

Şekil 4.9: Hiperspektal görüntünün tek bandı (b): sınıf bilgisi verisi (c) R.T.F kernel ( $\gamma =1$ ,  $C=65$ ) kullanılarak D.V.M ile elde edilen sınıflandırma haritası (d) R.T.F kernel ( $\gamma =1$ ) kullanılarak İ.V.M ile elde edilen sınıflandırma haritası.

Tablo 4.1: Eğitim ve test örneklerinin miktarları

Sınıf	Eğitim verisi	Test verisi
S1-Corn-no till	742	692
S2-Corn-min till	442	392
S3-Grass/Pasture	260	237
S4-Grass/Trees	389	358
S5-Hay-windrowed	236	253
S6-Soybean-no till	487	481
S7-Soybean-min till	1245	1223
S8-Soybean-clean till	305	309
S9-Woods	651	643
Toplam	4757	4588

Tablo 4.2 : İ.V.M sınıflandırma sonuçları

Yöntem	Kernel Modeli	Kernel parametreleri		S.B	İ.V
		$\gamma$	$d$		
İ.V.M	R.T.F	0.1	-	89.41	414
İ.V.M	R.T.F	0.5	-	90.30	541
İ.V.M	R.T.F	1	-	90.14	514
İ.V.M	R.T.F	2	-	90.32	592
İ.V.M	R.T.F	3	-	90.03	509
İ.V.M	Ç.T.K	1	7	89.39	412

Tablo 4.3: D.V.M sınıflandırma sonuçları

Yöntem	Kernel Modeli	Kernel Parametreleri		C	S.B	D.V
		$\gamma$	$d$			
D.V.M	R.T.F	0.1	-	1000	90.88	3195
D.V.M	R.T.F	1	-	65	91.95	3259
D.V.M	R.T.F	2	-	40	92.67	3393
D.V.M	R.T.F	2	-	1000	92.56	3207
D.V.M	Ç.T.K	1	7	60	90.03	2066

Tablo 4.4: Farklı boyutlarda eğitim verisi kullanılarak elde edilen D.V.M ve İ.V.M sınıflandırma sonuçları

Eğitim Verisi	Test Verisi	D.V.M		İ.V.M	
		S.B	D.V	S.B	İ.V
590	4588	84.39	937	80.95	192
1320	4588	87.94	1510	84.45	254
2376	4588	90.56	2217	87.05	353
4757	4588	92.67	3393	90.32	592

## 5. SEYREKLİK-SINIFLANDIRMA BAŞARIMI DEĞİŞ TOKUŞU

Bu bölümde standart denetimli sınıflandırma algoritmalarına göre daha iyi sonuç veren destek vektör makinaları (D.V.M) ve ilgililik vektör makinaları (İ.V.M) temelli hiperspektral görüntü sınıflandırılması için seyreklik/ sınıflandırma başarımı değış tokuşu anlatılmaktadır. Bu doğrultuda,  $K$ -ortalama [40] ve faz korelasyonu temelli bölütleme [41] yöntemleri kullanılarak eğitim aşamasında benzer hiperspektral veri örneklerinin birleştirilmesi veya RAS.ÖR.ON [75] bağımsız geçerlilik sınaması (cross-validation) temelli en iyi alt-küme seçilmesi gerçekleştirilmektedir. Sonuç olarak hiperspektral eğitim verisi azaltılmaktadır ve D.V.M ile sınıflandırma için destek vektör sayısı, İ.V.M sınıflandırma için ilgililik vektör sayısı azaltılmaktadır. Gerçekleştirilen yöntem hem sınıflandırma hem de eğitim aşamasını hızlandırmakta; model seyrekliğini sınıflandırma başarımındaki düşük bir azalma karşılığında iyileştirmektedir. Hiperspektral görüntülere ön-işlem uygulandıktan sonra D.V.M ve İ.V.M sınıflandırma yöntemlerinin uygulanması gerçekleştirilmektedir. Gerçekleştirilen yöntem İ.V.M sınıflandırma için İ.V sayısını, D.V.M sınıflandırma için D.V sayısını azaltmakta ve düşük karmaşıklık gerektiren hedef tanıma uygulamaları gibi gerçek zamanlı uygulamalar için uygundur. Gerçekleştirilen yaklaşımlar ile sınıflandırma başarımında kabul edilebilir bir düşüş karşılığında seyreklik sağlanmaktadır. Seyreklik, model karmaşıklığını etkilemekte ve gerçekleştirilen yöntem ile model karmaşıklığı ve hesapsal yük azaltılmaktadır.

### 5.1 Faz Korelasyonu Kullanarak Bölütleme

Faz korelasyonu, iki işaretin benzerliğinin bulunmasında kullanılabilir ve temel olarak iki işaret arasındaki benzerliği bulmak için Fourier dönüşümünün özelliklerini kullanmaktadır. Gürültü azaltma ve video sıkıştırma gibi değışik uygulamaları bulunan faz korelasyonu, iki işaret arasında denklem 5.1 kullanılarak hesaplanmaktadır.

$$S_{(t,t+1)} = F^{-1} \left[ \frac{F(I_t) \times F^*(I_{t+1})}{|F(I_t) \times F^*(I_{t+1})|} \right] \quad (5.1)$$

Bu eşitlikte  $I_t$  ve  $I_{(t+1)}$  ardışık imge çerçevelerini gösterirken;  $F$ , iki boyutlu ayrık Fourier dönüşümünü (AFD) (discrete Fourier transform-DFT);  $F^{-1}$ , iki boyutlu ters ayrık Fourier dönüşümünü, \* ise karmaşık eşleniği ifade etmektedir.

Faz korelasyonu, hiperspektral görüntülerde iki farklı spektral imzanın benzerliğinin ölçülmesi amacıyla [41]'de kullanılmıştır. [41]'de gerçekleştirilen çalışmada alt-örneklenmiş spektral imzaların faz korelasyonu kullanılarak hiperspektral görüntülerde denetimsiz sınıflandırma (unsupervised classification) işlemi gerçekleştirilmiştir. Gerçekleştirilen uzamsal alt-örnekleme için 5:1 oranının kullanılması işlem yükünün düşük tutulabilmesi için tercih edilmiştir. Faz korelasyonunun önemli bir özelliği, iki işaret bire-bir aynı olmasa dahi, benzerlik durumunda yüksek bir yanıt alınabilmesidir [71, 72]. Bu nedenle faz korelasyonun iyi bir hiperspektral sınıflandırma ve tanıma yaklaşımı sağlayabileceği [41]'de gösterilmiştir.

Gerçekleştiren çalışma kapsamında faz korelasyonu kullanarak bölütleme işlemi gerçekleştirildikten sonra her kümenin ortalama değeri özellik vektörü olarak belirlenmekte ve sınıflandırma işleminde eğitim aşamasında kullanılmaktadır. Hiperspektral verinin tamamını kullanmak yerine, oluşan kümelerin ortalamasını alarak, eğitim ve tahmin aşamalarında hızlandırma gerçekleştirilmektedir.

## 5.2 $K$ -Ortalama Bölütlemesi

$K$ -ortalama algoritması veri kümesini, giriş parametresi olarak verilen  $K$  adet kümeye bölütlemektedir.  $K$ -ortalama algoritması ile gerçekleştirilen bölütleme işlemi sonunda elde edilen kümelerin, küme içi benzerliklerinin maksimum ve kümeler arası benzerliklerinin minimum olması amaçlanmaktadır. Küme benzerliği, kümenin ağırlık merkezi ile diğer veriler arasındaki uzaklıklar olarak ölçülmektedir [40].

$K$ -ortalama algoritmasının işlem basamakları şöyledir:

1. İlk küme merkezleri belirlenmektedir.
2. Her verinin seçilen merkez noktalara olan uzaklığı hesaplanmaktadır. Elde edilen sonuçlara göre tüm veriler  $K$  adet kümeden kendilerine en yakın olan kümeye yerleştirilmektedir.
3. Oluşan kümelerin yeni merkez noktaları o kümedeki tüm verilerin ortalama değeri ile değiştirilmektedir.
4. Merkez noktalar değişmeye kadar 2. ve 3. adımlar tekrarlanmaktadır.

$K$ -ortalama algoritmasının en büyük eksikliği sınıf sayısını ( $K$ ) otomatik tespit edememesidir. Bu nedenle başarılı bir kümeleme elde etmek için farklı  $K$  değerleri için deneme yanılma yönteminin uygulanması gerekmektedir.

Gerçekleştirilen çalışmada ön-işlem olarak  $K$ -ortalama algoritması kullanılarak bölütleme işlemi gerçekleştirildikten sonra her kümenin ortalama değeri özellik vektörü olarak belirlenmekte ve eğitim aşamasında sadece bölütleme sonucu elde edilen kümelerin ortalamaları kullanılmaktadır. Bu yaklaşım sayesinde eğitim ve tahmin aşamalarındaki hesapsal yük sınıflandırma başarımındaki az miktarda düşüş karşılığında azaltılmaktadır.

### 5.3 Rasgele Örnek Onaylaşım Yaklaşımı

Rasgele Örnek Onaylaşım (RAS.ÖR.ON) yaklaşımı [75] 'de önerilmiştir. Bu çalışma kapsamında önerilen RAS.ÖR.ON D.V.M ve İ.V.M yönteminde eğitim verisinden rasgele alt kümeler seçilmektedir. İ.V.M sınıflandırma için ilgililik vektörleri, D.V.M sınıflandırma için destek vektörleri bu alt kümelerin eğitim aşamasında kullanılmasıyla elde edilmektedir. Eğitim verisinden seçilen alt küme dışında kalan diğer eğitim verileri bağımsız geçerlilik sınaması aşamasında kullanılarak sınıflandırma başarımı hesaplanmaktadır ve eğer sınıflandırma başarımı yüksek ise, eğitim kümesinden rasgele seçilen o veri seti için elde edilen vektörler test verisinde de kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Sınıflandırma başarımı istenen değerde değilse aynı işlem yeni alt küme seçilerek tekrar gerçekleştirilmektedir. Sınıflandırma başarımının istenen kadar yüksek olmaması

durumunda sürekli rasgele veriler seçilerek işlem süresinin uzamasını engellemek amacı ile maksimum sınıflandırma başarımına sahip veri kümesinin eğitilmesi sonucu oluşan ilgililik vektörleri ve destek vektörleri sınıflandırma (test) aşamasında kullanılmaktadır. başarıım  $K$ -ortalama ön-işlem yöntemi kullanılarak elde edilmiştir.

#### 5.4 Deneysel Sonuçlar

Ön bölütleme D.V.M ve RAS.ÖR.ON D.V.M ile ön bölütleme İ.V.M ve RAS.ÖR.ON İ.V.M sınıflandırma yöntemleri 220 bant içeren 1992 yılında kuzeybatı Indiana'nın Indian Pine test alanında alınan hiperspektral görüntüsünde atmosferik gürültü içeren bantlar atılarak 200 bant kullanılarak uygulanmıştır. Özgün sınıf bilgisi verisinde 16 sınıf bulunmaktadır. Fakat, bazı sınıfların eleman sayısı çok düşük olduğundan veri miktarı büyük olan 9 sınıf seçilerek, bu sınıflar 4757 eğitim verisi ve 4588 test verisi elde etmek için kullanılmıştır. Her sınıf için seçilen eğitim ve test verilerinin miktarları Tablo 4.1'de gösterilmektedir. Hızlı eğitim süresi sağladığı için çoklu sınıflandırma için bire-bir çoklu sınıflandırma kullanılmıştır. İ.V.M yöntemi ikili sınıflandırma ile sınırlandırılmadığı halde pratikte çoklu sınıflandırma kullanımı azdır ve Hessian matrisinin boyutu sınıf sayısı arttıkça arttığı için işlem yükünü arttırmaktadır.

Örnek seyreltme yöntemleri olarak sınıflandırma öncesinde faz korelasyonu ve  $K$ -ortalama ön bölütleme yöntemleri ile RAS.ÖR.ON kullanılmıştır. Tablo 5.1-Tablo 5.5'de farklı örnek seyreltme oranlarında D.V.M ve İ.V.M sınıflandırma sonuçlarını göstermektedir. Bu tablolarda  $K$ -ortalama,  $K$ -ortalama bölütleme yöntemini, FK, faz korelasyonu bölütleme yöntemini ve RAS.ÖR.ON, RAS.ÖR.ON bağımsız geçerlilik sınavasını göstermektedir. D.V.M ve İ.V.M sınıflandırma için en sık kullanılan kerneller doğrusal, çok terimli ve radyal taban kernel fonksiyonlarıdır. Bu bölümde ön bölütleme ve RAS.ÖR.ON İ.V.M ve ön bölütleme ve RAS.ÖR.ON D.V.M sınıflandırma için R.T.F kerneli kullanılmıştır. Elde edilen sonuçlarda D.V.M sınıflandırma için C parametresi 40 ve D.V.M ve İ.V.M sınıflandırmada kullanılan R.T.F kerneli için gama değeri ( $\gamma$ ) 2 seçilmiştir. Tablolarda S.B sınıflandırma başarımını, İ.V ilgililik vektör sayısını ve D.V destek vektör sayısını göstermektedir.



Önerilen yaklaşımlar D.V ve İ.V sayıları azaltmakta fakat bunun karşılığında sınıflandırma başarımı düşmektedir.

$K$ -ortalama İ.V.M, faz korelasyonu İ.V.M ile karşılaştırıldığında yaklaşık aynı ilgililik vektör sayısında daha iyi sınıflandırma başarımı sağlamaktadır. RAS.ÖR.ON İ.V.M ise daha çok ilgililik vektörleri kullanarak  $K$ -ortalama İ.V.M'den daha iyi sınıflandırma başarımı sağlamaktadır. Ön bölütlenmiş İ.V.M ve RAS.ÖR.ON İ.V.M eğitim aşamasındaki zaman performansı nedeni ile ön bölütlenmiş D.V.M ve RAS.ÖR.ON D.V.M'ye göre tercih edilmektedir.

Hiperspektral görüntünün ön bölütlenmiş İ.V.M ve D.V.M ile RAS.ÖR.ON İ.V.M ve D.V.M sınıflandırılması sonucu elde edilen sınıflandırma başarımları ve ön bölütleme ve RAS.ÖR.ON İ.V.M sınıflandırma için kullanılan İ.V sayısı ile ön bölütleme ve RAS.ÖR.ON D.V.M sınıflandırma için kullanılan D.V sayısı farklı kernel parametreleri için Tablo 5.6 ve Tablo 5.7'de gösterilmektedir. Burada S.B sınıflandırma başarımını göstermektedir. Sınıflandırma başarımı ve test aşamasında kullanılan özellik vektörü sayısı (D.V.M için D. V, İ.V.M için İ.V sayısı) değiş tokuşu incelendiğinde  $K$ -ortalama yönteminin daha iyi sonuç verdiği gözlemlenmektedir.

Ön bölütleme ve RAS.ÖR.ON yaklaşımının sınıflandırma başarımındaki azalma karşılığında D.V.M sınıflandırma için destek vektör sayısını İ.V.M sınıflandırma için ilgililik vektör sayısını azalttığı gözlemlenmektedir. Deneysel sonuçlar ön bölütlenmiş İ.V.M ve RAS.ÖR.ON İ.V.M sınıflandırma yönteminin ön bölütlenmiş D.V.M ve RAS.ÖR.ON D.V.M ile karşılaştırıldığında benzer sınıflandırma başarımının daha az kernel fonksiyonu ile elde edildiğini göstermektedir. Seyreklik elde etmek amacıyla ön bölütlenmiş İ.V.M ve RAS.ÖR.ON İ.V.M tercih edilebilmektedir. Şekil 5.1 (a)'da R.T.F kerneli kullanılarak D.V.M ( $\gamma=2, C=40$ ) sonucu oluşan sınıf haritası, Şekil 5.1 (b)'de İ.V.M ( $\gamma=2$ ) sonucu oluşan sınıf haritası, Şekil 5.1 (e)'de  $K$ -ortalama D.V.M ( $\gamma=2, C=40$ ) sonucunda oluşan sınıf haritası, Şekil 5.1 (f)'de ise  $K$ -ortalama İ.V.M ( $\gamma=2, C=40$ ) sonucunda oluşan sınıf haritası gösterilmektedir.

Tablo 5.1: Eğitim verisinde % 88 oranında örnek seyreltimi sonucu elde edilen sonuçlar

Yöntem	D.V.M		İ.V.M	
	S.B	D.V	S.B	İ.V
<i>K</i> -ortalama	87.68	942	82.78	192
RAS.ÖR.ON	87.57	1203	82.74	209
FK	83.39	873	79.01	193

Tablo 5.2: Eğitim verisinde % 78 oranında örnek seyreltimi sonucu elde edilen sonuçlar

Yöntem	D.V.M		İ.V.M	
	S.B	D.V	S.B	İ.V
<i>K</i> -ortalama	89.25	1271	83.91	219
RAS.ÖR.ON	88.55	1470	84.06	264
FK	85.13	1307	80.62	240

Tablo 5.3: Eğitim verisinde % 66 oranında örnek seyreltimi sonucu elde edilen sonuçlar

Yöntem	D.V.M		İ.V.M	
	S.B	D.V	S.B	İ.V
<i>K</i> -ortalama	90.62	1746	85.06	287
RAS.ÖR.ON	89.84	1855	87.05	304
FK	87.46	1739	84.91	300

Tablo 5.4: Eğitim verisinde % 50 oranında örnek seyreltimi sonucu elde edilen sonuçlar

Yöntem	D.V.M		İ.V.M	
	S.B	D.V	S.B	İ.V
<i>K</i> -ortalama	91.06	2198	87.29	347
RAS.ÖR.ON	88.86	2030	84.63	388
FK	89.34	2134	86.79	349

Tablo 5.5: Eğitim verisinde % 25 oranında örnek seyreltimi sonucu elde edilen sonuçlar

Yöntem	D.V.M		İ.V.M	
	S.B	D.V	S.B	İ.V
<i>K</i> -ortalama	91.95	2782	89.42	438
RAS.ÖR.ON	91.84	2786	90.54	444
FK	91.30	2803	88.46	420

Tablo 5.6: Farklı kernel parametreleri için sonuçlar

Yöntem	Kernel parametreleri	S.B	İ.V
	$\gamma$		
<i>K</i> -ortalama İ.V.M	0.5	78.51	156
<i>K</i> -ortalama İ.V.M	1	80.38	176
<i>K</i> -ortalama İ.V.M	2	82.78	192
RAS.ÖR.ON İ.V.M	0.5	81.86	211
RAS.ÖR.ON İ.V.M	1	82.58	216
RAS.ÖR.ON İ.V.M	2	82.74	209
FK İ.V.M	0.5	78.16	166
FK İ.V.M	1	78.33	181
FK İ.V.M	2	79.01	193

Tablo 5.7: Farklı kernel parametreleri için sonuçlar

Yöntem	Kernel parametreleri	C	S.B	D.V
	$\gamma$			
<i>K</i> -ortalama D.V.M	0.5	150	86.02	805
<i>K</i> -ortalama D.V.M	1	65	86.83	885
<i>K</i> -ortalama D.V.M	2	40	87.68	942
RAS.ÖR.ON D.V.M	0.5	150	86.35	961
RAS.ÖR.ON D.V.M	1	65	87.01	1021
RAS.ÖR.ON D.V.M	2	40	87.57	1203
FK D.V.M	0.5	150	82.22	834
FK D.V.M	1	65	82.95	884
FK D.V.M	2	40	83.39	873



(a)



(b)



(c)



(d)

Şekil 5.1: R.T.F kerneli kullanılarak (a) D.V.M ( $\gamma=2$ ,  $C=40$ ) sonucu oluşan sınıf haritası (b) İ.V.M ( $\gamma=2$ ) sonucu oluşan sınıf haritası (c)  $K$ -ortalama D.V.M ( $\gamma=2$ ,  $C=40$ ) sonucunda oluşan sınıf haritası (d)  $K$ -ortalama İ.V.M ( $\gamma=2$ ,  $C=40$ ) sonucunda oluşan sınıf haritası

## 6. SONUÇLAR VE ÖNERİLER

Bu çalışmada hiperspektral görüntülerin kernel temelli D.V.M ve İ.V.M kullanılarak sınıflandırılması gerçekleştirilmiştir. Hiperspektral görüntülere uygulanmamış olan İ.V.M'nin bu tez kapsamında özgün olarak kullanılması sayesinde akıllı hiperspektral sınıflandırma ve tanıma yöntemlerinin geliştirilmesi sağlanmıştır. İ.V.M, D.V.M'nin genelleştirilmiş doğrusal bir biçimi olup D.V.M'nin istatistiksel çıkış verememe, ödünleşim (trade-off) parametre ihtiyacı ve 'Mercer' kernel fonksiyonlarının kullanılması zorunluluğu gibi dezavantajlarını ortadan kaldırmaktadır. İ.V.M sınıflandırma yöntemi ile D.V.M yöntemine göre daha az kernel fonksiyonu kullanılması nedeni ile gerçek zamanlı uygulamalar için daha uygundur.

Akıllı sınıflandırma yöntemleri olan İ.V.M ve D.V.M, hiperspektral görüntüye uygulanmadan önce  $K$ -ortalama veya faz korelasyonu temelli bölütleme algoritmaları ya da RAS.ÖR.ON yaklaşımı kullanılarak hiperspektral görüntülerde örnek seyreltme sonucu eğitim ve test sürelerinin sınıflandırma başarımında küçük düşüş karşılığında azaltılabileceği gösterilmiştir.

Hiperspektral görüntülerin sınıflandırılması öncesi sıkıştırılması amacı ile uygulanan yöntemlerden en iyi sonucu  $K$ -ortalama algoritması vermiştir.  $K$ -ortalama algoritmasında her kümenin merkezi bulunduktan sonra özellik vektörlerinin bu merkezlere uzaklıkları bulunmakta ve özellik vektörleri minimum uzaklıktaki merkeze ait kümeye ait olmaktadır. Burada örnek değerleri minimum uzaklığa sahip kümenin elemanıdır. Beklenti en büyütme (expectation maximization) algoritması ise  $K$ -ortalama algoritmasının olasılıksal biçimidir. Dolayısıyla keskin bilgiler vermek yerine örnek değerlerinin her sınıfa ait olma olasılıklarını bulmaktadır. İ.V.M ve D.V.M sınıflandırma öncesi beklenti en büyütme (expectation maximization) algoritmasının gerçekleştirilmesi  $K$ -ortalama İ.V.M ve  $K$ -ortalama D.V.M'den daha iyi sınıflandırma başarımı verebilir.

Hiperspektral görüntülerin uzamsal ve spectral imzalara göre gürültü giderimi yapıldıktan sonra D.V.M ve İ.V.M ile sınıflandırılması incelenerek, sınıflandırma performansına etkisi araştırılabilir.

## KAYNAKLAR

- [1] [http://earth.esa.int/ew/earthquakes/turkey\\_99/](http://earth.esa.int/ew/earthquakes/turkey_99/) (**Ziyaret Tarihi: 20 Kasım 2006**)
- [2] <http://asterweb.jpl.nasa.gov/gallery-detail.asp?name=esperanza/> (**Ziyaret Tarihi: 20 Kasım 2006**)
- [3] <http://rst.gsfc.nasa.gov/> (**Ziyaret Tarihi: 20 Kasım 2006**)
- [4] <http://www.remotesensing.org/tiki-index.php> (**Ziyaret Tarihi: 20 Kasım 2006**)
- [5] Mahmood, N.N., Loh, K.F., Ahmad, S., “Remote sensing research in Malaysia”, *IEEE International Geoscience and Remote Sensing*, 3, 1418-1420 (1997)
- [6] <http://www.es.ucsc.edu/~hyperwww/chevron/pan.html> (**Ziyaret Tarihi: 20 Kasım 2006**)
- [7] [http://www.classzone.com/books/earth\\_science/terc/content/investigations/esu101/esu101page07.cfm](http://www.classzone.com/books/earth_science/terc/content/investigations/esu101/esu101page07.cfm) (**Ziyaret Tarihi: 20 Kasım 2006**)
- [8] Biehl, L.L., Silva, L.F., “A multilevel multispectral data set analysis in the visible and infrared wavelength regions”, *Proceedings of the IEEE*, 63, 164 -175 (1975)
- [9] Jianghua, H., Lianfa, B., Jie, K., Bin, L., Liping, W., Baomin, Z., “Multispectral low light level image fusion technique”, *3rd International Conference on Signal Processing*, 2, 890-893 (1996)
- [10] <http://www.microimages.com> (**Ziyaret Tarihi: 20 Kasım 2006.**)
- [11] Perkinson, M.-C., Lobb, D., Cutter, M., Renton, R., “Low Cost Hyperspectral Imaging from Space”, *5th IAA Symposium on Small Satellites for Earth Observation*, Berlin, Germany, (2001)
- [12] Shippert, P., “Spotlight on Hyperspectral”, Geospatial Solutions, (2002)
- [13] Agrawal, A., Harrell, T., Bambot, S. B., Faupel, M., “Multimodal hyperspectral imaging of the cervix in vivo for the detection of neoplasia”, *Proceedings of SPIE* 4259
- [14] Ferris, D. G., Lawhead, R. A., Dickman, E. D., Holtzapple, N., Miller, J. A., Grogan, S., Bambot, S., Agrawal, A., Faupel, M. L., “Multimodal Hyperspectral Imaging for the Noninvasive Diagnosis of Cervical Neoplasia”, *Journal of Lower Genital Tract Disease*, 5, (2001)
- [15] Chaudhari, A. J., Darvas, F., Bading, J. R., Moats, R. A., Conti, P. S., Smith, D. J., Cherry, S.R., and Leahy, R. M., “Hyperspectral and multispectral

bioluminescence optical tomography for small animal imaging”, *Phys. Med. Biol.* 50, 5421-5441, (2005)

[16] Haboudane, D., Miller, J. R., Tremblay, N., Pattey, Vigneault E., P., “Estimation of Leaf Area Index using Ground Spectral Measurements over Agriculture Crops: Prediction capability assessment of optical indices”, *XXth ISPRS Congress*, 12-23, Istanbul, (2004)

[17] Smith, M. L., Martin, M. E., Plourde, L. and Ollinger S. V., “Analysis of Hyperspectral Data for Estimation of Temperate Forest Canopy Nitrogen Concentration: Comparison Between an Airborne (AVIRIS) and a Spaceborne (Hyperion) Sensor”, *IEEE Trans. on Geoscience and Remote Sensing* 41, 1332-1337, (2003)

[18] Smith, D. P., Lawrence, K. C., Park B., “Detection of fertility and early development of hatching eggs with hyperspectral imaging”, *Proceedings 17th European Symposium on Quality of Poultry Meat*. 139-144, (2005)

[19] Choi, Y., Stenger, H.G., “Kinetics, simulation and insights for CO selective oxidation”, *Journal of Power Sources*, 129, 246-254, (2004).

[20] [http://www.orient.it/spettroscantes\\_eng.html](http://www.orient.it/spettroscantes_eng.html) (**Ziyaret Tarihi: 20 Kasım 2006**)

[21] Gladden, J. B., Nelson, E., Riley, S., Jensen, J. R., Hadley, B. C., Tullis J. A., Filippi, T., Pendergast, M., “2002 Hyperspectral Analysis of Hazardous Waste Sites on the Savannah River Site”, University of South Carolina, *Westinghouse Savannah River Company, Texas A&M University, SMP Enterprises, Technical Report WSRC-TR-2003-00275*, (2003)

[22] Salem, F., M. Kafatos, T. El-Ghazawi, R. Gomez, and R. Yang, “Hyperspectral image assessment of oil-contaminated wetland”, *International Journal of Remote Sensing* 26, 811-821, (2005)

[23] Pal, D. and Nash G. D., “Mineralogic Interpretation Of Hymap Hyperspectral Data, Dixie Valley, Nevada, USA : Initial Results.” *Geothermal Resources Council Transactions* 27, 669-672, (2003)

[24] Bachmann, C. M., Donato, T. F. Lamela, G. M., Rhea W. J., Bettenhausen, M. H., Fusina, R. A, Bois, K. R. D., Porter, J. H., and Truitt, B. R., “Automatic Classification of Land Cover on Smith Island, VA, Using HyMAP Imagery”, *IEEE Trans. on Geoscience and Remote Sensing* 40, 2313–2330, (2002)

[25] Landgrebe, D. A., “Analysis of multispectral and hyperspectral image data”, Introduction to Modern Photogrammetry, *John Wiley & Sons, Inc.*, 2001

[26] Jia, X., Richards, J. A., “Segmented Principal Components Transformation for Efficient Hyperspectral Remote-Sensing Image Display and Classification”, *IEEE Trans. on Geoscience and Remote Sensing*, 37, 538–542 (1999)

[27] Lee, C. and Landgrebe D. A., “Analyzing highdimensional multispectral data”, *IEEE Trans. Geoscience and Remote Sensing*, 31, 792-800, (1997)



- [28] Jimenez, L. O., "High Dimensional Feature Reduction Via Projection Pursuit". Ph.D. thesis, *School of Electrical & Computer Engineering, Purdue University*, West Lafayette. (1995)
- [29] Tadjudin, S., "Classification of high dimensional data with limited training samples", Ph.D. thesis, *School of Electrical & Computer Engineering, Purdue University*, West Lafayette. (1998)
- [30] Hsu, P. H., Tseng, Y. H., and Gong P., "Dimension reduction of hyperspectral images for classification applications", *Geographic Information Sciences*, 8, 1-8 (2002)
- [31] Hsu, P.H., "Spectral Feature Extraction of Hyperspectral Images Using Wavelet Transform", Ph.D. Thesis, *Department of Surveying Engineering, National Cheng Kung University*, Tainan, Taiwan, R.O.C (2003)
- [32] Younan, N.H., King, R.L., Bennett, H.H., "Hyperspectral data analysis using wavelet-based classifiers", *Geoscience and Remote Sensing Symposium*, 1, 390-392, (2000).
- [33] P.H. Hsu: "Feature Extraction of Hyperspectral Images using Matching Pursuit", *XXth ISPRS Congress*, 883-888, Istanbul, Turkiye, (2004)
- [34] Du, H., Qi, H., Wang, X., Ramanath, Rajeev., Snyder, W. E., "Band Selection Using Independent Component Analysis for Hyperspectral Image Processing", *32nd Applied Imagery Pattern Recognition Workshop*, 93-98, Washington, DC, USA, (2003)
- [35] Lin, H.D., Bruce, L.M., "Parametric projection pursuit for dimensionality reduction of hyperspectral data", *IEEE International Geoscience and Remote Sensing Symposium*, 6, 3483-3485, (2003)
- [36] Velez-Reyes, M., Jimenez, L.O., "Subset selection analysis for the reduction of hyperspectral imagery", *IEEE International Geoscience and Remote Sensing Symposium Proceedings*, 3, 1577 - 1581 (1998)
- [37] Long, W., III; Srihann, S.; "Land cover classification of SSC image: unsupervised and supervised classification using ERDAS Imagine", *IEEE International, Geoscience and Remote Sensing Symposium*, 4, 2707 - 2712 (2004).
- [38] Goswami, A.; Ruoming Jin; Agrawal, G.; "Fast and exact out-of-core k-means clustering", *Fourth IEEE International Conference on Data Mining*, 83-90, Brighton, UK, (2004)
- [39] Chun, B. T., Bae Y., Kim, T.Y., "Caption segmentation method in videos using isodata clustering of topographical features", *TENCON 99. Proceedings of the IEEE Region Conference*, 2, 915 - 918 (1999)
- [40] Meyer, A., Paglieroni, D., Astaneh, C., "K-means re-clustering: algorithmic options with quantifiable performance comparisons", *SPIE Proceeding: Optical Engineering at the Lawrence Livermore National Laboratory*, 5001, 84-92, (2003)

- [41] Ertürk, A., Ertürk, S., “Unsupervised Segmentation of Hyperspectral Images Using Modified Phase Correlation,” *IEEE Geoscience and Remote Sensing Letters*, 3, 527-531 (2006)
- [42] Qian, S-E., Hollinger, A.B., Williams, D., Manak, D., “Vector quantization using spectral index-based multiple subcodebooks for hyperspectral data compression”, *IEEE Transactions on Geoscience and Remote Sensing*, 38, 756-770, (1999)
- [43] Chang, L., “Multispectral image compression using eigenregion-based segmentation”, *Pattern Recognition*, 36, 1233-1243, (2004)
- [44] Silvermann, J., Rotman, S.R., Cafer, C.E., “Segmentation of hyperspectral images based on histograms of principal components”, *SPIE Proceedings: Imaging Spectrometry VIII*, 4816, 270-277, (2002)
- [45] Mercir, G., Derrode, S., Lennon, M., “Hyperspectral image segmentation with markov chain model”, *Geoscience and Remote Sensing Symposium (IGARSS'03)*, 6, 3766-3768, (2003)
- [46] Acito, N., Corsini, G., Diani, M., “An unsupervised algorithm for hyperspectral image segmentation based on the Gaussian mixture model”, *Geoscience and Remote Sensing Symposium (IGARSS'03)*, 6, 3745-3747, (2003)
- [47] Boser, B. E., Guyon, I. M., and Vapnik, V., “A Training Algorithm for Optimal Margin Classifiers,” *Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory*, 144-152 (1992), Pittsburgh, PA,
- [48] Burges, C.: “A Tutorial on Support Vector Machines for Pattern Recognition,” *in Proc. Data Mining and Knowledge Discovery*, U. Fayyad, Ed. Kluwer Academic, 1-43 (1998)
- [49] Hsu, C.-W., Lin, C.-J.: “A comparison of methods for multiclass support vector machines,” *IEEE Trans. on Neural Networks*, 13, 1026 – 1027 (2002)
- [50] Bottou, L., Cortes, C., Denker, J., Drucker, H., Guyon, I., Jackel, L., LeCun, Y., Muller, U., Sackinger, E., Simard, P., and Vapnik, V.: “Comparison of classifier methods: A case study in handwriting digit recognition,” *in Proc. Int. Conf. Pattern Recognition*, 2, 77–87(1994)
- [51] Knerr, S., Personnaz, L., and Dreyfus, G.: “Single-layer learning revisited: A stepwise procedure for building and training a neural network,” in *Neurocomputing: Algorithms, Architectures and Applications*, J. Fogelman, Ed. *New York: Springer-Verlag*, (1990)
- [52] Huang, C., Davis, L. S., and Townshend, J. R. G.: “An Assessment of Support Vector Machines for Land Cover Classification,” *Int. J. Remote Sensing*, 23, 725-749 (2002)
- [53] Roli, F., and Fumera, G.: “Support vector machines for remote-sensing image classification,” *Proc. SPIE*, 4170, 160–166 (2001)

- [54] Hermes, L., Frieauff, D., Puzicha, J., and Buhmann, J. M.: “Support vector machines for land usage classification in landsat TM imagery,” *in Proc. IGARSS*, 348–350, Hamburg, Germany, (1999),
- [55] Gualtieri, J. A., Chettri, S. R., Crompton, R. F., and Johnson, L. F.: “Support vector machine classifiers as applied to AVIRIS data,” *in Summaries 8th JPL Airborne Earth Science Workshop, JPL Pub.* 99-17, 217–227 (1999)
- [56] Melgani, F., and Bruzzone, L.: “Classification of Hyperspectral Remote Sensing Images with Support Vector Machines,” *IEEE Trans. on Geoscience and Remote Sensing*, 42, 1778-1790 (2004)
- [57] Lennon, W. M., Mercier, G., and Hubert-Moy, L.: “Classification of hyperspectral images with nonlinear filtering and support vector machines,” *in IGARSS*, 3, 1670 -1672 (2002)
- [58] Camps-Valls, G., Bruzzone, L.: “Kernel-based methods for hyperspectral image classification,” *IEEE Trans. on Geoscience and Remote Sensing*, 43, 1352-1362 (2005)
- [59] Müller, K.R., Mika, S., Ratsch, G., Tsuda, K., and Schölkopf, B.: “An Introduction to Kernel-Based Learning Algorithms,” *IEEE Trans. on Neural Networks*, 12, 181–201 (2001)
- [60] Tipping, M. E.: “The relevance vector machine,” in *Advances in Neural Information Processing Systems 12*, S. A. Solla, T. K. Leen, and K.-R. Müller, Eds. Cambridge, MA: *MIT Press*, (2000)
- [61] Tipping, M. E.: “Sparse Bayesian learning and the relevance vector machine,” *Journal of Machine Learning Research*, 1, 211–244 (2001)
- [62] Markowska-Kaczmar, U., Kubacki, P., “Support vector machines in handwritten digits classification”, *Proceedings. 5th International Conference on Intelligent Systems Design and Applications*, 1 252 – 256 (2005)
- [63] Qin, Jun., He, Zhong-Shi., “A SVM face recognition method based on Gabor-featured key points”, *International Conference on Machine Learning and Cybernetics*, 8, 5144 -5149, (2005)
- [64] Li, Y., Liu Q., Ruan, X., “Cancer molecular classification based on support vector machines”, *Fifth World Congress on Intelligent Control and Automation, (WCICA)*, 6, 5521 - 5524 (2004)
- [65] Viswanathan, M., Kotagiri, R., “Comparing the performance of support vector machines to regression with structural risk minimization”, *Proceedings of International Conference on Intelligent Sensing and Information Processing*, 445 -449, (2004)
- [66] MacKay, D. J. C.: “The evidence framework applied to classification networks,” *Neural Computation*, 4, 720–736 (1992)

- [67] Nabney, I. T., “Efficient training of RBF networks for classification,” *in Proc. 9th ICANN*, 1, 210–215(1999)
- [68] Weston., J, and Watkins, C., “Multi-class support vector machines,” *in Proc. ESANN99*, M. Verleysen, Ed., Brussels, Belgium, (1999)
- [69] Vapnik, V., Statistical Learning Theory. *New York: Wiley*, 1998.
- [70] Crammer, K., and Singer, Y., “On the learnability and design of output codes for multiclass problems,” *Comput. Learning Theory*, 35–46, (2000).
- [71] Kindermann, J., Leopold, E., and Paass, G., “Multi-Class Classification with Error Correcting Codes,” in Treffen der GI-Fachgruppe 1.1.3, Maschinelles Lernen, E. Leopold and M. Kirsten, Eds., 2000, GMDRep. 114. .
- [72] Wang, J., Wu, X., Zhang, C.: “Support Vector Machines Based on K-means Clustering for Real-time Business Intelligence systems”, *Int. J. Business Intelligence and Data Mining*, 1, 54-64, (2005)
- [73] Ertürk, S., Dennis, T. J., “Image Sequence Stabilisation based on DFT filtering”, *IEE Proc. on Vision, Image, and Signal Processing*, 147, 95-102 (2000).
- [74] Ertürk, S., “Digital Image Stabilization with Sub-Image Phase Correlation Based Global Motion Estimation”, *IEEE Transactions on Consumer Electronics*, 49, 1320-1325, (2003).
- [75] Fischler, M. A., Bolles, R. C.: “Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography,” *Comm. of the ACM*, 24, 381-395, (1981)
- [76] <ftp://ftp.ecn.purdue.edu/biehl/MultiSpec/92AV3C> ve [ftp://ftp.ecn.purdue.edu/biehl/PC\\_MultiSpec/ThyFiles.zip](ftp://ftp.ecn.purdue.edu/biehl/PC_MultiSpec/ThyFiles.zip) (Ziyaret Tarihi: 20 Kasım 2006)
- [77] Cover, T. M.: “Geometrical and statistical properties of systems of linear inequalities with application in pattern recognition,” *IEEE Transactions on Electronic Computers*, 14, 304–314, (1965)

## KİŞİSEL YAYINLAR ve ESERLER

1. Begüm DEMİR, Sarp ERTÜRK, “Hyperspectral Image Classification Using Relevance Vector Machines”, *IEEE Geoscience and Remote Sensing Letters*, Ekim 2007, yayınlanmak üzere kabul edildi.
2. Begüm DEMİR, Sarp ERTÜRK, “Hyperspectral Data Classification Using RVM with Pre-Segmentation and RANSAC”, *International Conference on Geoscience and Remote Sensing Symposium*, July 2007, Barcelona, Spain, yayınlanmak üzere kabul edildi.
3. Begüm DEMİR, Sarp ERTÜRK, “Phase Correlation Based Supervised Classification of Hyperspectral Images Using Multiple Class Representatives”, *International Conference on Geoscience and Remote Sensing Symposium*, July 2007, Barcelona, Spain, yayınlanmak üzere kabul edildi.
4. Begüm DEMİR, Sarp ERTÜRK, “Achieving More Sparsity in Hyperspectral SVM Classification Using Unsupervised Pre-segmentation in the Training Phase”, *III. International Conference on Recent Advances in Space Technologies (RAST 2007)*, June 2007, Istanbul, TURKEY, yayınlanmak üzere kabul edildi.
5. Begüm DEMİR, Sarp ERTÜRK, “Vektör Makinaları Temelli Hiperspektral Sınıflandırma için Seyreklik/ Sınıflandırma Başarımı Değiş Tokuşu”, *XV IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Haziran 2007, Eskişehir
6. Begüm DEMİR, Sarp ERTÜRK, "Hiperspektral Görüntülerde Destek Vektör Makinaları ile Sınıflandırma Öncesi Dalgacık Uzayında Gürültü Giderimi", *XV IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Haziran 2007, Eskişehir.

## ÖZGEÇMİŞ

1984 yılında Ordu'da doğdu. İlk, orta ve lise öğrenimini İzmit'de tamamladı. 2001 yılında girdiği Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden 2005 yılında mezun oldu. 2005 yılından beri Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nde Yüksek Lisans'a devam etmektedir. Kocaeli Üniversitesi Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü'nde 2006-2007 tarihleri arasında Araştırma Görevlisi olarak görev yaptı. Mart 2007 tarihinden itibaren Elektronik ve Haberleşme Sistemleri Uygulama ve Araştırma Merkezinde Araştırma Görevlisi olarak çalışmaktadır.