

ÖZET

UZAKTAN ALGILAMALI GÖRÜNTÜLERİN BANT ÇIKARIMI ve MATEMATİKSEL BİÇİMBİLİM ÖNİŞLEMLERİ KULLANILARAK SINIFLANDIRILMASI

Zafer KIZILTOPRAK
Bilgisayar Mühendisliği, Yüksek Lisans Tezi

Hiperspektral görüntüler, uzaktan algılama yöntemleri kullanılarak elde edilen ve geniş bir bant aralığından alınan yüzlerce imgeyi içerir. Bu imgeler kullanılarak, görüntüyü oluşturan her bir piksel için dalga boyuna bağlı olarak kesikli olmayan bir spektrum bilgisi oluşur. Bu spektrumlardan yararlanarak, sınıflandırma için gerekli olan bilgilerde artış sağlanmaktadır. Bu da sınıflandırma aşamasında, başarımı daha yüksek sonuçlar elde edilmesini olanaklı kılar.

Hiperspektral görüntülerin, çok fazla tekrar eden bilgi içermesi nedeniyle son zamanlarda birçok uygulamada özellik çıkarımı yöntemleri kullanılarak bant azaltma yapılmaktadır. Bu yöntemlerin içinden, Temel Bileşen Analizi (TBA), bu çalışmada sınıflandırma öncesi kullanılan önışlemlerin ilk adımını oluşturmaktadır.

Matematiksel biçimbilim işlemleri ise TBA sonucunda elde edilen bantlardaki uzamsal verilerin ortaya çıkarılması amacıyla kullanılmaktadır. Temel işlemlerden olan açma ve kapama işlemleri, pikseller arası komşuluk ilişkilerini arttırarak sınıflandırma öncesindeki ikinci adımı oluştururlar.

Bu çalışmada, Destek Vektör Makineleri (DVM) ve İlgililik Vektör Makineleri (İVM), sınıflandırma yöntemleri kullanılmaktadır. Daha önceki çalışmalarda bahsedilen DVM ile sınıflandırma başarımının arttırılması ve İVM ile bir karşılaştırması gözlemlenmiştir. DVM ve İVM sınıflandırma performansını arttırmak ve sınıflandırma hesapsal yükünü azaltmak üzere, sınıflandırma öncesi hiperspektral görüntülere Temel Bileşen Analizi (TBA) ve biçimbilimsel yöntemler uygulanması önerilmiştir. Ön işlem olarak TBA ile bant sayısı azaltılmakta, biçimbilimsel işlemler ise veri kümelerinin sahip olduğu spektral özellikteki bilgilerin yanısıra, uzamsal özelliğe sahip bilgilerin ortaya çıkması olanaklı kılınmaktadır. TBA sonucu kullanılan her bir banta, biçimbilimsel işlemler uygulanarak, elde edilen bantlar İVM ile sınıflandırmaya sokulmaktadır. Önerilen yöntem, ön-işlem uygulanarak elde edilen düşük bant miktarında İVM sınıflandırmanın, doğrudan İVM ile karşılaştırıldığında daha iyi sonuçlar verdiğini göstermektedir.

ABSTRACT

THE CLASSIFICATION of REMOTE SENSED IMAGES WITH BAND EXTRACTION AND MATHEMATICAL MORPHOLOGY PREPROCESSING OPERATIONS

Zafer Kızıltoprak
Computer Engineering, Master Thesis

Hyperspectral images contain hundred of images obtained by remote sensing methods and collecting from a large wave length interval. By using these images, for each pixel constituting the image, a continuous spectrum information depending on the wave length is created. The information which is needed for classification is increased by means of these spectrums. This makes possible to augment the classification accuracy at the classification level.

As the hyperspectral images have lots of repeating information in itself, on many approaches and applications, the band reduction methods are recently used. Among these methods, the Principal Component Analysis (PCA) is the first step of the preprocessing operation which are mentioned in this thesis.

Mathematical morphology operations are used so as to rediscover the spatial information on the bands obtained as a result of PCA. The opening and closing, both are the basic operations of morphology, is the second step by increasing the neighbourhood relation between pixels.

In this thesis, the Support Vector Machines (SVM) and Relevance Vector Machines (RVM) are being used as classification methods. Improving of classification accuracy with SVM, mentioned in previous papers, articles and thesis, and comparing SVM and RVM is observed. It is proposed to apply PCA and mathematical morphology operations in order to increase classification performance for both SVM and RVM and also decrease computational load of Relevance Vector Machine (RVM). As preprocessing operations, by using PCA, the number of bands is reduced and by using morphological operations, it becomes possible to use spatial informations of data in addition to the spectral informations that the data has already had. The bands obtained by morphological operations using the results of PCA are processed in RVM. Proposed method shows that the bands obtained after preprocessing is giving better results than the RVM applied to the data directly.

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	iv
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ	viii
ÖNSÖZ	ix
ÖZET	x
ABSTRACT	xi
1. GİRİŞ	1
2. UZAKTAN ALGILAMA ve HİPERSPEKTRAL GÖRÜNTÜLER.....	4
2.1 Uzaktan Algılama.....	4
2.2 Çok Bantlı Görüntüler	7
2.2.1 Multispektral Görüntüler	7
2.2.2 Hiperspektral Görüntüler	7
3. HİPERSPEKTRAL GÖRÜNTÜLERDE BANT AZALTMA	10
3.1 Özellik Seçimi	11
3.2 Özellik Çıkarımı	12
3.2.1 Temel Bileşen Analizi	13
4. MATEMATİKSEL BİÇİMBİLİM.....	23
4.1 Temel Biçimbilimsel Birimler	23
4.1.1 Yapısal Eleman	23
4.1.2 Aşınma	24
4.1.3 Genişleme	26
4.2 Gelişmiş Biçimbilimsel İşlemler	28
4.2.1 Açma	28
4.2.2 Kapama	30
4.2.3 Gelişmiş Biçimbilimsel İşlemler	32
5. HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA	35
5.1 Eğitici-siz Sınıflandırma	36
5.2 Eğitici-li Sınıflandırma	38
5.3 Hiperspektral Gelişmiş Sınıflandırma Yöntemleri.....	40
5.3.1 Destek Vektör Makineleri.....	40
5.3.1.1 Doğrusal Olarak Ayrılabilen DVM ile Sınıflandırma	41

5.3.1.2	Doğrusal Olarak Ayrılamayan DVM ile Sınıflandırma.....	43
5.3.1.3	Doğrusal Olarak Ayrılamayan Kernel Yöntemli DVM ile Sınıflandırma.....	44
5.3.1.4	Çoksınıflı DVM ile Sınıflandırma.....	46
5.3.2	İlgililik Vektör Makineleri	47
6.	UYGULANAN YÖNTEM	52
6.1	Veri Seti	53
6.2	Uygulanan Yöntemin Adımları	56
6.2.1	Giriş – Özgün Veri	57
6.2.2	Bant Çıkarımı – Temel Bileşen Analizi.....	58
6.2.3	Matematiksel Biçimbilim – Açma / Kapama İşlemleri	62
6.2.4	Sınıflandırma Yöntemleri – DVM ve İVM	64
7.	SONUÇ	69
	KAYNAKLAR.....	71
	ÖZGEÇMİŞ	74

SİMGE LİSTESİ

d	Boyut sayısı
F	Özellik kümesi
r_i	x_i verisinin sınıf bilgisi
s^2	Varyans
$C^{n \times n}$	Kovaryans matrisi
l	Özdeğer
G	Dönüşüm matrisi
Λ	Aşınma
V	Genişleme
K	Küme Sayısı
S_i	i . sınıf
x_i	Eğitim setindeki i . veri
w	Ağırlık vektörü
a	Lagrange çarpanı
e	Yapay değişken
Σ	Kovaryans matrisi
$\Phi()$	Doğrusal olmayan dönüşüm
g	Radyal temel fonksiyonu ve çokterimli kernel fonksiyonu kernel parametresi
$s()$	Lojistik sigmoid bağlantı fonksiyon

KISALTMA LİSTESİ

AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
DAIS	Digital Airborne Imaging Spectrometer
HYDICE	Hyperspectral Digital Imagery Collection Experiment
BKB	Bire-Karşı-Bir
BKH	Bire-Karşı-Hepsi
DAFE	Discriminant Analysis Feature Extraction
DBFE	Decision Boundary Feature Extraction
DDA	Doğrusal Diskriminant Analizi
DVM	Destek Vektör Makineleri
İSA	İkili Sıradüzensel Ağaç
İVM	İlgililik Vektör Makineleri
TBA	Tmele Bileşen Analizi

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1	1999 İzmit depremi (a)öncesi ve (b)sonrası İzmit Körfezi (UHUZAM, 1999)	1
Şekil 1.2	26 Aralık 2004 tsunami felaketi (a)öncesi ve (b)sonrası Endonezya’da Aceh bölgesinin görüntüleri (NASA, 2004).....	2
Şekil 2.1	Elektromanyetik tayf	5
Şekil 2.2	Uzaktan algılamanın temel bileşenleri (a) enerji kaynağı (b) ışıınım ve atmosfer (c) nesneyle etkileşim (d) uzaktan algılayıcı (e) aktarım (f) yorumlama ve analiz (g) uygulama.....	6
Şekil 2.3	Elektromanyetik ışıının nesne yüzeylerine verdiği farklı tepkiler	6
Şekil 2.4	Bir hiperspektral görüntüye ait spektral küp	8
Şekil 2.5	Parlaklık değerleriyle elde edilen piksel spektrumu	9
Şekil 2.6	Multispektral ve hiperspektral verilerinin karşılaştırılması.....	9
Şekil 3.1	(a) 3 bantlı bir görüntüden bir piksele ait değerlerin alınması, (b) piksellerin koordinat ekseninde gösterilmesi (Akça, M.,D., Doğan, S., 2002)	20
Şekil 3.2	(x1, x2, x3) uzayında tanımlı 3 boyutlu görüntüye ait piksellerin (y1,y2,y3) uzayına olan dönüşümü (Akça, M.,D., Doğan, S., 2002)	21
Şekil 4.1	Yapısal eleman örnekleri. (a) Z8, (b) Z4, (c) disk, (d) 2x3 dikdörtgen, (e) kaydırma24	
Şekil 4.2	Aşındırma işlemi.....	25
Şekil 4.3	(a) İkili imge (b) Kırmızı alanlar : Dairesel yapısal alan. Mavi alan : Aşınmadan etkilenmeyen arkaplan. Beyaz alan : Aşınmadan etkilenen, önplandaki nesneden arkaplana dahil olacak piksel grubu (c) İmgenin genişlemeden sonraki hali.....	26
Şekil 4.4	Genişleme işlemi.....	27
Şekil 4.5	(a) İkili imge (b) Kırmızı alanlar : Dairesel yapısal alan. Mavi alan : Genişlemeden etkilenmeyen arkaplan. Beyaz alan : Genişlemeden etkilenen, arkaplandan önplandaki nesneye dahil olacak piksel grubu (c) İmgenin genişlemeden sonraki hali.....	27
Şekil 4.6	OCR taraması sonucunda elde edilen örnek imge- kullanılan yapısal eleman ve genişleme sonrası sonuç resmi.....	28
Şekil 4.7	3x3 boyutlarındaki bir yapısal eleman ile gerçekleştirilen açma işlemi	29
Şekil 4.8	(a) İkili resim (b) mavi : arkaplan, beyaz : önplan, kırmızı : yapısal eleman (c) açma sonucu	29
Şekil 4.9	11 piksel çaplı disk şeklindeki bir yapısal eleman ile açma işleminin çalışması	30

Şekil 4.10	Kapama işlemi	31
Şekil 4.11	(a) İkili resim (b) mavi : arkaplan, beyaz : önplan, kırmızı : yapısal eleman (c) açma sonucu	31
Şekil 4.12	(a) Kapama işlemi uygulanacak giriş imgesi (b) Kapama işlemi sonuç imgesi	32
Şekil 4.13	(a) Özgün gri seviyeli imge (b) Aşınma (c) Genişleme (d) Açma (e) Kapama.....	33
Şekil 4.14	Renkli imgelerde temel biçimbilimsel işlemler (a) Özgün renkli imge (b) Aşınma (5x5'lik yapısal eleman) (c) Genişleme (5x5'lik yapısal eleman).....	34
Şekil 5.1	(a) Uzaktan algılama yöntemleri ile elde edilen örnek görüntü (b) örnek görüntü için sınıf verisi	35
Şekil 5.2	4 bantlı bir görüntünün temel sınıflandırma akışı.....	36
Şekil 5.3	(a) Uzaktan algılama ile elde edilmiş 3 bantlı görüntü (Landsat / Kowloon – Hong Kong Island) (b) $k = 10$ için 10-ortalama (c) $k=5$ için 5-ortalama sonucu oluşan sınıflandırma sonuçları.....	37
Şekil 5.4	(a) Indian Pine görüntüsü (b) Normal DVM ve (c) birleşik kernelli DVM ile elde edilen sınıflandırma sonuç görüntüleri.....	39
Şekil 5.5	Farklı DVM örnekleri.....	41
Şekil 5.6	İki sınıflı bir sınıflandırma işleminde destek vektörlerinin gösterimi (Melgani, F., Bruzzone, L., 2004).....	42
Şekil 5.7	2 boyutlu uzaydan 3 boyutlu özellik uzayına geçiş	44
Şekil 5.8	Aynı veri seti üzerinde hata ve vektör sayısı bakımından DVM ve İVM karşılaştırması (Tipping, M. E., 2000).....	50
Şekil 6.1	Temsili görüntüler (a) DC-Mall, (b) Pavia, (c) Indian Pine (IP)	53
Şekil 6.2	(a) <i>Indian Pine</i> görüntüsünün temsili örnek imgesi (b) <i>Indian Pine</i> görüntüsüne ait sınıf bilgilerini gösteren sınıf bilgisi imgesi.....	55
Şekil 6.3	Tez kapsamında uygulanan yöntem adımlarının akışı	56
Şekil 6.4	200 bantlık IP görüntüsünden rastgele seçilmiş bant örnekleri.....	57
Şekil 6.5	<i>Indian pine</i> verisi için ilk 3 bantlık TBA sonucu.....	62
Şekil 6.6	Kullanılan yapısal elemanlar (3x3, 5x5 ve 7x7).....	63
Şekil 6.7	“Indian Pine” verisi için elde edilen 1. TBA bandı (a) için, 3x3, 5x5, 7x7'lik yapısal elemanlar kullanılarak oluşturulan açma-kapama işlemleri (b)(c)(d) açma (e)(f)(g) kapama işlemleri	63
Şekil 6.8	İVM Sınıflandırma başarımlar haritaları. (a) 21 bant, (b) 27 bant, (c) 33 bant, (d) 39 bant üzerinden yapılan sınıflandırma başarımları.....	67
Şekil 6.9	DVM Sınıflandırma başarımlar haritaları. (a) 21 bant, (b) 27 bant, (c) 33 bant, (d) 39 bant üzerinden yapılan sınıflandırma başarımları.....	67

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1	Uzaktan algılamada kullanılan dalga boyları ve frekansları	4
Çizelge 3.1	(a) $X=[0\ 8\ 12\ 20]$ kümesi için standart sapma hesaplanması. (b) $X=[8\ 9\ 11\ 12]$ kümesi için standart sapma hesaplanması	14
Çizelge 6.1	DC-Mall, Pavia ve Indian Pine görüntülerine ait temel özelliklerin karşılaştırılması	53
Çizelge 6.2	<i>Indian Pine</i> görüntüsü için ilk 9 sınıfın eğitim ve test piksel sayıları	55
Çizelge 6.3	TBA sonucunda elde edilen bantların özdeğerleri ve bütün özdeğerler toplamına oranları	62
Çizelge 6.4	DVM için farklı TBA bant ve farklı açma-kapama işlemlerinin sonuçları. İBS=İlk Bant Sayısı, TBA-BS=TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, % DVM=% olarak DVM Başarımı.	65
Çizelge 6.5	İVM sonuçları. TBA-BS= TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, İV=İlgililik Vektör Sayısı, % İVM= % olarak Başarım, ES (s)=Eğitim Süresi, TS (s)=Test Süresi.66	
Çizelge 6.6	DVM sonuçları. TBA-BS= TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, İV=Destek Vektör Sayısı, % DVM= % olarak Başarım, ES (s)=Eğitim Süresi, TS (s)=Test Süresi.66	

ÖNSÖZ

Ülkemiz olanaklarında bilim ve fen alanında yapılan çalışmaların kağıt üstünde kalmayıp, ülkemiz gençlerine yeni ufuklar açmasını diliyorum. Bu çalışmanın da ülkemiz geleceği için artı değerler getirmesini, kendilerini bu tez konusu kapsamına giren alanlarda geliştirmek isteyen araştırmacı arkadaşlara yol göstermesi temel temennimdir. Diğer yandan uydu ve havacılık teknoloji alanlarında gelişim gösterip teknolojik açıdan kendi kendimize yettiğimiz günler için ufak da olsa bir ilerleme sağlayabilmek tek amacımdı. Büyük Önder Mustafa Kemal Atatürk'ün de belirttiği gibi, “İstikbal, göklerde dir”.

Bu tez çalışması öncesinde ve sırasında;

Destegi ni her zaman hissettiğim ve bana karşı göstermiş oldu ğu sabrını örnek aldı ğım değerli hocam Yrd.Doç.Dr. Banu Diri' ye,

Biçimbilim kavramıyla beni tanıştı rıp önümde yeni ufuklar açan değerli dostum Erhan Abdullah'a,

Her aşamada deste ğini, ilgisini ve sevgisini bir an olsun bile eksik etmeyen, çalışma hırsıyla beni gayretlendiren biricik insan Begüm Demir'e,

Ve tabii ki, bugünlere gelmemde, doğru ya da yanlış her kararında, doğru da destekleyerek, yanı şta doğruyu göstererek her zaman yanımda olan aileme, anneme, babama ve ağabeyime, herşey için çok teşekkürler, iyi ki varsınız.

ÖZET

UZAKTAN ALGILAMALI GÖRÜNTÜLERİN BANT ÇIKARIMI ve MATEMATİKSEL BİÇİMBİLİM ÖNİŞLEMLERİ KULLANILARAK SINIFLANDIRILMASI

Zafer KIZILTOPRAK

Bilgisayar Mühendisliği, Yüksek Lisans Tezi

Hiperspektral görüntüler, uzaktan algılama yöntemleri kullanılarak elde edilen ve geniş bir bant aralığından alınan yüzlerce imgeyi içerir. Bu imgeler kullanılarak, görüntüyü oluşturan her bir piksel için dalga boyuna bağlı olarak kesikli olmayan bir spektrum bilgisi oluşur. Bu spektrumlardan yararlanarak, sınıflandırma için gerekli olan bilgilerde artış sağlanmaktadır. Bu da sınıflandırma aşamasında, başarıyı daha yüksek sonuçlar elde edilmesini olanaklı kılar.

Hiperspektral görüntülerin, çok fazla tekrar eden bilgi içermesi nedeniyle son zamanlarda birçok uygulamada özellik çıkarımı yöntemleri kullanılarak bant azaltma yapılmaktadır. Bu yöntemlerin içinden, Temel Bileşen Analizi (TBA), bu çalışmada sınıflandırma öncesi kullanılan önışlemlerin ilk adımını oluşturmaktadır.

Matematiksel biçimbilim işlemleri ise TBA sonucunda elde edilen bantlardaki uzamsal verilerin ortaya çıkarılması amacıyla kullanılmaktadır. Temel işlemlerden olan açma ve kapama işlemleri, pikseller arası komşuluk ilişkilerini arttırarak sınıflandırma öncesindeki ikinci adımı oluştururlar.

Bu çalışmada, Destek Vektör Makineleri (DVM) ve İlgililik Vektör Makineleri (İVM), sınıflandırma yöntemleri kullanılmaktadır. Daha önceki çalışmalarda bahsedilen DVM ile sınıflandırma başarımının arttırılması ve İVM ile bir karşılaştırması gözlemlenmiştir. DVM ve İVM sınıflandırma performansını arttırmak ve sınıflandırma hesapsal yükünü azaltmak üzere, sınıflandırma öncesi hiperspektral görüntülere Temel Bileşen Analizi (TBA) ve biçimbilimsel yöntemler uygulanması önerilmiştir. Ön işlem olarak TBA ile bant sayısı azaltılmakta, biçimbilimsel işlemler ise veri kümelerinin sahip olduğu spektral özellikteki bilgilerin yanısıra, uzamsal özelliğe sahip bilgilerin ortaya çıkması olanaklı kılınmaktadır. TBA sonucu kullanılan her bir banta, biçimbilimsel işlemler uygulanarak, elde edilen bantlar İVM ile sınıflandırmaya sokulmaktadır. Önerilen yöntem, ön-işlem uygulanarak elde edilen düşük bant miktarında İVM sınıflandırmanın, doğrudan İVM ile karşılaştırıldığında daha iyi sonuçlar verdiğini göstermektedir.

ABSTRACT

THE CLASSIFICATION of REMOTE SENSED IMAGES WITH BAND EXTRACTION AND MATHEMATICAL MORPHOLOGY PREPROCESSING OPERATIONS

Zafer Kızıltoprak
Computer Engineering, Master Thesis

Hyperspectral images contain hundred of images obtained by remote sensing methods and collecting from a large wave length interval. By using these images, for each pixel constituting the image, a continuous spectrum information depending on the wave length is created. The information which is needed for classification is increased by means of these spectrums. This makes possible to augment the classification accuracy at the classification level.


As the hyperspectral images have lots of repeating information in itself, on many approaches and applications, the band reduction methods are recently used. Among these methods, the Principal Component Analysis (PCA) is the first step of the preprocessing operation which are mentioned in this thesis.

Mathematical morphology operations are used so as to rediscover the spatial information on the bands obtained as a result of PCA. The opening and closing, both are the basic operations of morphology, is the second step by increasing the neighbourhood relation between pixels.

In this thesis, the Support Vector Machines (SVM) and Relevance Vector Machines (RVM) are being used as classification methods. Improving of classification accuracy with SVM, mentioned in previous papers, articles and thesis, and comparing SVM and RVM is observed. It is proposed to apply PCA and mathematical morphology operations in order to increase classification performance for both SVM and RVM and also decrease computational load of Relevance Vector Machine (RVM). As preprocessing operations, by using PCA, the number of bands is reduced and by using morphological operations, it becomes possible to use spatial informations of data in addition to the spectral informations that the data has already had. The bands obtained by morphological operations using the results of PCA are processed in RVM. Proposed method shows that the bands obtained after preprocessing is giving better results than the RVM applied to the data directly.

1. GİRİŞ

Günümüz dünyasında, çevresel olayların gözlenmesi, insan-doğa etkileşiminin sonuçlarının takibinin yapılması ve yorumlanması, vb. sebeplerden yeryüzüne ait kapsamlı veri kümelerine ihtiyaç duyulmaktadır. Dünya yüzeyine ait gelişimlerin en kolay ve en geniş şekilde izlenebildiği noktalardan biri de dünya yörüngesindeki uydulardır. Uydular aracılığıyla elde edilen verilerin tutarlılığının sağlanması ve belli bir noktanın farklı zamanlara ait görüntüsünün elde edilmesini olanaklı kılmaktadır. Şekil 1.1.(a) ve Şekil 1.1.(b)'de 1999 İzmit depreminden önce ve sonra alınmış uydu görüntüleri gösterilmiştir. Şekil 1.1.(b)'de deprem sonrası meydana gelen yangına ait dumanlar görülmektedir. Şekil 1.2'de ise Endonezya'nın Aceh bölgesinin 26 Aralık 2004 tarihinde yaşadığı tsunami felaketinden önceki ve sonraki görüntüleri görülmektedir.



Şekil 1.1 1999 İzmit depremi (a)öncesi ve (b)sonrası İzmit Körfezi (UHUZAM, 1999)

Uzaktan algılama kavramının, askeri, sivil ve araştırma alanlarındaki ihtiyaçların karşılanması doğrultusunda gelişen günümüz teknolojisinin bir getirisi olarak uzay fotoğrafçılığı ile birlikte gelişim göstermesi bu alanda elde edilen verilerin ulaşılabilirliğini arttırmıştır. Bunun yanında bu görüntülerin kalitesi ve işlenebilirlik oranı da bu gelişimle paralel yönde ilerlemiştir.

Bu tez kapsamında, uzaktan algılama yöntemleri kullanılarak elde edilen çok bantlı görüntü sınıflarından biri olan hiperspektral görüntüler üzerinde yapılan görüntü işleme ve sınıflandırma yöntemlerine değinilmiştir.

Uzaktan algılama ve hiperspektral görüntülemenin birbirleriyle olan ilişkileri, uzaktan algılamanın hangi şartlar altında gerçekleştirildiği, hiperspektral görüntülerin yapıları ve elde edilme yollarından bu tez çalışmasında Bölüm 2'de bahsedilmiştir. Hiperspektral görüntülerin elde edilmesinde kullanılan elektromanyetik dalga boyu aralıkları ve bunların özellikleri

multispektral görüntülerle karşılaştırılarak incelenmiştir.



(a)



(b)

Şekil 1.2 26 Aralık 2004 tsunami felaketi (a)öncesi ve (b)sonrası Endonezya’da Aceh bölgesinin görüntüleri (NASA, 2004)

Hiperspektral görüntüler, elde edilme şekilleri yüzünden çok büyük veri boyutlarına sahiptirler. Bu aşamada bu miktarda veri kümesinin işlenmesi zaman ve sistem kaynağı açısından birçok soruna yol açmaktadır (Zortea, M., Haertel, V, 2004). Bu nedenle bu tip görüntüler üzerinde işleme öncesi bant azaltma yöntemleri kullanılmaktadır. Hiperspektral resimler üzerindeki bant azaltma yöntemleri iki başlık altında, özellik seçme ve özellik çıkarımı olarak incelenmiştir (Kittler, J., 1986). Bu tez çalışması uygulamasında özellik çıkarımı yöntemi olan *Temel Bileşen Analizi (Principal Component Analysis)* kullanılmıştır. Bölüm 3’te hiperspektral görüntüler üzerinde bant azaltma yöntemlerinden bahsedilmiş ve Temel Bileşen Analizi (TBA) bu kapsamda detaylı bir şekilde incelenmiştir.

1980’li yılların başında kafes kuramı ve topoloji kavramlarından yola çıkılarak oluşturulan

matematiksel biçimbilim (mathematical morphology) konusuna ait olan işlemlerin imgeler üzerine kullanılması kuramın başlangıcına kadar uzanır (Diamantaras, I., Zimerman K.H., Kung S.Y., 1990). İmgeler üzerinde gürültü gideriminden, iskelet çıkarımına kadar geniş bir yelpazede aşınma (erosion) ve genişleme (dilation) olarak adlandırılan iki temel işlemi kullanan biçimbilim bu çalışmada hiperspektral görüntülerin sahip olduğu bantlara uygulanmıştır. Matematiksel biçimbilime ait temel kavramlar ve uygulama örnekleri tez çalışmasında Bölüm 4'te detaylandırılmıştır.

Uzaktan algılamada en çok çalışılan alanlardan biri olan sınıflandırma kavramı Bölüm 5'te ele alınmıştır. Bu bölümde, TBA ve matematiksel biçimbilim önışlemlerinden geçen görüntülerin içeriğinde bulunan nesnelerin tanımlanması için gerekli olan yöntemlerin farkları, modellerin oluşturulma safları ve matematiksel altyapıları anlatılmıştır. Sınıflandırma yöntemlerinde *Destek Vektör Makineleri (Support Vector Machines)* ve *İlgililik Vektör Makineleri (Relevance Vector Machines)* detaylı bir şekilde incelenip bu iki yöntemin aralarındaki yapısal ilişki, birbirlerine göre avantaj ve dezavantajları, vb. noktalar irdelenmiştir.

Tez çalışmasının son bölümünde, TBA ve biçimbilimsel işlemlerden geçirilmiş hiperspektral verinin Destek Vektör Makineleri (DVM) ve İlgililik Vektör Makineleri (İVM) ile sınıflandırılması sonucu elde edilen başarımlar karşılaştırılmış ve yorumlanmıştır. Biçimbilimsel önışlem uygulanan verinin DVM ile sınıflandırılmasına benzer şekilde, biçimbilimsel önışleme tabii tutulan veri kümesinin İVM ile sınıflandırılması ilk kez bu tez kapsamında ele alınmıştır. Uygulanan yöntem ve sonuçlara ait detaylar Bölüm 6 ve 7'de bulunmaktadır.

2. UZAKTAN ALGILAMA ve HİPERSPEKTRAL GÖRÜNTÜLER

2.1 Uzaktan Algılama

Uzaktan algılama, yeryüzünün ve yeryüzüne ait kaynakların incelenmesinde, yeryüzü ile fiziksel bir temas kurmadan inceleme ve kaydetme tekniklerinin bütünüdür. Diğer yandan, uzaktan algılama uydu teknolojilerinin kullanılmaya başlandığı yıllardan beri varolan bir tekniktir. Bu tanıma ek olarak, algılama işleminde kullanılan temel araç, yeryüzünden yansıyan elektromanyetik tayf içinde morötesi ve mikrodalga bantlar arasında dalga boylarına sahip ışıktır. Uzaktan algılama tekniğinde kullanılan dalga boyu aralıkları Çizelge 2.1’de verilmiştir. Bu çizelgedeki sadece görünür bölge insan gözü tarafından algılanabilir. Şekil 2.1’de dalga boylarının dağılımının görsel olarak ifadesi vardır.


Çizelge 2.1 Uzaktan algılamada kullanılan dalga boyları ve frekansları

Sınıf		Dalga Boyu	Frekans
a.Mor ötesi		0.3-0.4 μm	750 -3000 THz
b.Görünür bölge	Mavi	0,4 - 0,5 μm	644 - 750 THz
	Yeşil	0,5 - 0,6 μm	537 - 644 THz
	Kırmızı	0,6 - 07 μm	430 - 537 THz
c.Kırmızı ötesi	Yakın Kırmızı Ötesi	0.7 - 1.3 μm	230 - 430 THz
	Kısa dalga Kırmızı Ötesi	1.3 - 3 μm	100 - 230 THz
	Orta Kırmızı Ötesi	3 - 8 μm	38 - 100 THz
	Isıl Kırmızı Ötesi	8 - 14 μm	22 - 38 THz
	Uzak Kırmızı Ötesi	14 μm - 1 mm	0.3 – 22 THz
d. Radyo Dalgaları	Mikrodalga	Milimetre (EHF)	1 - 10 mm 30 – 300 GHz
		Santimetre (SHF)	1 - 10 cm 3 – 30 GHz
		Desimetre (UHF)	0.1 - 1 m 0.3 – 3 GHz
	Çok Kısa Dalga (VHF)		1 - 10 m 30 - 300 MHz
	Kısa Dalga (HF)		10 - 100 m 3 - 30 MHz
	Orta Dalga (MF)		0.1 - 1 km 0.3 - 3 MHz
	Uzun Dalga (LF)		1 - 10 km 30 - 300 KHz
	Çok Uzun Dalga (VLF)		10 - 100 km 3 - 30 KHz

Işık, uzaktan algılamadaki temel bilgi kaynağı olduğundan, algılayıcılar bir ışık kaynağına ihtiyaç duyarlar. Bu kaynak *edilgen uzaktan algılama (passive remote sensing)* yöntemleri için yapay ışık kaynaklarıdır. Bu tarz kaynaklar genellikle alıcıyla birlikte aynı sistem içinde yer alırlar. *Etkin uzaktan algılama (active remote sensing)* yöntemlerinde ise ışık kaynağı doğaldır, yani güneş ışığıdır. Bu yöntem en güvenilir sonuçları vermesine karşın gece-gündüz değişimlerinden ve bazı atmosfer hareketlerinden doğrudan etkilenir (Ulaby F.T., Moore R.K., Fung A.K 1981). Şekil 2.2’de uzaktan algılama sürecinin gelişimi ve temel taşları

gösterilmektedir.

Dalga boyları, kısa dalga boylarından başlamak üzere, X-ışınlarından radyo dalgalarına kadar geniş bir aralıkta yerleşmektedirler. Dalga boyu kısaltıkça, elektromanyetik ışınlam daha doğrusal ve daha fazla yönelme başarımıyla hareket eder.




Şekil 2.1 Elektromanyetik tayf

Işığın sahip olduğu ve nesnelerden yansıyan ya da yayımlanan elektromanyetik ışınlam, uzaktan algılamanın veri kaynağıdır. Nesnelerden yansıyan ya da yayımlanan bu ışınlamı belirleyen ve onları kaydetmede kullanan araçlara uzaktan algılayıcılar denmektedir. Kameralar ve tarayıcılar bu araçlara örnek olarak verilebilir. Şekil 2.3’de elektromanyetik ışınlamın nesneler üzerinde 5 farklı tür tepkiye yol açtığı görülmektedir (Campbell, J.B., 2006). Bu 5 farklı tepki, iletim, yansıma, serpilme, emilim ve yayma olarak adlandırılır. Uzaktan algılamada, algılayıcılar genellikle yansıma ve yayma ışınlam türleri ile gerekli verilere ulaşırlar.


Uzay fotoğrafçılığının temellerinin atılması ve geliştirilmesi ile uzaktan algılama tekniğinin ve bu teknikten elde edilen verilerin güvenilirliği artmıştır. Sistemli uzay ve hava fotoğrafçılığının temelleri, askeri amaçlar doğrultusunda Birinci Dünya Savaşı sırasında atılarak, soğuk savaş yıllarını da içine alacak şekilde artan bir ivmeyle devam etmiştir. İlk önceleri uçak ve benzeri hava araçları ile gözlenmekteyken, uydu teknolojisinin gelişmesi ve

maliyetlerin azalmasıyla veri alımları bu yöne kaymıştır. 20. yüzyılın ikinci yarısında yapay uyduların geliştirilmesi küresel anlamda uzaktan algılama yapılmasına olanak sağlamıştır. *Landsat*, *Nimbus* uyduları hava durumu için gözlem yaparken, *RADARSAT* ve *UARS* gibi uydular da sivil ve/veya askeri araştırma amaçlı Dünya gözlemlemesi yapmaktadırlar.



Şekil 2.2 Uzaktan algılamanın temel bileşenleri (a) enerji kaynağı (b) ışınım ve atmosfer (c) nesneyle etkileşim (d) uzaktan algılayıcı (e) aktarım (f) yorumlama ve analiz (g) uygulama

Uzaktan algılamada elde edilen veriler iki alanda incelenir ve yorumlanır. Bunlardan birincisi *görsel yorum (visual interpretation)* olarak adlandırabileceğimiz ve sadece insanın görme duyusu ile ilişkilendirilen alandır. İkinci ve daha etkin olanı ise *sayısal görüntü işleme (digital image processing)* tekniklerinin kullanıldığı alandır (Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2003).



Şekil 2.3 Elektromanyetik ışınımın nesne yüzeylerine verdiği farklı tepkiler

Sayısal görüntü işleme tekniklerinin kullanılmasına yol açan en büyük neden uzaktan algılama ile elde edilen verilerin detaylarıdır. Bu detaylar görüntülenen bölgenin farklı dalga boylarındaki ışık yansımaları ve yayımlanmasıyla elde edilir. Bu noktada insan gözünün görme yetisinin kısıtlı olması sayısal görüntü işleme tekniklerinin sınıflandırma, nesne/yer belirleme, gürültü giderimi, boyut azaltımı gibi noktalarda devreye girmektedir. Aynı bölgenin farklı dalga boylarında görüntüsünün alınıp bir arada sunulması, multispektral ve hiperspektral görüntü kavramlarını çok bantlı görüntü kavramıyla beraber türetmiştir.

2.2 Çok Bantlı Görüntüler

Çok bantlı olarak bilinen görüntüler pankromatik görüntülerin bir sonraki aşaması olarak kabul edilirler. Bu tip görüntüler, multispektral ve hiperspektral olma üzere iki ana bölümde incelenirler.

2.2.1 Multispektral Görüntüler

Multispektral görüntülemeye, görüntüler Bölüm 2.1’de bahsettiğimiz farklı dalga boylarında görüntülenmiş imgelerden oluşmaktadır. Bu görüntüler arasında görme sınırları ötesindeki dalga boylarından da görüntüler mevcuttur. Bu tip görüntülerin de eklenmesi insan gözünün sahip olduğu kırmızı, yeşil ve mavi alıcılarının yakalayamadığı verileri de kaydetme ve işleme imkanı tanır (Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2003).


Multispektral görüntüler, uzaktan algılama yöntemi ile elde edilen temel görüntülerdir. Işıkdoygun (*panchromatic*) görüntülerin karşıtıdır. Uydular üzerinde multispektral görüntüler için genellikle 3 ila 7 arasında algılayıcı vardır. Bunların her biriyle, görünür dalga boylarından kırmızı ötesi dalga boylarına kadar olan bir aralıkta görüntüler alınabilmektedir.

2.2.2 Hiperspektral Görüntüler

Multispektral görüntülerin, uzaktan algılama ile elde edilmesi aşamasından sonra gelen hiperspektral görüntülerin kaydedilmesi, günümüzün gelişen kamera ve görüntü tarayıcıları ile mümkün hale gelmiştir. Hiperspektral görüntüler, multispektral görüntülere göre çok daha geniş dalga boyu aralığında alınmış görüntülerin bir bütünü şeklindedir. Şekil 2.4’te, bir hiperspektral görüntüye ait spektral bir küp görülmektedir.

Multispektral görüntülerde birkaç farklı dalga boyu kullanılarak görüntü elde edilmesine karşın, hiperspektral görüntülerde dar ve ardışık dalga boylarından yüzlerce görüntü alınır. Bu ölçüm yöntemi, nesnelerin farklı dalga boylarındaki ışığı farklı değerlerde yansıtması özelliği


de göz önüne alındığında imge üzerindeki her bir piksel için devamlı bir spektrumun oluşturulmasını olanaklı kılmaktadır. Şekil 2.5’da hiperspektral imgeyi temsil eden görüntü dizisine ait bir noktanın spektrumu gösterilmiştir. Görüntüyü elde eden alıcılar üzerinde yapılan iyileştirmeler ve geliştirmeler sonucunda, atmosfere ait veya yer şekillerinden dolayı kaynaklanan gürültüler giderilip daha sağlıklı sonuçlar alınabilmektedir.




Şekil 2.4 Bir hiperspektral görüntüye ait spektral küp

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. Hiperspektral algılama, tüm malzemelerin moleküler birleşimlerine bağlı olarak, belirli dalga boylarında farklı örüntülerde 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.

Hiperspektral görüntüler multispektral görüntülere göre Şekil 2.6’da gösterildiği gibi daha çok bant sayısı içermektedir ve dolayısıyla daha iyi sınıflandırma başarımı sağlamaktadır. Multispektral görüntüler farklı türlerin (örneğin orman, su, vs.) sınıflandırılmasında başarılı olmasına rağmen, sınıflandırma kapasitesi, aynı türlerin farklı durumlarının (örneğin ormandaki farklı ağaç çeşitlerinin) tanınmasında oldukça sınırlıdır (Hunt, E.R., Parker-Williams, A. 2004).



Şekil 2.5 Parlaklık değerleriyle elde edilen piksel spektrumu



Şekil 2.6 Multispektral ve hiperspektral verilerinin karşılaştırılması

3. HİPERSPEKTRAL GÖRÜNTÜLERDE BANT AZALTMA

Herhangi bir sınıflandırma mekanizmasının karmaşıklığı girilen verinin sayısına bağlıdır. Bu durum, zaman ve uzam karmaşıklığını belirlediği gibi mekanizmayı eğitmek için gerekli olan eğitim örneği sayısını da belirlemede etkili olur. Bir uygulamada, içindeki verinin kullanılabilir olduğuna inandığımız gözlem verisi giriş verisi olarak alınır ve karar vermede kullanılmak üzere sisteme gönderilir. İdeal olan durum, kullanılan mekanizmanın ayrı olarak herhangi bir özellik seçimi veya özellik çıkarımına gerek duymamasıdır. Mekanizma kendisi için anlamlı olan özellikleri kullanıp, geri kalanları gereksiz olarak ayırabilmelidir. Buna karşın, ayrı bir önışlem adımı olarak boyut azaltımının kullanılmasının bazı sebepleri vardır:

- Karmaşıklık, veri örneğinin boyutuna (N) bağlı olduğu gibi, girişteki boyut sayısına da (d) bağlıdır. Daha az hafıza ve hesaplama yükü için, boyut azaltımı problemlerinin çözümüne ihtiyaç vardır.
- Bir giriş değeri gereksiz olarak kabul gördüğünde, bu verinin hesaplanmasından doğacak hesaplama ve çıkarım yükünden kurtulunur.
- Küçük modeller, küçük veri setlerinde daha sağlam sonuçlar verirler ve daha az değişim gösterirler. Gürültü, aykırı değerler gibi örneğe özel değişikliklerden daha az etkilenirler.
- Bir veri seti daha az özellik ile ifade edildiğinde, verinin temelini oluşturan süreç hakkında daha sağlam fikirlere sahip olunmaktadır.
- Bir veri seti herhangi bir kaybı olmadan, daha az özellik ile ifade edilirse onu görsel olarak izlemek ve analiz etmek kolaylaşmaktadır.

Boyut azaltmada temel olarak kullanılan yöntemler iki başlık altında toplanır: *Özellik seçimi (Feature selection)* ve *özellik çıkarımı (Feature extraction)*. Özellik seçiminde, d boyut içinden veri hakkında bize en fazla bilgiyi verecek olan k adet boyutun bulunması ve geri kalan $(d - k)$ boyutun göz ardı edilmesi temel düşüncüyü temsil eder. *Altküme seçimi*, özellik seçiminde öne çıkan bir yöntemdir. Özellik çıkarımında ise, d boyutun birleşimi şeklinde oluşturulacak ve giriş verisini en iyi şekilde temsil edecek, k boyutlu yeni bir veri setini bulmak temel düşüncedir (Alpaydın E., 2004). Bu yöntemler çıkış verisi kullanılıp kullanılmamasına bağlı olarak *eğitici (supervised)* ve *eğitici (unsupervised)* olarak ayrılmaktadırlar. En iyi bilinen ve en çok kullanılan özellik çıkarım yöntemleri ise *Temel Bileşen Analizi (Principal Component Analysis)* ve *Doğrusal Ayırım Analizi (Linear Discriminant Analysis)* olarak bilinmektedir.

3.1 Özellik Seçimi

Özellik seçimi yöntemlerinden biri olan *altküme seçimi*, özellik kümesi içindeki en iyi altkümenin bulunmasını esas alır. En iyi altküme, başarıyı en fazla olan en az sayıdaki boyutu içerir. Geri kalan göz ardı edilir ve önemsiz olarak kabul görülür. d adet değişken için tanımlı olası 2^d adet altküme bulunmaktadır. d sayısının çok küçük olduğu durumlar hariç, alt kümelerin hepsi test edilmez. Kabul edilebilir zaman içerisinde uygun olan çözümü bulmak için sezgisel yöntemler kullanılmaktadır.

Alt küme seçiminde iki yaklaşım bulunmaktadır: *İleriye dönük seçimde*, elimizde değişken olmadan işleme başlanır ve hatanın en aza indiği noktalarda bu değişkenler eklenir. Herhangi bir ileriye dönük eklemenin hatayı azaltmadığı noktada ise durulmaktadır. *Geriye dönük seçimde* ise, bütün değişkenler alınır ve hatanın en aza indiği noktalarda teker teker silinirler. Herhangi bir ileriye dönük eklemenin hatayı gözle görülür bir şekilde arttırdığı noktada durulur. Her iki durumda da, hataların kontrol edilmesi eğitim setinden farklı bir doğrulama kümesi üzerinden gerçekleştirilmelidir. Çünkü, genelleştirilmiş başarıyı kontrol etmek temel amaçtır. Daha fazla özellik gerektiren durumlarda, genellikle daha düşük eğitim hataları elde ederken, daha az doğrulama hatasına gerek yoktur.

F , giriş boyutları x_i , $i = 1, \dots, d$ olacak şekilde bir özellik kümesi olsun. Bu durumda, $E(F)$, sadece F içindeki giriş değerleri kullanıldığında doğrulama örneği üzerinde elde edilen hatayı temsil eder. Kullanılan uygulamaya göre, hatayı hesaplama yöntemi, ortalama kare hatası ya da yanlış sınıflandırma hatası olabilir.

Ardışık ileriye dönük seçimde, $F = \emptyset$ alınarak özelliksiz başlanır. Her bir adımda, bütün olası x_i için, model eğitilir ve doğrulama kümesindeki $E(F \cup x_i)$ hesaplanır. Daha sonra, Eşitlik 3.1’de görüleceği üzere, en az hataya sahip x_j değeri seçilir.

$$j = \arg \min_i E(F \cup x_i) \quad (3.1)$$

Eğer $E(F \cup x_j) < E(F)$ ise, x_j değeri F kümesine eklenir. Herhangi bir özelliğin E değerini azaltmadığı durumda ise durulmaktadır. Eğer hatadaki düşüş değeri çok küçükse, karmaşıklık ve hatanın önemine, uygulama kısıtlarına göre belirlenen kullanıcı tanımlı bir eşik değerine sahip daha erken bir adımda da durulabilir. Yeni bir özellik eklemek, her zaman özelliğin gözlemlenmesi gerekliliği ile sınıflandırmanın daha karmaşık hale gelmesini de beraberinde getirir (Alpaydın E., 2004).

Bu işlem hesaplama yükü açısından bakıldığında çok iyi bir yöntem değildir. Çünkü, özellik boyutunu d 'den k 'ya indirmek için sistemi $d + (d-1) + (d-2) + \dots + (d-k)$ defa eğitmek ve test etmek gerekir. Bu da $\partial(d^2)$ derecesinde karmaşıklık getirir. Bu yerel bir arama işlemidir ve en küçük hatayı olanaklı kılan, en küçük altkümenin yani en uygun altkümenin bulunmasını garantilemez. Örneğin, x_i ve x_j kendi başlarına iyi olmamakla beraber birlikte hatayı büyük oranda azaltabilirler. Çünkü burada kullanılan algoritma bir anda çalışacak yapıdadır ve özellikleri birer birer ekler. Örnekteki durumu da gözden kaçırabilir. Bunu genelleştirmek ve bütün hesapsal yük göze alınarak tek bir anda bir tane yerine m adet özellik eklenebilir. Ayrıca geriye dönük kontrol yapılarak önceki eklenen özellik kaldırılıp, yerine yenisi eklenebilir. Bu arama alanını genişlettiği gibi karmaşıklığı da artırır.

Ardışık geriye dönük seçimde, F kümesi bütün özellikleri içerecek şekilde başlatılır ve ardışık ileriye dönük seçimde olan ekleme yerine çıkarma yapılarak süreç ilerletilir. Eşitlik 3.2'de görüleceği üzere en az hataya yol açan özellik sistemden çıkarılır.

$$j = \arg \min_i E(F - x_i) \quad (3.2)$$

Eğer $E(F - x_j) < E(F)$ şartı sağlanıyorsa x_j değeri F kümesinden silinir. Özellik silme, hata değerini azaltmıyorsa algoritma durdurulur. Karmaşıklığı azaltmak için izlenen yol, bir özelliğin kaldırılması, hatada artışa yol açıyorsa kaldırılır şeklindedir.

İleriye dönük aramalar için mümkün olan bütün değişkenler, ayrıca geriye dönük arama için de mümkündür. Bir sistemi daha fazla değişken ile eğitmenin daha az değişken ile eğitmeye oranla daha fazla yük getirmesi dışında geriye dönük arama, ileriye dönük arama ile aynı karmaşıklık derecesine sahiptir. Eğer çok miktarda kullanılmayacak özellik bekliyorsak ileriye dönük arama tercih edilmelidir.

Altküme seçimi, çıkış değerleri hata ölçümünde kullanıldığı için eğitimi bir yöntem olarak kabul edilmektedir. Ayrıca, yüz tanıma gibi bir uygulamada, özellik seçimi boyut azaltımı için iyi bir yöntem değildir. Bunu nedeni, piksellerin tek başlarına yeterli miktarda ayrımsal veri içermemeleridir. Örneğin yüz tanımda, yüz kimliğini oluşturan veri, birçok piksel değerinin bir araya gelip anlamlandırılmasıyla elde edilir.

3.2 Özellik Çıkarımı

Uzaktan algılama ile elde edilen hiperspektral imgelerin, normal imgelere göre boyutlarının

büyük olması birçok sınıflandırma yöntemi öncesi veriden bazı temel ve baskın özelliklerin çıkarılması, gürültülerin giderilmesi,vb. yöntemlerin kullanılmasını zorunlu kılar. Özellik çıkarımı yöntemlerinden öne çıkan yöntem, “Temel Bileşen Analizi-TBA” olarak adlandırılan yöntemdir. İmge içerisindeki yüksek bant sayıları, bu yöntem sayesinde verinin niteliğinden ödün vermeden, nicelik kısmından azaltıma gidilerek makul seviyelere indirilip sınıflandırma için hazır hale getirilir.

Özellik çıkarımı yöntemlerinden diğer ikisi *Karar Sınırı Tabanlı Özellik Çıkarımı (Decision Boundary Feature Extraction)* ve *Diskriminant Analiz Özellik Çıkarımı (Discriminant Analysis Feature Extraction)* dır (Hsu P.H., Tseng Y.H., 1999). Bu yöntemlerin göze çarpan özellikleri üzerinde çalıştığı sistemlere aşırı bir yük getirmesi ve sadece az sayıda (genellikle iki) sınıf içeren imgeler için başarımların yüksek olmasıdır. İmge içerisinde bulunan sınıf sayısı arttıkça başarımların buna bağlı olarak da bu yöntemin tercih edilebilirliği düşmektedir.

Dalgacık dönüşümleri (Wavelet transformations), hiperspektral imgeler üzerinde uygulanmış (Mallat, 1989), bu uygulamanın çeşitli sürümleri de farklı yöntemlerin desteklenmesiyle elde edilmiştir. Hiperspektral imgenin içeriğini oluşturan bantların değerlerini kaybetmeden, temel özellikleri ortaya çıkaran ve sınıflandırmaya yönlendiren bir kısım yöntem daha vardır. Parametrelizasyon takibi, alt küme seçimi, bağımsız bileşen analizi bu yöntemlerdendir.

Özellik çıkarımı, hiperspektral imgeler için sınıflandırma öncesi öngörülen bir işlemdir ve birçok noktada zorunluluk olarak kabul edilebilir. İmge verisinin boyutunun küçültülmesi veri üzerindeki kontrolü artırdığı gibi daha kolay ve hızlı işlenmesine de önayak olur.

Bu çalışmada, veri boyutunda azaltımı sağlamak için özellik çıkarımı yöntemi olarak Temel Bileşen Analizi kullanılmıştır.

3.2.1 Temel Bileşen Analizi

İzdüşüm yöntemlerinden biri olan TBA, özgün görüntüdeki d -boyutlu giriş uzayından $k < d$ olmak üzere k -boyutlu bir uzaya, en az veri kaybıyla geçiş yapmayı sağlayan bir haritalama kullanır. $\mathbf{x}$ vektörüne ait $\mathbf{w}$ yönündeki izdüşümü Eşitlik 3.3'teki gibidir.

$$\mathbf{z} = \mathbf{w}^T \mathbf{x} \quad (3.3)$$

TBA, çıkış bilgisini kullanmayan eğitici-siz bir yöntemdir. Buradaki tek ölçüt, varyansın (karşıtlığın) enbüyüklenmesidir (Alpaydın E., 2004). Bu aşamada, bazı istatistik terimlerinin

açıklanması gerekmektedir (Smith L.I., 2002).

Standart sapma

Standart sapmayı anlayabilmek için bir örnekle açıklamak daha etkili bir yol olarak kabul edilir. Öncelikle standart sapma için bir adet veri kümesi gerekmektedir. Veri kümemiz $X = [1\ 2\ 5\ 7\ 9\ 10\ 11\ 14\ 15\ 20]$ şeklinde olsun.

X , veri kümesinin tamamını ifade ederken X_i bu küme içindeki i . elemanı, n de küme içerisindeki eleman sayısını göstermektedir. Bu kümeyi kullanarak hesaplanabilecek birçok değer vardır. Bunlardan biri örneklemin ortalamasının hesaplanmasıdır. Küme içerisindeki elemanların değerlerinin toplanarak eleman sayısına bölünmesi yoluyla Eşitlik 3.4'teki gibi hesaplanır.

$$\bar{X} = \frac{\sum_{i=1}^N X_i}{n} \quad (3.4)$$

Ancak, ortalama bir küme içerisindeki elemanların değerleri hakkında yeterli bilgiyi bize sağlamamaktadır. Zira, iki farklı kümenin ortalaması aynı olabilir. Bu yüzden bir kümenin içindeki eleman dağılımı ifade edilirken standart sapma kavramı kullanılır. Standart sapma, küme içerisindeki noktaların küme ortalamasına olan ortalama uzaklıklarıdır. Bunu hesaplamanın yolu ise, Eşitlik 3.5'te görüleceği üzere, her noktanın küme ortalamasına olan uzaklığının karelerinin bulunup toplanması ve kümedeki eleman sayısının bir eksiğine bölünerek karekökünün alınmasıdır.

Çizelge 3.1 (a) $X=[0\ 8\ 12\ 20]$ kümesi için standart sapma hesaplanması. (b) $X=[8\ 9\ 11\ 12]$ kümesi için standart sapma hesaplanması

X	$X - \bar{X}$	$(X - \bar{X})^2$	X	$X - \bar{X}$	$(X - \bar{X})^2$
0	-10	100	8	-2	4
8	-2	4	9	-1	1
12	2	4	11	1	1
20	10	100	12	2	4
Toplam		208	Toplam		10
(n-1) bölümü		69.333	(n-1) bölümü		3.333
Karekökü		8.3266	Karekökü		1.8257

(a)

(b)

Standart sapma hesaplaması ortalamaları aynı ve 10 olan iki farklı veri kümesi için Çizelge

3.1’de hesaplanmıştır.

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \quad (3.5)$$

Eğer kümemiz $X=[10 \ 10 \ 10 \ 10]$ şeklinde bir küme olsaydı buradaki standart sapma değeri, bütün elemanlar ortalama değeriyle aynı olduğundan 0 olacaktır.

Varyans

Varyans, bir küme içerisindeki dağılımın hesaplanması için kullanılan bir başka değerdir. Standart sapma ile neredeyse aynıdır. Eşitlik 3.6’da varyans hesaplanması için kullanılan formül verilmiştir.

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)} \quad (3.6)$$

Görüleceği üzere, varyans standart sapmanın karesi şeklinde ifade edilir. s^2 varyans için kullanılan genel bir ifadedir. İki değer de, veri kümesi içindeki dağılımın hesaplanması için kullanılan ölçüm değerleridir (Smith L.I., 2002).

Kovaryans

Bundan önce ele aldığımız standart sapma ve varyans ölçümleri tek boyutlu ölçümler için kullanılan ölçüm değerleridir. Standart sapma ve varyans tek boyutlu olduklarından veri kümesinin her bir boyutu için diğer boyutlarından bağımsız olarak ölçüm yapmaktadırlar. Ancak, birçok veri kümesi birden fazla boyuta sahip olup, amaç olarak da istatistiksel olarak boyutlar arasında bir ilişkinin var olup olmadığının belirlenmesi ele alınabilir. Bu tip veri kümelerinde farklı boyutlardaki verilerin diğer boyutlara göre ne kadar değiştiğinin belirlenmesi önemli olabilmektedir.

Kovaryans, iki boyut arasında ölçüm yapabilen bir yöntemdir. Bir boyutun kendisi ile kovaryansının hesaplanması, varyans ölçüm değeriyle aynı anlamdadır. Eğer (x, y, z) gibi 3-boyutlu bir kümemiz varsa, $cov(x, y)$, $cov(x, z)$ ve $cov(y, z)$ hesaplanmaktadır. Örneğin $cov(x, x)$ değeri x ’in varyansına eşittir.

Varyans formülü Eşitlik 3.7’deki gibi de yazılabilmektedir.

$$\text{var}(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})}{(n-1)} \quad (3.7)$$

Varyans denklemindeki kare değeri açılarak yazılabilir. Buradan da iki boyutlu kümeye ait kovaryans denklemine Eşitlik 3.8'deki gibi ulaşılabilir.

$$\text{cov}(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)} \quad (3.8)$$

Kovaryansta önemli olan elde edilen değerden daha çok, elde edilen değerın işaretidir. Eksi ya da artı olmasına göre farklı değerlendirmeler yapılmaktadır. Eğer kovaryans değeri artı ise, bu iki değerin iki boyutta da beraber arttıklarını göstermektedir. Değer eksi ise boyutlardan birinde azalmanın, diğerinde de artmanın olduğunu gösterir. Son durumda ise kovaryans değeri sıfır olabilir. Bu da iki boyutun birbirlerine göre tamamen bağımsız olduğunu gösterir.

Çarpma işlemi sırabagımsız olduğundan dolayı da kovaryans işlemi ile aynı özelliktedir. Eşitlik 3.9'daki eşitlik işlemin özelliğinin sonucudur.

$$\text{cov}(X, Y) = \text{cov}(Y, X) \quad (3.9)$$

Kovaryans Matrisi

Kovaryans hesaplaması her zaman iki boyut arasında gerçekleştirilmektedir. Eğer ikiden fazla boyuta sahip bir veri kümemiz varsa, birden fazla kovaryansımız var demektir. Daha önce de belirtildiği üzere; 3-boyutlu bir kümemiz varsa, $\text{cov}(x, y)$, $\text{cov}(x, z)$ ve $\text{cov}(y, z)$ hesaplanabilecek olası kovaryans değerleridir. Buradan çıkarılabilecek sonuç, n -boyutlu veri

kümesi için $\frac{n!}{(n-2)! \cdot 2}$ adet farklı kovaryans değeri hesaplanabilir.

Böyle bir durumda, kovaryans değerlerini göstermenin ve ifade etmenin en iyi yolu kovaryansları bir matrisin içinde belirtmektir (Smith L.I., 2002). n -boyutlu bir veri kümesi için kovaryans matrisi Eşitlik 3.10'daki gibi tanımlanabilir.

$$C^{n \times n} = (c_{i,j}, c_{i,j} = \text{cov}(\text{Dim}_i, \text{Dim}_j)) \quad (3.10)$$

Bu eşitlikten de anlaşılacağı üzere, n -boyutlu bir veri kümesi için tanımlanan kovaryans matrisi $n \times n$ boyutlarındadır. Bunu 3-boyutlu veri kümesi örneği ile açıklayabiliriz. x , y ve z olmak üzere 3 boyuta sahip bir veri kümesinin kovaryans matrisi Eşitlik 3.11'deki gibidir.

$$C = \begin{pmatrix} \text{cov}(x, x) & \text{cov}(x, y) & \text{cov}(x, z) \\ \text{cov}(y, x) & \text{cov}(y, y) & \text{cov}(y, z) \\ \text{cov}(z, x) & \text{cov}(z, y) & \text{cov}(z, z) \end{pmatrix} \quad (3.11)$$

Kovaryans işleminin sırabagimsız olduğundan dolayı, matris simetriktir. Ayrıca, matrisin diagonal köşegenini oluşturan kovaryans değerleri de boyutların kendi içlerindeki kovaryans değerleridir. Diğer bir deyişle, o boyutlardaki varyans değerleridir.

Özvektörler ve Özdeğerler

$n \times n$ boyutlu bir kare matris için tanımlanan özvektör değeri, Eşitlik 3.12’de verilen eşitliği sağlamak durumundadır.

$$\mathbf{Ax} = l \mathbf{x} \quad (3.12)$$

Eğer sıfırdan farklı bir $\mathbf{x}$ vektörü varsa l sayısı da $\mathbf{A}$ matrisinin özdeğeri olarak kabul edilir. $\mathbf{x}$ vektörü de l için tanımlanan özvektör olarak ifade edilir. Bir matris için tanımlanan özdeğer ve özvektörlerin hesaplanması için Eşitlik 3.12’den elde edilen denklem çözümüne ihtiyaç duyulmaktadır. Eşitlik 3.13’te yukarıdaki denklemden elde edilen bir eşitlik görülmektedir.

$$(\mathbf{A} - l \mathbf{I})\mathbf{x} = 0 \quad (3.13)$$

$\mathbf{I}$ matrisi $n \times n$ için tanımlı birim matristir. Sıfırdan farklı $\mathbf{x}$ vektör değerleri için $(\mathbf{A} - l \mathbf{I})$ değerinin tersi tanımlı olmamalıdır. Tersinin tanımlı olduğu durumda Eşitlik 3.15’te elde edilen sonuç ortaya çıkar. Bu da özvektörün sıfır olması anlamı gelir

$$(\mathbf{A} - l \mathbf{I})^{-1}(\mathbf{A} - l \mathbf{I})\mathbf{x} = (\mathbf{A} - l \mathbf{I})^{-1}0 \quad (3.14)$$

$$\mathbf{x} = 0 \quad (3.15)$$

Özvektörün sıfır olmadığı durumda, eşitliği sağlayacak olan kısım $(\mathbf{A} - l \mathbf{I})$ ’dir. Bu kısmın determinantının sıfır olması gerekmektedir. Eşitlik 3.16’da belirtilen eşitliğe $\mathbf{A}$ matrisinin özellik polinomu denmektedir.

$$p(l) = \det(\mathbf{A} - l \mathbf{I}) \quad (3.16)$$

Özellik polinomunun kökleri, $\mathbf{A}$ kare matrisi için tanımlı olan özdeğerleri vermektedir (Akça, M.,D., Doğan, S., 2002). Bu özdeğerlere uyan özvektörlerin hesaplanması ise doğrusal denklem sistemine ait Eşitlik 3.13’ün çözülmesi ile bulunmaktadır.

Özdeğer ve özvektör hesaplanmasına yönelik bir örnek aşağıdaki iki boyutlu $\mathbf{A}$ matrisi için

hesaplanmıştır. $\mathbf{A} = \begin{pmatrix} 2 & -4 \\ -1 & -1 \end{pmatrix}$ matrisi içinde Eşitlik 3.17’de özellik polinomu ve çözümü verilmiştir.

$$\begin{aligned} p(l) &= \det \begin{bmatrix} 2-l & -4 \\ -1 & -1-l \end{bmatrix} \\ &= (2-l)(-1-l) - (-4)(-1) \\ &= l^2 - l - 6 \\ &= (l-3)(l+2) \end{aligned} \quad (3.17)$$

$l_1=3$ ve $l_2 = -2$ değerleri $\mathbf{A}$ matrisi için geçerli olan özdeğerlerdir. Bu matrise ait özvektörlerin hesaplanması ise Eşitlik 3.14’ten yola çıkılarak yapılmaktadır. $l_1=3$ için uygun özvektörü $\mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix}$ olarak tanımlayalım. Bu durumda Eşitlik 3.18’deki eşitliğe ulaşılabacaktır.

$$\begin{bmatrix} 2-3 & -4 \\ -1 & -1-3 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (3.18)$$

Eşitlik 3.18’deki eşitlik ile iki bilinmeyenli ikili bir denklem elde edilir

$$\begin{aligned} -v_1 - 4v_2 &= 0 \\ -v_1 - 4v_2 &= 0 \end{aligned} \quad (3.19)$$

Eşitlik 3.19’daki ikili denklemden elde edilen v_1 ve v_2 değerleri ile $\mathbf{v}$ vektörü $l_1=3$ için hesaplanır. $\mathbf{v} = \begin{bmatrix} -4 \\ 1 \end{bmatrix}$ vektörü, yukarıdaki denklem için tek çözüm olmaması, bu vektörün sabit değerlerle çarpılarak çoğaltılabilmesi, bu vektörün, özvektörlerin taban vektörü olarak tanımlanmasına yol açar.

Özdeğerler çözüm kümesinin diğer elemanı olan $l_2 = -2$ için özvektör değerinin bulunması da benzer yolla gerçekleştirilir. l_2 için elde edilen iki bilinmeyenli ikili denklemler Eşitlik 3.20’de gösterilmiştir.

$$\begin{aligned} 4v_1 - 4v_2 &= 0 \\ -v_1 + v_2 &= 0 \end{aligned} \quad (3.20)$$

Bu eşitlik sisteminin çözümü, v_1 ve v_2 değerlerinin eşit olduğu durumdadır. Buradan da

$\mathbf{v} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ özvektör taban tanımlamasına ulaşılmaktadır. $l_2 = -2$ özdeğeri için özvektörler bu özvektör tabanından türetilir.

Çok değişkenli verilerin analizinde, bütüncül istatistiki sonuçlar elde etmenin yanısıra çok değişkenli veri yapısını tanımlama yöntemleri de vardır. TBA bu yöntemlerden biridir. TBA bazı koşullar altında, ilintili değişkenlere doğrusal dönüşüm uygulayan bir yöntemdir. Koşullardan en dikkat edilmesi gereken, dönüşüm sonrasında değişkenler arasında ilinti bulunmamasıdır. Bu şarttan yola çıkarak, TBA, birbirleri arasında yüksek ilinti bulunan çok değişkenli veri kümelerinin, ilintinin olmadığı yeni bir koordinat eksenine dönüştürülmesi işlemidir. Sayısal görüntülerde yapılan TBA dönüşümleri görüntülerin sahip olduğu radyometrik yapı üzerinde istatistiksel bir dönüşümdür (Alpaydın E., 2004).

Bu çalışmada TBA, hiperspektral görüntülerde, veri kümesindeki bilginin niteliğini bozmadan niceliğinde azaltma, diğer bir deyişle bant azaltma işlemi için kullanılmıştır.

Bantlararası İlinti

Hiperspektral görüntülerde yüksek sayıda bulunan bantlar arasındaki ilinti çok yüksektir. Örneğin, uzaktan algılama ile elde edilmiş bir yeryüzü görüntüsündeki bitki örtüsüne ait bir piksel değeri için, görünür kırmızı bant ile yakın kızılötesi bant arasında eksi ilinti bulunurken, görünür yeşil bant ve görünür mavi banttaki piksel değerleri arasında artı ilinti bulunur. Bantlar arasında yüksek ilinti bulunması piksel değerleri için ihtiyaç fazlası veri olduğu anlamına gelir. Çünkü, bir piksele ait veri için birçok bantta çok yaklaşık yansıma değerleri elde edilir. Kısacası veri tekrarlanır.


İki değişken arasındaki ilinti, bir katsayıyla ifade edilir. Bu katsayı, değişkenler arasındaki kovaryansın, değişkenlerin standart sapmalarının çarpımlarıyla Eşitlik 3.21'deki gibi elde edilir.

$$r_{X,Y} = \frac{\text{cov}(X,Y)}{\text{cov}(X,X) \cdot \text{cov}(Y,Y)} \quad (3.21)$$

İlinti katsayısının değeri $[-1, +1]$ kapalı aralığında değişmektedir. İki değişkenin birbirinden bağımsız olması durumunda, sözü edilen katsayı sıfıra yakın bir değer almaktadır. Katsayı değerinin $+1$ 'e yakın olması iki değişkene ait verilerin arasında yüksek ilinti olduğunu ve bir değişken için ortalamanın üstünde olan değerlerin diğer değişkende de karşılığı olduğunu göstermektedir. Diğer bir deyişle, değişkenlerden biri artarken diğeri de artmakta, azalırken

de azalmaktadır. Katsayının -1'e yakın olması, bu durumun benzer ama zıt yönde olduğunu gösterir. Değişkenler birbirlerine bağımlıdır ve ancak biri artarken diğeri azalmaktadır.

İlinti katsayısının mutlak değerinin 1 olması, değişkenler arasında $Y = aX + b$ şeklinde doğrusal bir fonksiyonun varlığını gösterir. Değişkenler arasında bağımlılığın fonksiyona dayalı olması ama doğrusal olmaması durumunda bu değer 1'den uzaklaşıp 0'a yaklaşır.



Şekil 3.1 (a) 3 bantlı bir görüntüden bir piksele ait değerlerin alınması, (b) piksellerin koordinat ekseninde gösterilmesi (Akça, M.,D., Doğan, S., 2002)

Şekil 3.1.(a)'da RGB 3 bantlı bir görüntüye ait piksel şeması gösterilmektedir. Şekil 3.1.(b)'de bu şekilden elde edilen pikseller 3-boyutlu uzayda gösterilmiştir. Piksel değerlerinin birbirlerine çok yakın olduğu varsayılp, elips şeklinde gösterilmektedir.


Şekil 3.1.(b)'e ait görüntünün kovaryans matrisi Eşitlik 3.22'deki gibi ifade edilebilmektedir.

$$C_x = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \quad (3.22)$$

Bantlar arasında yüksek ilintinin bulunduğu durumlarda C_x matrisinin köşegenlerinde yer alan değerler diğer yerlerdeki verilerden daha büyük olacaktır. TBA'da gerçekleşen durum, kovaryans matrisindeki değerlere bir dönüşüm uygulanarak, verilerin matrisin köşegeninde yoğunlaştığı başka bir uzaya taşınmasıdır.

TBA'daki problem, Şekil 3.2'de gösterilen piksellerin (x_1, x_2, x_3) koordinat ekseninden (y_1, y_2, y_3) koordinat eksenine olan dönüşüm problemidir. Bu dönüşümde eksenler arasındaki katsayı birdir ve öteleme olmadan elde edilir. Eksenler arasındaki diklik koşulları

korunacağından dönüşüm matrisi ortogonal bir matris olacaktır. Veriler arasındaki ilintinin yok edilmesi temel amaç olduğundan, yeni eksenler ile elipsin sahip olduğu eksenler birbirlerine paralel olacaklardır. Oluşan yeni eksenlerde piksellerin en geniş aralıkta ifade edildiği eksen birinci özvektör, aralık değeri de özdeğer olacaktır. Eksen aralıklarının büyükten küçüğe doğru sıralanması özvektörlerin büyükten küçüğe doğru sıralanmasını sağlar. En büyük aralıklara sahip yani en büyük özdeğerlere sahip, özvektörler görüntünün ana bileşenlerini oluşturur. Hiperspektral görüntülerde bu bileşenlerin ilk birkaç bantta yoğunlaştığı görülmektedir. Bu yüzden bütün görüntüyü ifade etmek için dönüştürülmüş koordinat ekseninde birkaç eksen yeterli olmaktadır.



Şekil 3.2 (x_1, x_2, x_3) uzayında tanımlı 3 boyutlu görüntüye ait piksellerin (y_1, y_2, y_3) uzayına olan dönüşümü (Akça, M.,D., Doğan, S., 2002)

TBA'daki temel problem G dönüşüm matrisinin bulunmasıdır. Eşitlik 3.23'de koordinat eksenleri ve G arasındaki ilişki gösterilmektedir.

$$y = G \cdot x \quad (3.23)$$

Dönüşümden sonraki amaç, veriler arasındaki ilintinin sıfırlanması olduğundan, y koordinat eksenine ait kovaryans matrisi köşegen olmalı ve köşegen haricindeki bütün değerler sıfır olmalıdır.

$$C_Y = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})(Y_i - \bar{Y})^T \quad (3.24)$$

$\bar{Y}$, y eksenindeki verilerin ortalama değeri olduğundan Eşitlik 3.23'ye dayanarak

$\bar{Y} = G \cdot \bar{X}$ olarak ifade edilmektedir. Ortalama değerlerin bu ifadesi ve Eşitlik 3.24 kullanılarak Eşitlik 3.25 elde edilir.

$$\begin{aligned}
 C_y &= \frac{1}{n-1} \sum_{i=1}^n (GX_i - G\bar{X})(GX_i - G\bar{X})^T \\
 C_y &= \frac{1}{n-1} \sum_{i=1}^n G(X_i - \bar{X})[G(X_i - \bar{X})]^T \\
 C_y &= G \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T G^T \\
 C_y &= GC_x G^T
 \end{aligned} \tag{3.25}$$

C_y matrisi tanımı gereği köşegen bir matris olacaktır. Köşegendeki değerlerde veri kümesinin dönüştürüldüğü uzaydaki varyans değerleri, diğer bir deyişle özdeğerleri olacaktır. G matrisi ortogononal bir matris olduğundan tersi evriğine eşittir. Bu özelliği de kullanarak Eşitlik 3.26'yı elde edebiliriz.

$$C_x G^T = G^T C_y \tag{3.26}$$

TBA, temelde bir lineer cebir problemi olup, bilinmeyen G matrisidir (Akça, M.,D., Doğan, S., 2002). Bu matris de C_x matrisinin özdeğerleri ve özvektörleri hesaplandıktan sonra bulunur.

4. MATEMATİKSEL BİÇİMBİLİM

Matematiksel biçimbilim, sayısal imgeler içinde bulunan gerekli parçaları ortaya çıkarmak ve bunların tanımlanmasını sağlamak için kullanılan kuramsal bir modeldir. Bu model, “lattice kuramı-kafes kuramı”ndan ve topoloji kavramından yola çıkarak şekillendirilmiştir (Serra J., 1982). 1960'larda Georger Matheron tarafından temellendirilmiş, Serra tarafından da kuramının kendisi tanımlanmıştır.

Kuramın ortaya atıldığı ilk zamanlar, ikili imgeler üzerinde çalışılmış, daha sonraki aşamalarda 256 renk içeren gri seviyeli imgeler ve farklı renk uzaylarına sahip renkli imgeler üzerinde de çalışılmıştır.

Matematiksel biçimbilim imge içerisindeki şekillerde *kenar belirleme (edge detection)*, *inceltme (thinning)*, *budama (pruning)*, imgede gürültü azaltımı (Ortiz F., Torres F., Gil P., 2004) gibi işlemlerin gerçekleştirilmesinde kullanılmaktadır.

Biçimbilim kuramını oluşturan birimlerin arasında temel iki işlem ve bu işlemlerde temel olarak kullanılan bir adet değişken vardır.

4.1 Temel Biçimbilimsel Birimler

Biçimbilimsel işlemler temel olarak birbirine çok benzeyen iki işlemden oluşur. *Aşınma (erosion)* ve *genişleme (dilation)* olarak adlandırılan bu iki işlemden yola çıkarak, biçimbilimde kullanılan diğer bütün işlemler ifade edilebilir.

Bu işlemlerde kullanılan değişken birim ise yapısal elemandır (*structuring element*).


4.1.1 Yapısal Eleman

Kullanılan imgelerde temel işlemlerin uygulanacağı piksel gruplarını belirlemek için kullanılan kuramsal yapılardır. İmge içerisindeki şekilleri bulan, piksellerden oluşan geometrik bir örüntü şemasıdır (Lybanon M., 1995).

Yapılan çalışmalarda, uygulanan yapısal elemanın işlemlerin sonuçlarına doğrudan etkisi olduğu bilinmektedir. Yapısal elemanın boyut ve şekli sonuçların olumlu yönde geliştiği durumlarda değiştirilebilir. Bu eleman, imge üzerinde piksellerin gruplanmasını sağlayacak bir maske yapısında düşünülebilir. Genel olarak, yapısal eleman da bir imge olarak tasarlanabilir ve imge üzerinde piksel piksel ilerletilen bir maske şeklinde ifade edilir.

Yapısal eleman, pikseller arasındaki komşuluk ilişkisini öne çıkardığından dolayı, imgelerin

sahip olduğu uzamsal verinin kullanılması, değerlendirilmesi ve istikrarlı sonuçlara ulaşılması açısından önemlidir. Özellikle, imge içerisinde aranılan ya da özellikleri ortaya çıkarılmak istenen nesnelerin sahip olduğu şekillerin bilinmesi durumunda iyi sonuçlara ulaşılır. Diğer yandan, bu tarz çalışmalarda aranılan veriye ait şekillerin bilinmesi pek de sık rastlanan bir durum değildir. Bu durumda genellikle yapısal eleman dairesel veya dörtgen şekline seçilmektedir. Yapısal elemanlar herhangi bir şekilde, boyutta ve bağlantı da olabilirler. Tek parça olmak zorunda da değildirler. Yapısal eleman şekline ait bazı örnekler Şekil 4.1’de görülmektedir.



Şekil 4.1 Yapısal eleman örnekleri. (a) Z8, (b) Z4, (c) disk, (d) 2x3 dikdörtgen, (e) kaydırma

Yapısal eleman da önemli kısım, piksel kümesi içinde merkez olarak belirlenen piksel ve gruplamayı sağlayan şekildir. Yapısal elemanın şekli genellikle merkezi, şekillerin ağırlık merkezi olacak şekilde dikdörtgen, kare veya daire olarak alınır. Merkez noktası, yapılan işlemlerden sonra grubu temsil edecek olan pikseldir. Bu durum, merkez piksel seçilmesini de son derece önemli kılmaktadır.

4.1.2 Aşınma

Aşınma, genel tanımı itibariye yapısal elemanın şekil olarak uyduğu yerlerin ortaya çıkarılmasını sağlamaktadır.

Aşınma işlemi, bir küme içindeki elemanların en küçüğünün seçilip merkez pikselin değeri olarak atanması şeklinde ifade edilebilir. Buradaki küme ifadesi biçimbilimsel açıdan incelendiğinde yapısal eleman içine dahil olan pikseller kümesidir. Aşınma, en küçük elemanın değerlendirilmesi olarak kabul edilmektedir.

A değerinin imge, B değerinin yapısal eleman olarak kabul edildiği durumda, aşınma Eşitlik 4.1 ile ifade edilebilir.


$$A \ominus B = \left\{ z \mid (B)_z \subseteq A \right\} = \bigcap_{x \in B} A_x \quad (4.1)$$

Diğer yandan, yapılan çalışmaların gri seviyeli imgeler üzerinden geliştirilmesi iki boyutlu uzay içinde bir aşınma işlemi olarak tanımlanmıştır. İki boyutlu için yapılan değerlendirmede, tek boyutta tanımlanan kesişim işleci, iki boyutlu uzayda enküçükleme işlemine dönüşmüştür. Aşınma işleminin iki boyutlu uzaydaki matematiksel ifadesi Eşitlik 4.2 ile gösterilmektedir. Burada f , kesikli Z^2 uzayında gri seviyeli imge; B , Z^2 tarafından kapsanacak şekilde yapısal eleman olarak gösterilmektedir. $Z^2(B)$, B tarafından tanımlanmış komşuluk ilişkisi içinde bulunan piksellere atanmış uzamsal koordinatlar toplamını belirtmektedir (Plaz A., Martinez, P., Plaza, J., Perez R., 2005).

$$(f \ominus B)(x, y) = \Lambda_{(s,t) \in Z^2(B)} f(x+s, y+t) \quad x, y \in Z^2 \quad (4.2)$$


Uygulama tarafında, Bölüm 4'ün başında belirtmiş olduğumuz üzere, merkez piksel değerine yapısal eleman içinde komşuluk ilişkisi ile tanımlanmış piksel değerleri arasında en küçük olan değer seçilip merkez pikselin yeni değeri olarak atanır. Yapısal elemanın her piksel ile komşuluk ilişkisine bakıldıktan sonra ikili resimlerde şekil içeren yapının küçülmesi ve arkaplanın baskın hale gelmesi olarak görünür.

İmge ve yapısal elemanın aşındırma işleminin giriş değerleri olarak alındığı durumda Şekil 4.2'deki arkaplan baskınlığının arttığı, ön planda bulunan nesnenin ise kendi yapısında aşınmaya gittiği gözlenmektedir.



Şekil 4.2 Aşındırma işlemi

Aşınma işleminde, yapısal elemanın önplanda duran nesnenin iç tarafından yaklaşacak şekilde arkaplan ile temas ettiği noktalar sınır kabul edilerek, nesneden arkaplana katılırlar. Şekil 4.3'te kırmızı olarak belirtilen dairesel bir yapısal elemanın iki renkten oluşan bir imge üzerinde aşındırma işleminin uygulanışı gösterilmiştir.



Şekil 4.3 (a) İkili imge (b) Kırmızı alanlar : Dairesel yapısal alan. Mavi alan : Aşınmadan etkilenmeyen arkaplan. Beyaz alan : Aşınmadan etkilenen, önplandaki nesneden arkaplana dahil olacak piksel grubu (c) İmgenin genişlemeden sonraki hali

4.1.3 Genişleme

Aşınma işleminin tersine, genişleme işlemi imge içindeki nesnelerle kesiştiği yerlerin ortaya çıkarılmasını sağlar. Genişleme işlemi, aşınmayla aynı mantığa sahip, fakat tam zıt yönde çalışmaktadır. Aşınmanın grup değerler içinde en küçüğe yoğunlaştığı noktada genişleme, bu değerler içindeki en büyük değeri merkez değer olarak kabul eder. Genişleme işleminin tek boyutlu veriler için ifadesi Eşitlik 4.4'teki gibi tanımlanmaktadır.


$$A \oplus B = \left\{ z \mid (\hat{B})_z \cap A \neq \emptyset \right\} = \bigcup_{x \in B} A_x \quad (4.4)$$

A, resmi; B, yapısal elemanı ifade ederken $\hat{B}$, Z kümesi çerçevesinde B yapısal elemanın 1'e tümleyen kümesini verir. Burada kullanılan birleşim işlemi, aşınmadaki enküçükleme işlemine dönüşün tam tersi olarak, enbüyükleme işlemine dönüşmektedir. Genişlemenin Z^2 kümesindeki ifadesi Eşitlik 4.5 ile gösterilmektedir (Plaza A., Martinez P., Plaza J., Perez R., 2005).

$$(f \oplus B)(x, y) = \bigvee_{(s, t) \in Z^2(B)} f(x - s, y - t) \quad x, y \in Z^2 \quad (4.5)$$


Eşitlik 4.5'teki ifade aşınma denklemi ile büyük benzerlikler gösterir. Enküçükleme-enbüyükleme zıtlığının dışında yapılan işlemlerin, pikseller üzerindeki değişikliklerin mantığı aşınma ile aynıdır.

Şekil 4.4, genişleme işleminin önplan kabul edilen nesneye olan etkisini göstermektedir.



Şekil 4.4 Genişleme işlemi

Yapısal eleman içinde meydana getirilen piksel komşuluk değerlerinin enbüyüklemesi sonucunda ikili imgelerde nesne olarak kabul edilen birimler, imge üzerinde daha fazla yer almaya başlarken bununla ters orantılı olmak üzere arkaplana dahil olan piksellerde azalma gözlemlenmektedir. Şekil 4.5'te, nesneye arkaplan üzerinde yaklaşan yapısal elemanın nesneye ne tür bir katılım sağlayarak genişlemesine yol açtığı gözlemlenmektedir.




Şekil 4.5 (a) İkili imge (b) Kırmızı alanlar : Dairesel yapısal alan. Mavi alan : Genişlemeden etkilenmeyen arkaplan. Beyaz alan : Genişlemeden etkilenen, arkaplandan önplandaki nesneye dahil olacak piksel grubu (c) İmgenin genişlemeden sonraki hali

Bu açıdan bakıldığında, aşındırma; imge içinde önplan nesnesinin aşınması olurken aynı anda arkaplanın genişlemesi olmaktadır. Genişlemede ise, bu işleme ismini verdiği nokta itibari ile, önplan kabul edilen nesne genişlerken, arkaplan olarak kabul edilen kısım aşınmaktadır.

Şekil 4.6'da genişleme yönteminin kullanıldığı bir örnek görüyoruz. Birçok karakterleri arasındaki bağlantılar kopmuş olan bir metin belgesinin taranmış imgesinde genişleme

yöntemi kullanılarak harflerin daha belirgin ve karakter içi oluşumlarının sürekli olması sağlanarak kopukluklar ortadan kaldırılmıştır.



Şekil 4.6 OCR taraması sonucunda elde edilen örnek imge- kullanılan yapısal eleman ve genişleme sonrası sonuç resmi

4.2 Gelişmiş Biçimbilimsel İşlemler

Matematiksel biçimbilim içinde tanımlanmış bütün diğer işlemler yukarıda belirtmiş olduğumuz iki temel işlem sayesinde gerçekleştirilmektedir. Aşınma ve genişlemeden elde edilen diğer işlemlerin sonuçlarında bölümün giriş kısmında bahsetmiş olduğumuz iskelet çıkarma, kenar belirleme, vb. karmaşık işlemler elde edilmektedir.


4.2.1 Açma

Aşınma ve genişleme işlemlerinin türevleri olarak doğan iki temel işlemten biri olan *açma* (*opening*), aşınma uygulanmış bir giriş imgesine, aynı yapısal eleman ile genişleme uygulanmasıdır (Plaza A., Martinez P., Plaza J., Perez R., 2005). Açma işleminin, giriş değerleri temel olarak kullandığı işlemler ile aynı olup, açma işlemi uygulanacak bir imge ve bu işlemi uygulayacak olan yapısal elemandır.

$$A \circ B = (A \ominus B) \oplus B \quad (4.6)$$


Açma işleminin temel etkisi, aşınmanın bir türüdür. Önplanı oluşturan piksel grubunu kenarlarındaki önplan piksellerinin arka plana dahil olmasını sağlar. Önplan nesnesi açısından bakıldığında, normal aşındırma işleminden çok daha az yıkıcı etkisi vardır.

Eşitlik 4.6’da da görüleceği üzere açma işlemi iki temel işlemin birleşimi olarak da düşünülebilir. Aşınma ile önplan nesnesinden arkaplana aktarılan piksellerin bir kısmı, genişleme ile tekrar nesneye kazandırılmaktadır. Önplan nesnesinde gürültü olarak kabul edilebilecek piksellerin aşınma ile giderilmesi, bunun yanında diğer bütün bölgeleri de etkileyerek istem dışı veri kayıplarına da sebep olmaktadır. Açma işleminin ikinci aşaması olan genişleme kaybedilen bu piksellerin geri kazanımını hedeflemektedir.



Şekil 4.7 3x3 boyutlarındaki bir yapısal eleman ile gerçekleştirilen açma işlemi


Şekil 4.7’de giriş imgesi verilen bir açma işleminin 3x3 boyutlarındaki yapısal eleman ile elde ettiği sonuç imgesi gösterilmiştir.



Şekil 4.8 (a) İkili resim (b) mavi : arkaplan, beyaz : önplan, kırmızı : yapısal eleman (c) açma sonucu

Aşınma ve genişleme işlemlerindekinin tersine, açma işleminde seçilen yapısal elemanın merkezinin sonuç üzerinde doğrudan bir etkisi bulunmamaktadır. Bu noktada önemli olan noktanın kullanılan yapısal elemanın şekli olduğu göze çarpmaktadır. Şekil 4.9’da kullanılan

11 piksel çapında ve disk yapısına sahip yapısal elemanın önplan nesnesinde düzgün olarak sadece daire yapısına dahil olan pikselleri koruduğu, geri kalanını ise arka plana dahil ederek görüntüden çıkardığı görülmektedir.



Şekil 4.9 11 piksel çaplı disk şeklindeki bir yapısal eleman ile açma işleminin çalışması

4.2.2 Kapama


Şu ana kadar ele alınan işlemlerde olduğu gibi *kapama (closing)* işlemi de aşınma ve genişleme ile doğrudan ilgilidir. İşlemin kullandığı parametreler birebir aynı olup, kapama uygulanacak bir adet imge ve kapamayı gerçekleştirecek olan yapısal elemandır.

Aşınma ve genişleme arasında bulunan zıtlık ilişkisi, türetilen işlemler olan açma ve kapamada da görülmektedir. Kapama işlemi, genişleme uygulanmış bir imgeye aşındırma uygulanması şeklinde ifade edilir (Plaza A., Martinez P., Plaza J., Perez R., 2005). A imge ve B yapısal eleman olmak üzere, Eşitlik 4.7’de ifade edilen işlem sırası kapama işlemini tanımlar.

$$A \bullet B = (A \oplus B) \ominus B \quad (4.7)$$


Eşitlik 4.7’den de anlaşılacağı üzere, kapama işlemini de tanımlamak için aşınma ve genişleme işlemleri yeterli olmaktadır. Kapama, temel olarak genişleme ile önplandaki nesnenin sınırlarını genişletme açısından benzerlik göstermesine rağmen, genişlemeye göre nesneye ve sınırlarına daha az hasar verir.

Kapama işlemi de “çift” işlem olarak değerlendirilmektedir. Önplan, çıkış noktası olarak alındığında buraya ait olan piksel gruplarının kapaması şeklinde değerlendirilirken arkaplandan bakan biri için arkaplanının kapanması söz konusudur.



Şekil 4.10 Kapama işlemi


Şekil 4.10’da görüldüğü üzere, kapama işlemi önplan nesnesine işlemden sonra yeni pikseller kazandırmıştır. Burada, önplan nesnesine daha çok ait olduğu hesaplanan pikseller nesneye dahil edilir. Bu tarz bir işlemi, uygulama olarak gürültüye sahip imgelerde gürültü giderimi, nesne içi kopuklukların tamamlanması gibi alanlarda görebiliriz.



Şekil 4.11 (a) İkili resim (b) mavi : arkaplan, beyaz : önplan, kırmızı : yapısal eleman (c) açma sonucu

Yapısal eleman, kapama işleminde de –genişlemede olduğu gibi- önplan nesnesine ait olan dış pikselleri belirleyip bunların nesneye dahil olmasını sağlar. Şekil 4.11’de görüldüğü üzere, nesneye ait olmadığı düşünülen gürültü olarak da kabul edilebilecek pikselleri ve komşularını nesneye dahil edip yeniden yapılanma sağlamaktadır. Kapamanın kullanıldığı durumlar, Şekil 4.12’de de görüldüğü gibi arkaplanda ortaya çıkan gürültülerin temizlenmesini amaçlar. Bütün işlemler de olduğu gibi burada da kullanılan yapısal elemanın şekli de önem kazanmaktadır. Dairesel gürültülerin giderimi için dairesel yapıya sahip yapısal elemanlar tercih edilir. Bu elemanların çapı da arkaplanda bulunan gürültülerin boyuyla doğru orantılı

olmalıdır. Şekil 4.12’de 11 piksel çapında bir yapısal eleman kullanılıp komşuluk ilişkileri değerlendirilmiştir.



Şekil 4.12 (a) Kapama işlemi uygulanacak giriş imgesi (b) Kapama işlemi sonuç imgesi

4.2.3 Gelişmiş Biçimbilimsel İşlemler

Matematiksel biçimbilim içinde kullanılan, tasarlanan ve geliştirilen bütün diğer işlemler yukarıda belirttiğimiz iki temel işlem, aşınma ve genişleme kullanılarak, açma ve kapama işlemlerinin türevleri olacak şekilde kullanılır. Bunların en önemlileri kendisini tekrar eden açma-kapama işlemleri, jeodezik tabanlı aşınma ve genişleme, aşınma/genişleme ile tekrar yapılandırma kabul edilmektedir (Pesaresi M., Benediktsson J.A., 2001). Bu işlemlerin bazıları iskelet çıkarma, gürültü giderme gibi filtrelerin oluşturulmasında kullanılır.

Diğer yandan yukarıda yapılan işlemler ikili imgeler üzerinde denenmiş ve biçimbilimsel işlemler şekillendirilmiştir. Biçimbilimsel işlemlerin uygulandığı diğer alanlar, gri seviyeli ve renkli imgeler olmuştur. Gri seviyeli imgelerde yapısal eleman içine düşen, bu kümede yer alan piksel değerlerinin enküçüğü ya da enbüyüğü yapılan işleme göre merkez piksel değeri olarak atanmış ve sonuç resmi oluşturulmuştur. Renkli imgelerde ise kullanılan renk uzayına göre farklı yöntemler denenmiş olup öncelikle renkli imgeyi oluşturan gri seviyeli bantlar arasında işlemler yapıp çıkna sonuçlardan yeni imgeler elde edilmiştir. Şekil 4.13’te gri seviyeli imgeler, Şekil 4.14’te de renkli imgeler ile ilgili yapılmış temel biçimbilimsel işlemler sonucunda elde edilen imgeler verilmiştir.



(a)



(b)



(c)



(d)



(e)

Şekil 4.13 (a) Özgün gri seviyeli imge (b) Aşınma (c) Genişleme (d) Açma (e) Kapama



(a)



(b)




(c)

Şekil 4.14 Renkli imgelerde temel biçimbilimsel işlemler (a) Özgün renkli imge (b) Aşınma (5x5'lik yapısal eleman) (c) Genişleme (5x5'lik yapısal eleman)

5. HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA

Sınıflandırma kavramı, bir veri kümesi elemanlarının gruplanması ve etiketlenmesi ihtiyacı üzerine ortaya çıkmıştır. Küme elemanlarının sahip oldukları özellikler ışığında çeşitli sınıflara ayrılması, sınıflandırma kavramının temel dayanağını oluşturmaktadır. Görüntü işleme alanında sınıflandırma kavramı, görüntü işlemenin temel kavramlarından biridir. Görüntüde, piksel değerlerinin bağlı olduğu sınıfların özdevinimsel olarak tanınması probleminde getirilen çözümler sınıflandırma başlığı altında incelenmektedir. Görüntülerin sınıflandırılmasında temel amaç, görüntüdeki sınıfların doğru tanımlanmasına yardımcı olacak araçlar geliştirmek ve bunların işlevselliğini arttırmaktır. Şekil 5.1.(a)'da uzaktan algılama yöntemleri ile elde edilmiş ağaç, deniz, yol sınıflarını içeren örnek bir görüntü ve Şekil 5.1.(b)'de ise ilgili görüntünün sınıf verisi gösterilmektedir ve farklı renklerle ifade edilen farklı sınıflar gözlemlenmektedir. Bir sınıfa dahil edilen herhangi bir pikselin gerçekte olduğu sınıftan farklı bir sınıf içinde yer alması, sınıflandırma başarımını düşüren etmendir ve yanlış sınıflandırma olarak adlandırılmaktadır. Sınıflandırma algoritmaları yanlış sınıflandırma durumlarını en aza çekecek şekilde kullanılmaktadır ve geliştirilmektedir.




Şekil 5.1 (a) Uzaktan algılama yöntemleri ile elde edilen örnek görüntü (b) örnek görüntü için sınıf verisi

Farklı dalga boyu bantlarında veri içeren hiperspektral görüntülerin analiz edilmesi için sınıflandırma algoritmaları gerekmektedir. Her piksel için hiperspektral görüntüleme sistemleri ile elde edilen spektral imza (sürekli yansıtılık spektrumu), sınıflandırmada temel belirleyici görev üstlenmektedir ve bu yansıma spektrumları kullanılarak standart görüntü algılayıcılarına göre daha iyi sınıflandırma sonuçları elde edilmektedir.

Şekil 5.2'de 4 bantlı bir görüntüden elde edilen piksel spektrumlarına dayanarak sınıflandırma

yapıldığı temel düzeyde gösterilmektedir. Bir piksel için elde edilen 4 farklı değer işlenerek daha önceden belirlenmiş veya o anda belirlenen sınıf türlerini temsil eden değerlerle karşılaştırılarak işlenen pikselin hangi sınıfa ait olduğuna karar verilmektedir.



Şekil 5.2 4 bantlı bir görüntünün temel sınıflandırma akışı

Sınıflandırma yöntemleri *eğitici* (*supervised*) ve *eğitici* (*unsupervised*) sınıflandırma olarak farklı iki kategoride incelenmektedir.

5.1 Eğitici Sınıflandırma


Eğitici -diğer bir deyişle denetimsiz- sınıflandırma, piksellerin, herhangi bir ön giriş verisi ve kullanıcı müdahalesi olmadan algoritmalar yardımı ile otomatik olarak bölütlenmesi (kümeleneşmesi) temeline dayanmaktadır. Eğitici sınıflama yöntemlerinde, sınıflandırılacak bölgenin tüm pikselleri kullanarak kümeleneşmeler elde edilmektedir (Long, W., Srihann, S., 2004). Eğitici sınıflandırma; görüntüdeki veri tanımlanamadığında yani verinin sınıf bilgisine sahip olunmadığı durumlarda başvuru olan yöntemdir.

K-ortalama algoritması (Goswami, A., Ruoming J., Agrawal G., 2004), eğitici sınıflandırma yöntemleri arasında en çok tercih edilen metottur. Bu metotta, sınıf sayısını temsil eden “*K*” sayısı ilk aşamada sisteme verilmek üzere, bu “*K*” değeri kadar rastgele piksel seçilerek ortalama değeri olarak alınmaktadır. İmge içerisindeki pikseller de en yakın oldukları ortalama değerine göre kümelere atanmaktadır. Bu işlem bittikten sonra kümelerin ortalamaları, aynı kümeye ait olan piksellerin ortalaması olarak alınmakta ve pikseller yeni ortalamalara göre yeniden merkezine en yakın olduğu kümeye atanarak sınıflandırma gerçekleştirilmektedir. Bu işlem döngüsü, piksellerin kümeler arasındaki geçişleri son bulana kadar devam etmektedir. Şekil 5.3.(a)’da uzaktan algılama ile elde edilmiş bir görüntünün üç


bandtan oluşturulan “yanlış renkli” bir görüntü, Şekil 5.3.(b)’de bu görüntünün k değeri 10, Şekil 5.3.(c)’de k değeri 5 alınarak uygunlanan k -ortalama bölütleme işlemlerinin sonuçları gösterilmektedir.



(a)



(b)



(c)

Şekil 5.3 (a) Uzaktan algılama ile elde edilmiş 3 bantlı görüntü (Landsat / Kowloon – Hong Kong Island) (b) $k = 10$ için 10-ortalama (c) $k=5$ için 5-ortalama sonucu oluşan sınıflandırma sonuçları

Hiperspektral görüntüler üzerinde, eğitici sınıflandırma kullanılarak yapılan çalışmalarda, çoklu eşikli (Multi-threshold), iso-bölütme (iso-segmentation) ve histogram temelli bölütme (histogram based segmentation) yöntemlerinin spektral görüntüye uygulanışı çalışılmıştır (Qian S-E., Hollinger A.B., Williams D., Manak D., 1999). Özbölge temelli

bölütleme yöntemi de önerilmiştir (Chang L., 2004). Silvermann ve arkadaşlarının yaptığı çalışmada hiperspektral veriler ana bileşenlerin histogramı temelli bölütleme yöntemi ile sınıflandırılmıştır (Silvermann J., Rotman S.R., Caefer C.E., 2002). *Saklı Markov zincirlerinin (hidden Markov chains)* hiperspektral verilerin bölütlemesinde kullanılması da çalışılmıştır (Mercir G., Derrode S., Lennon M., 2003). Hiperspektral görüntüler için Gauss karışım modellerinin kullanılması temeline dayanan istatistiksel bölütleme yöntemi önerilen çalışmalardandır (Acito N., Corsini G., Diani M., 2003).

5.2 Eğitici Sınıflandırma

Eğitici sınıflandırma yöntemleri, eğitici olarak adlandırılan diğer yöntemlerden çok fazla tanıma bilgisi ve tanıma önbilgisine ihtiyaç duymaktadır. Sınıflandırma işleminden önce sınıflandırılacak olan görüntünün içeriği ve sınıf bilgileri hakkında bir önbilgi çalışması gerekmektedir (Long W., Srihann S., 2004). *Eğitim verisi (train)*, *deney verisi (test)* ve *sınıf bilgisi verisi (thematic map – ground truth)* kavramları bu sınıflandırma yöntemleri altında ortaya çıkmaktadır.

Eğitim verisi, eğitim aşamasında sınıflara ait ve sınıfın temel özelliklerini içeren veri modellerinin elde edilmesi aşamasında kullanılmaktadır. Sınıflandırma aşamasında, eğitim aşamasında elde edilen model kullanılarak daha önceden görülmemiş giriş verilerinin (test verisi) hangi sınıfta olduğu bulunmaktadır. Sınıflandırma aşamasında, eğitim aşamasında oluşturulan modeller kullanılmakta ve tüm eğitim verisi yeniden işleme sokulmamaktadır.

Eğitici sınıflandırmada, sınıflandırma başarımı, sınıflandırılan görüntünün sahip olduğu sınıfları doğru olarak ifade eden piksellerin, sınıf verisinin (ground truth) gerçek değerleri ile karşılaştırılması ile bulunmaktadır. Sınıflandırmadaki temel amaç, sınıflandırmada oluşacak hatayı, diğer bir deyişle sınıfı yanlış ifade edilen piksellerin sayısının en aza indirecek yöntem ve algoritmaların bulunmasıdır.


Eğitim ve test gruplarına sahip sınıflandırma işleminin temel modellemesi, iki sınıflı sınıflandırmalar ile açıklanmaktadır. x_i , eğitim verisi içindeki i . veri, r_i bu veriye ait sınıf bilgisi olmak üzere eğitim seti Eşitlik 5.1 ile gösterilmektedir.

$$(x_1, r_1), \dots, (x_i, r_i) \in R^n \times \{\pm 1\} \quad (5.1)$$

Eşitlik 5.2 ile gösterilen fonksiyon test verisi içindeki piksel değerlerinin hangi r_i değerine sahip olduğunu belirlemekte kullanılmaktadır.

$$f: R^N \rightarrow \{\pm 1\} \quad (5.2)$$

Eğitici sınıflandırma çalışmalarının, hiperspektral görüntüler üzerinde kullanılmasına multispektral görüntülerde kullanılmasından sonra geçilmiştir. Eğitici sınıflandırma yöntemlerinden biri olan Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon amacıyla multispektral ve hiperspektral görüntüler üzerinde kullanılmıştır (Huang, C., Davis, L. S., Townshend, J. R. G., 2002; Roli, F., Fumera, G., 2001). DVM yönteminin, farklı uydu görüntüleri arasında AVIRIS algılayıcıları ile elde edilen görüntülere uygulanmıştır (Gualtieri, J. A., Chettri, S. R., Crompt, R. F., and Johnson, L. F., 1999). Sınıflandırma başarımını arttırmak amacıyla, farklı kernel tabanlı iyileştirme önerileri sunulmuş (Camps-Valls, G., Bruzzone, L., 2005) ve DVM'nin özellik çıkartımı yöntemleri ile birleştirilmesi (Melgani, F., Bruzzone, L., 2004) çalışmaları gerçekleştirilmiştir.



Şekil 5.4 (a) Indian Pine görüntüsü (b) Normal DVM ve (c) birleşik kernelli DVM ile elde edilen sınıflandırma sonuç görüntüleri

Şekil 5.4.(a)'da Indian Pine görüntüsünün orjinal hali, Şekil 5.4.(b)'de normal DVM ve Şekil 5.4.(c)'de birleşik kernelli DVM sınıflandırma sonuçları görülmektedir.

DVM, gelişmiş eğitimci sınıflandırma yöntemlerinin başında gelmektedir. DVM'nin doğrusal biçimli türevi olan İlgililik Vektör Makineleri (İVM), DVM'de dezavantaj olan istatistiksel çıkış verememe, “*trade-off*” parametre ihtiyacı ve “*Mercer*” kernel kullanılma zorunluluğunu ortadan kaldırmıştır (Tipping, M. E., 2000; Tipping, M. E., 2001). Demir, B. ve Ertürk, S. DVM sınıflandırma yöntemini hiperspektral görüntüler üzerinde uygulamış ve İVM sınıflandırma yönteminin uygulanabilirliğini ve diğer artı yönleri çalışmalarında ele almışlardır (Demir, B., Ertürk, S., 2007).

5.3 Hiperspektral Gelişmiş Sınıflandırma Yöntemleri

Bu çalışma kapsamında, gelişmiş sınıflandırma yöntemlerinden DVM ve İVM ele alınmıştır. Bu sınıflandırma yöntemlerine giriş değeri olarak önışlem uygulanmış hiperspektral görüntüler verilmiş ve ortaya çıkan sonuçlar, bu iki sınıflandırma yöntemi çerçevesinde yorumlanmıştır.

5.3.1 Destek Vektör Makineleri

Destek vektör makinelerinin, görüntü işleme alanında sınıflama yöntemi olarak kullanılması daha önceden öngörülmüş ve denenmiş bir konudur. Tek ve çok bantlı görüntülerin, yanı sıra multispektral ve hiperspektral görüntüler üzerinde de yapılan çalışmalar bulunmaktadır. El yazısı tanıma (Markowska-Kaczmar, U., Kubacki, P., 2005), yüz tanıma (Qin, Jun., He, Zhong-Shi., 2005) ve tıp alanındaki görüntülerin (Li, Y., Liu Q., Ruan, X., 2004) sınıflandırılması çalışmalarında kullanılmaktadır.

Doğrusal olarak ayrılma konusunda DVM yöntemine ikili sınıflandırma örneği ile temel düzeyde anlatabiliriz. Elimizdeki iki sınıfı C_1 ve C_2 kümeleri olarak, -1 / +1 değerlerini de bu kümelere ait elemanları etiketlemek için kullanalım. Örnek olarak alınan $X = \{x^t, r^t\}$ tanımında, eğer $x^t \in C_1$ ise $r^t = +1$ ve $x^t \in C_2$ ise $r^t = -1$ olarak tanımlanmaktadır. Öğrenme aşamasında işlenen veriler bu şekilde etiketlenerek eğitim seti oluşturulur. Eğitim boyunca iki sınıf arasındaki ayırma düzleminin konumunu DVM arasındaki mesafe en çok olacak şekilde konumlandırılır. İki sınıf arasındaki ayırım en optimum hale gelirken sınıfları belirleyen DVM arası mesafe en çoklanmaya çalışılır. Yukarıda belirttiğimiz küme kavramının içeriğindeki elemanları hesaplamak için w ve w_0 tanımlanmalıdır.


$$w^T x^T + w_0 \geq +1, \quad r^t = +1 \text{ için} \quad (5.3)$$

$$w^T x^T + w_0 \leq -1, \quad r^t = -1 \quad (5.4)$$

Eşitlik 5.3 ve 5.4'te ifade edilen ayrımsallık denklemleri, r^t ifadesi ile birleştirilerek tek bir denklem ile ifade edilebilir.

$$r^t(w^T x^t + w_0) \geq +1 \quad (5.5)$$

Eşitlik 5.5'te, sınıflara ait elemanların, sınıflara dahil olabilmek için sadece sınıflar arası oluşturulan *aşırıdüzlemin (hyperplan)* çok yakınında olması istenmemektedir. Buna ek olarak genelleştirmeyi sağlamak için, bir miktar uzaklığın da sağlanması gerekmektedir. Aşırı plandan en yakın sınıf elemanına olan uzaklığa *aralık* denir. Şekil 5.5'te aşırı planı ve aralığı belirtilen iki sınıflı bir sınıflandırma ve bu sınıflara ait DVM'ler görülmektedir. Sınıfları belli eden sınırlar üzerindeki elemanlar destek vektörleridir.



Şekil 5.5 Farklı DVM örnekleri

5.3.1.1 Doğrusal Olarak Ayrılabilen DVM ile Sınıflandırma

Elimizdeki eğitimci ve iki sınıflı sınıflandırma probleminde, d -boyutlu özellik uzayından gelen, N tane vektör içeren bir eğitim seti $x_i \in \mathfrak{R}^d (i=1,2,...,N)$ olduğunu varsayalım. Her x_i vektörüne de $y_i \in \{-1,+1\}$ şeklinde olan bir birim ile eşleştirelim. Elimizdeki iki sınıfta doğrusal olarak ayrılabilirdiğini varsayalım. Bunun anlamı, $b \in \mathfrak{R}$ ve $w \in \mathfrak{R}^d$ kullanılarak tanımlanan ve iki sınıfı hatasız bir şekilde ayırabilecek en az bir aşırı düzlem bulabiliriz.

$$f(x) = w \cdot x + b \quad (5.6)$$

Eşitlik 5.6'da tanımlanan ve aşırı plan ile bağdaştırılan $f(x)$ diskriminant fonksiyonu

kullanılarak $\text{sgn}[f(x)]$, sınıflandırma karar fonksiyonu olarak tanımlanabilir. Eşitlik 5.7'deki şart altında, böyle bir aşırı planı tanımlamak için w ve b değerleri kestirilmelidir.

$$y_i(w \cdot x_i + b) > 0 \quad i=1, 2, \dots, N \text{ olmak üzere.} \quad (5.7)$$


DVM kavramı, en yakın eğitim örnekleri arasındaki uzaklığı enbüyükleyen, en uygun aşırı düzlemin bulunması üzerine kuruludur. Bu uzaklığı $1/\|w\|$ 'ye eşit olacak şekilde w ve b değerlerini Eşitlik 5.8'de değerlendirerek tanımlayabiliriz.

$$\min_{i=1,2,\dots,N} y_i(w \cdot x_i + b) \geq 1 \quad (5.8)$$

İki sınıf arasındaki geometrik uzaklık $2/\|w\|$ olarak tanımlanır. Genelleştirme kavramının bir ölçüsü olduğu için uzaklık kavramı, DVM kavramının merkez noktasını oluşturur. Aralığın genişlemesi, umulan genelleştirmenin artması demektir.

Buna göre, elimizdeki en uygun aşırı düzlemi tanımlama problemi, Eşitlik 5.9'daki ikinci dereceden dışbükey programlama problemine dönüştürebiliriz.

$$\left\{ \begin{array}{l} \frac{1}{2} \|w\|^2 \text{ değerini enküçüklemek} \\ y_i(w \cdot x_i + b) > 0 \text{ şartını } i=1, 2, \dots, N \text{ için sağlamak.} \end{array} \right. \quad (5.9)$$



Şekil 5.6 İki sınıflı bir sınıflandırma işleminde destek vektörlerinin gösterimi (Melgani, F., Bruzzone, L., 2004)

Yukarıda tanımlanmış olan doğrusal şartlara sahip optimizasyon problemi, Lagrange

denklemleri kullanılarak Eşitlik 5.10'da belirtilen ikili probleme dönüştürülür.

$$\begin{cases} \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (x_i \cdot x_j) & \text{değerini enbüyüklemek.} \\ \sum_{i=1}^N a_i y_i = 0 \text{ ve } a_i \geq 0 & \text{şartlarını } i = 1, 2, \dots, N \text{ için sağlamak.} \end{cases} \quad (5.10)$$

Eşitlik 5.10'da tanımlanmış Lagrange çarpanları, a_i ($i = 1, 2, \dots, N$) ikinci dereceden programlama yöntemleri ile tahmin edilebilir. En uygun aşırı düzlemle ilişkilendirilen diskriminant denklemi, Lagrange çarpanlarına ve eğitim verisine bağlı bir denkleme dönüşür (Eşitlik 5.11).

$$f(x) = \sum_{i \in S} a_i y_i (x_i \cdot x) + b \quad (5.11)$$

Eşitlik 5.11'de belirtilen S kümesi, sıfırdan farklı Lagrange çarpanlarına uyan eğitim verisinin altkümesini ifade etmektedir. Belirtmek gerekir ki Lagrange çarpanlarının ağırlıkları, her bir eğitim verisinin diskriminant fonksiyonunun tanınmasındaki önemine göre değişir. Sıfırdan farklı Lagrange çarpanına uyan eğitim verileri “destek vektörleri” olarak adlandırılır. Bunların en uygun aşırı düzleme olan uzaklıkları tam olarak $1/\|w\|$ kadardır.

5.3.1.2 Doğrusal Olarak Ayrılamayan DVM ile Sınıflandırma

Bir önceki bölümde tanımlanan DVM, doğrusal olarak ayrılabilen veri kümeleri için kullanılmaktadır. Bu şartlardaki bir veri kümesine gerçek veri bulmak çok iyimser bir yaklaşım olur. Doğrusal olarak ayrılamayan verileri sınıflandırabilmek için en uygun aşırı düzlem kavramı, iki ölçütün birleşimi şeklinde ifade edilen bir zarar fonksiyonunun enküçükleyen çözümü olarak geliştirilmiştir (Melgani, F., and Bruzzone, L., 2004). Bu iki ölçüt sırasıyla; aralık enbüyükleme (aynı doğrusal ayrılabilir veri sınıflandırmasında olduğu gibi) ve hata enküçükleme (yanlışla sınıflandırılmış örnekleri cezalandırmak için). Bu da Eşitlik 5.12'de görülen yeni hata fonksiyonunun tanımlanması demektir.

$$\Psi(w, x) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N x_i \quad (5.12)$$

Eşitlik 5.12 içinde tanımlanan yapay değişkenler x_i , ayrılamaz veri için hesaplama katsayısını ve C sabiti de hatalara verilen cezaları kontrol eden düzenleme parametresini temsil eder. C değeri ne kadar büyürse, yanlış sınıflandırılan örneklere verilen ceza da o kadar artar. Eşitlik 5.12'de belirtilen zarar fonksiyonunun enküçükleme Eşitlik 5.13 ve 5.14'teki kısıtların

sağlanmasını gerektirir.

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - x_i, \quad i = 1, 2, \dots, N \quad (5.13)$$


$$x_i \geq 0, \quad i = 1, 2, \dots, N \quad (5.14)$$

Bu noktada, doğrusal olarak ayrılamayan veriler için iki çeşit destek vektörünün varlığı belirtilmektedir. Bunlardan ilki, aşırı düzlem aralığında bulunan aralık destek vektörleri, diğeri ise aralığın yanlış tarafında bulunan aralık dışı destek vektörleridir.

5.3.1.3 Doğrusal Olarak Ayrılamayan Kernel Yöntemli DVM ile Sınıflandırma

İki veri sınıfı arasındaki ayrımı daha ileriye götürmek için seçilen yollardan biri de yukarıda tanımlanmış olduğumuz yöntemleri doğrusal olmayan diskriminat fonksiyonlarına uyacak şekilde genelleştirmektir. Buna göre, verinin $\Phi(\cdot)$ gibi bir doğrusal olmayan dönüşüm ile Bölüm 5.3.1.2’de tanımlanan yöntemin devamı niteliğinde, iki sınıf arasındaki ayrımın tanımlandığı daha büyük boyuttaki bir özellik uzayına $\Phi(\mathbf{x}) \in \mathcal{R}^d$ ($d' > d$) dönüştürülmesi düşünülebilir.

Buradaki ayırmadan kasıt $\mathbf{w} \in \mathcal{R}^d$ ve $b \in \mathcal{R}$ ile tanımlanmış olan bir en uygun aşırı düzlemdir. Bunu tanımlamak içinse, Eşitlik 5.8’deki gibi tanımlanmış bir ikili problemde, iç değişkenler olan $(\mathbf{x}_i \cdot \mathbf{x}_j)$ değerlerinin, bu değerlerden dönüştürülmüş olan $[\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)]$ karşılıkları ile yer değiştirilmesi gerekmektedir. Şekil 5.7’de, 2 boyutlu özellik uzayına ait doğrusal olarak ayrılamayan 2 sınıflı bir veri kümesinin Φ dönüşümü ile 3 boyutlu özellik uzayında bir düzlemlerle doğrusal olarak ayrılabilir duruma gelişi görülmektedir.



Şekil 5.7 2 boyutlu uzaydan 3 boyutlu özellik uzayına geçiş

Bu noktada, ortaya çıkan problem, $\Phi(\mathbf{x})$ ’in açık hesaplanmasının analitik olarak zaman alıcı

ve sistemi zorlayıcı olmasıdır. Kernel yöntemi bu probleme etkili bir çözüm getirmektedir. Eşitlik 5.15'teki gibi yüksek boyutlu özellik uzayına dönüşümü sağlamak için Mercer kuramında tanımlanmış olan şartı sağlayan bir kernel fonksiyonunun olduğunu varsayalım.

$$K(\mathbf{x}_i, \mathbf{x}) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) \quad (5.15)$$

Bu tip bir kernel fonksiyonu, Eşitlik 5.16'da görüleceği üzere dönüştürülmüş elemanların $[\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)]$ hesaplanmasını önlediği için elimizdeki ikili problemi büyük ölçüde basitleştirmektedir.

$$\left\{ \begin{array}{l} \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j K(x_i \cdot x_j) \text{ değerini en büyükmek} \\ \sum_{i=1}^N a_i y_i = 0 \text{ ve } 0 \leq a_i \leq C \text{ şartlarını } i=1, 2, \dots, N \text{ için sağlamak.} \end{array} \right. \quad (5.16)$$

Elde edilen son sonuç, daha düşük boyutlu özgün verinin fonksiyonuna benzer bir şekilde Eşitlik 5.17'de ifade edilen fonksiyondur.

$$f(x) = \sum_{i \in S} a_i y_i K(x_i \cdot x) + b \quad (5.17)$$

Diskriminant fonksiyonun şekli, seçilen kernel fonksiyonunun türüne bağlıdır. Mercer şartına uyan kernel örneği, Eşitlik 5.18'de verilen radyal tabanlı Gauss fonksiyondur.

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-g \|\mathbf{x}_i - \mathbf{x}\|^2) \quad (5.18)$$

Radyal tabanlı kernel fonksiyonu içinde belirtilen g , Gauss kernelinin genişliği ile ter orantılı olan bir değişkendir. Sıklıkla kullanılan bir diğer kernel fonksiyonu çeşidi de Eşitlik 5.19'daki p dereceli polinom fonksiyonudur.

$$K(\mathbf{x}_i, \mathbf{x}) = [\mathbf{x}_i \cdot \mathbf{x} + 1]^p \quad (5.19)$$

Yukarıda belirtilen kernel fonksiyon tiplerinden de anlaşılaacağı üzere, kernel tabanlı DVM sınıflandırma, kernel parametreleri (radyal tabanlı Gauss fonksiyonundag, polinom fonksiyonunda p) ve C düzenleme parametresi başta olmak üzere çok miktarda parametreye bağlı hale gelmektedir. Değişkene bağlı değerleri kestirmek için iki ana noktaya temas edilir. Bunlardan ilki; aralık değerini enbüyüklemek, diğeri ise; beklenen genelleme hata tahminini enküçükmektir. Bunları gerçekleştiren iki yöntemden bahsedilmektedir [13][22-23]. Bu kısım, “leave-one-out (LOO)” olarak bilinen analitik bir yöntem ile bütün parametre uzayında

azaltım araması ile parametrelerin en uygun halinin bulunması ile gerçekleştirilmektedir.

5.3.1.4 Çoksınıflı DVM ile Sınıflandırma

DVM sınıflandırıcısının ilk bölümünde bahsedildiği üzere, DVM sınıflandırması iki sınıflı veriler için kullanılan bir sınıflandırma yöntemidir. Buna karşın, hiperspektral verilerin sınıflandırılması genellikle birçok sınıfa ait veri içeren kümelerdir. Bu aşamada, dört farklı adet tanımlamayı inceleyeceğiz. Bu tanımlamalar, çoklu sınıf içeren hiperspektral veriler üzerindeki DVM problemlerine çözüm getirmek için kullanılmaktadır. d -boyutlu hiperspektral bir $\mathbf{X}$ görüntüsüyle eşleştirilmiş T adet olası etiketinin (sınıf bilgisi) bir $\Omega = \{w_1, w_2, \dots, w_T\}$ kümesi içinde toplandığını varsayalım. Çoklu sınıflı durumlarda, problem d -boyutlu $\mathbf{x}$ örneğine öntanımlı sınıflama ölçütlerini en uygun olarak sağlayacak bir Ω küme elemanın eşleştirilmesidir. Bu problemi çözmek için, ikili sınıflandırmalar üzerinden geliştirilen yöntemlerde yaklaşım iki basamaktan oluşmaktadır (Melgani, F., and Bruzzone, L., 2004).

- İkili sınıf verilerinin tanımlanması
- Tanımlanan bu sınıf verilerinin bazı karar kurallarına göre birleştirilmesi

İkili sınıflar kümesinin tanımı, $\Omega_A \in \Omega$ ve $\Omega_B \in \Omega$ olarak tanımlanan Ω_A ve Ω_B gruplarından yola çıkarak oluşturulan oluşturulan ikili sınıf altkümelerine birebir uymaktadır. +1 ve -1 olarak tanımlanan değerler de Ω_A ve Ω_B içindeki her bir örnek değere atanmaktadır. Bu altkümelerin seçilmesi ise, kümelerin birlikte nasıl kullanılacağına bağlı olarak değişmektedir. Burada iki ana yaklaşım söz konusudur. Bunlardan ilki “paralel yaklaşım”, diğeri ise “sıradüzensel ağaç-tabanlı yaklaşım”dır.

Paralel Yaklaşım

Bire-Karşı-Hepsi gengüdümü (One-Against-All Strategy)

Bire-Karşı-Hepsi (BKH) yöntemi, DVM için ilk ve en çok kullanılan yöntem olarak bilinmektedir. T adet DVM (herbiri için bir sınıf) tarafından oluşturulan paralel bir yapı içinde kullanılır. Eşitlik (5.20)’de görüldüğü üzere, her bir DVM, diğerlerine karşı olan bir sınıf tarafından tanımlanan iki sınıflı problemleri çözmektedir.

$$\begin{cases} \Omega_A = w_i \\ \Omega_B = \Omega - w_i \end{cases} \quad w_i \in \Omega \quad (5.20)$$

Son karar aşamasında “kazanan hepsini alır” kuralı geçerlidir. Bu da, kazanan sınıf diskriminant fonksiyon değeri olarak en yüksek değeri alan DVM’yi göstermektedir.

Bire-Karşı-Bir gengüdüümü (One-Against-One Strategy)

BKH yöntemindeki temel problem, bir sınıf ile diğerleri arasındaki ayrımın karmaşık bir fonksiyon ile tahminine yol açmaktadır. Buna ek olarak, bu denge dağılımı kararlı olmayan olasılıklara sahip problemler çözülmemektedir. Bire-karşı-bir (BKB) yöntemindeki temel fikir, basit sınıflandırma işlemlerinin paralel yapıya uygun şekilde mümkün kılınmasıdır. BKB yöntemi, olası bütün ikili karşılaştırmaları içine alan $T(T-1)/2$ adet DVM’i kullanır. Bu durumda, her DVM’nin, ikili sınıfların w_i ve w_j ($w_i \in \Omega, w_j \in \Omega, i \neq j$), $f_{ij}(x)$ ayrım fonksiyonu yardımıyla incelenir. Sonuç olarak gruplama Eşitlik 5.21’de görülen şekle gelir.

$$\begin{cases} \Omega_A = w_i & w_i \in \Omega \\ \Omega_B = w_j & w_j \in \Omega \end{cases} \quad (5.21)$$

Karar aşamasından önce, Eşitlik 5.22’de belirtilen ve ele alınan sınıflar için geçerli olan ve olmayan oyları toplayan bir puanlama fonksiyonunun $S_i(x)$ değeri, her bir sınıf $w_i \in \Omega$ için hesaplanmalıdır.

$$S_i(x) = \sum_{\substack{j=1 \\ j \neq i}}^T \text{sgn} \{ f_{ij}(x) \} \quad (5.22)$$

Bu yöntemde son karar aşaması, yine “kazanan hepsini alır” kuralına göre işler. Ancak, buradaki kazanma kısıtı Eşitlik 5.23’teki şekilde ifade edildiği üzere bir enbüyükleme durumudur.

$$w^* = \arg \max_{i=1, \dots, T} \{ S_i(x) \} \quad (5.23)$$

Bazen, aynı puana sahip iki farklı sınıf arasında problemler ortaya çıkabilir. Bu gibi durumlarda da önceki en yüksek olasılığa sahip sınıf seçilerek ortaya çıkan problemler çözülebilir.

5.3.2 İlgililik Vektör Makineleri

DVM, sınıflandırma ve regresyon işlemleri için, seyrek kernel dağılımları ile genelleştirme özelliklerini belirleyen tutarlı bir yöntemdir. Sahip olduğu bütün bu avantajlara karşı, DVM’nin de eksik bazı noktaları bulunmaktadır. Bunlar, olasılıksal çıkış değerlerinin

eksikliği, bir ödünleşim parametresinin tahmin edilmesine duyulan ihtiyaç ve “Mercer” kernel şartını sağlayan kernel fonksiyonlarının kullanılması ihtiyacıdır. İVM, DVM’ye birebir uyan fonksiyonel şeklin genelleştirilmiş bir doğrusal modeline, Bayes yaklaşımıyla ortaya çıkarılmıştır. İVM, yukarıda belirtilen eksik noktaların hepsini yok etmektedir. Diğer bir artı noktası da, daha az kernel fonksiyonuna ihtiyaç duyduğundan çalışma veriminde yükselmeye yol açar (Tipping, M. E., 2001).

DVM ikili sınıflandırma problemlerinin çözümünde kullanılan bir yöntemdir. İVM’de sınıf sayısında bir sınırlama yoktur. Buna karşın, matrissel işlemlerin çokluğu ve veri büyüdükçe matris işlemlerinin de artması aşırı yük getirmektedir. Bu yüzden, İVM de ikili sınıf problemi olarak ele alınır. İVM için $t_n \in \{0,1\}$ ikili sınıflandırmadaki sınıf bilgisi olarak alınmaktadır. t_n değerinin alabileceği değerler 0 ve 1’dir. Bu yüzden $p(t|w)$ olasılığının hesaplanması için Bernoulli dağılımı kullanılabilir. $y(x)$ değerine lojistik sigmoid bağlantı fonksiyonu $s(y) = 1/(1 + e^{-y})$ doğrusal yapıda bir model üretmek için uygulanır. Bernoulli dağılımına dayanarak $t_n \in \{0,1\}$ için oluşturulan benzerlik ifadesi Eşitlik 5.24’te gösterilmektedir.

$$p(\mathbf{t}|\mathbf{w}) = \prod_{n=1}^N s\{y(x_n; \mathbf{w})\}^{t_n} [1 - s\{y(x_n; \mathbf{w})\}]^{1-t_n} \quad (5.24)$$

Eşitlik 5.25’te ağırlık parametrelerinin önsel olasılığı gösterilmektedir. Bu eşitlik ifade edilirken ağırlık vektörünün bileşenlerinin istatistiksel olarak birbirlerinden bağımsız olduğu kabul edilmektedir.

$$p(\mathbf{w}|\boldsymbol{\alpha}) = \prod_{i=1}^N \frac{\sqrt{a_i}}{\sqrt{2p}} \exp\left(-\frac{a_i w_i^2}{2}\right) \quad (5.25)$$

$\boldsymbol{\alpha} = (a_1, a_2, \mathbf{K}, a_N)^T$ olarak ifade edilen vektör burada hiperparametreleri göstermektedir. Bu noktada Bayes teoremi kullanılarak ağırlık parametrelerinin sonsal olasılığı hesaplanmaktadır (Eşitlik 5.26).

$$p(\mathbf{w}|\mathbf{t}, \boldsymbol{\alpha}) = \frac{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})}{p(\mathbf{t}|\boldsymbol{\alpha})} \quad (5.26)$$

Yukarıdaki eşitlikte, $p(\mathbf{t}|\mathbf{w})$ benzerliği, $p(\mathbf{w}|\boldsymbol{\alpha})$ önsel olasılığı, $p(\mathbf{t}|\boldsymbol{\alpha})$ ise kanıtı (evidence) ifade etmektedir. Bu eşitlik içindeki $\mathbf{w}$ değerleri analitik olarak elde edilemediğinden Laplace yaklaşımı $\mathbf{w}$ değerlerinin elde edilmesi için kullanılmaktadır. $\boldsymbol{\alpha}$ değerlerine uygun $\mathbf{w}$ ağırlık

değerleri sonsal dağılım kullanılarak bulunmaktadır. Buradaki amaç $\mathbf{w}$ değerinin enbüyüklendiği noktaları bulmaktır. Bu bilgiye ek olarak $p(\mathbf{w}|\mathbf{t}, \mathbf{a})$ doğrusal olarak $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\mathbf{a})$ ile orantılı olduğu da bilinmektedir. Zira, $p(\mathbf{t}|\mathbf{a})$ değeri bütün olasılıkların toplamı olduğundan sabit olarak kabul edilmektedir. Eşitlik 5.27, enbüyükleme işlemi için Laplace yaklaşımının kullanılmasını göstermektedir.

$$\log\{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\mathbf{a})\} = \sum_{n=1}^N [t_n \log y_n + (1-t_n) \log(1-y_n)] - \frac{1}{2} \mathbf{w}^T \mathbf{A} \mathbf{w} \quad (5.27)$$

Bu eşitlikte, $y_n = s \{y(x_n; \mathbf{w})\}$, $\mathbf{A} = \text{diag}(a_1, a_2, \dots, a_N)$ köşegen matrisi olarak kullanılmaktadır. $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\mathbf{a})$ ifadesindeki bileşenler olasılıksal yoğunluk fonksiyonu olarak alınır. Artı değerde olduklarından $p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\mathbf{a})$ değerinin enbüyüklenmesi, $\log\{p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\mathbf{a})\}$ değerinin de enbüyüklenmesi anlamına gelir. a değerlerini kullanarak en olası $\mathbf{w}$ değerlerini bulmak için yinelemeli çözüm yöntemi kullanılmaktadır. En olası değerlerinin bulunması için *yinelemeli yeniden ağırlıklandırılmış en yakın kareler (iteratively-reweighed least-squares)* yöntemi kullanılmıştır. Eşitlik 5.27’de ifade edilen eşitliğin $\mathbf{w}$ ’ye göre iki kere türevi alınarak Hessian eşitliği Eşitlik 5.28’deki gibi bulunmaktadır.

$$\nabla_{\mathbf{w}} \nabla_{\mathbf{w}} \log p(\mathbf{w}|\mathbf{t}, \mathbf{a}) \Big|_{\mathbf{w}_{MP}} = -(\mathbf{\Phi}^T \mathbf{B} \mathbf{\Phi} + \mathbf{A}) \quad (5.28)$$

Bu eşitlikteki, $\mathbf{B} = \text{diag}(b_1, b_2, \dots, b_N)$ köşegen matrisidir ve matris içindeki her bir değer $b_n = s \{y(x_n)\} [1 - s \{y(x_n)\}]$ ile ifade edilmektedir. Hessian eşitliğinin eksisi alınıp ters hali hesaplandığında kovaryans matrisi â Eşitlik 5.29’daki gibi elde edilmektedir.

$$\begin{aligned} \mathbf{\Sigma} &= (\mathbf{\Phi}^T \mathbf{B} \mathbf{\Phi} + \mathbf{A})^{-1} \\ \mathbf{w}_{MP} &= \mathbf{\Sigma} \mathbf{\Phi}^T \mathbf{B} \hat{\mathbf{t}} \\ \hat{\mathbf{t}} &= \mathbf{\Phi} \mathbf{w}_{MP} + \mathbf{B}^{-1} (\mathbf{t} - \mathbf{y}) \end{aligned} \quad (5.29)$$


Eşitlik 5.29’da belirtilen değerler, genelleştirilmiş yakın kareler problemlerinin çözülmesi sonucu elde edilmektedirler. $\mathbf{w}_{MP}$ değerlerinin elde edilmesi sonucunda a_i değerleri,

$$a_i^{yeni} = \frac{g_i}{w_i^2}, \text{ denklemini kullanarak yenilenmektedir. Burada } w_i, i. \text{ ortalama sonsal ağırlık ve}$$

$g_i = 1 - a_i N_{ii}$,’dir. N_{ii} kovaryans matrisinin i . köşegen elemanıdır. Seyreklik kavramı bu noktada sağlanmaktadır. Birçok a_i değeri yüksek değerler ile ifade edildiğinden gözardı

edilirler. Bu eksiltmede sistemde seyrekliğin oluşmasına yol açar (Tipping, M. E., 2000).

İVM, DVM'nin geliştirilmiş bir türevi olup, olasılıksal seyrek kernelli bir yöntemdir. Öğrenme kısmına getirilen Bayes yaklaşımı ile hiperparametreler tarafından tanımlanan önsel olasılıkla ağırlıklar belirlenir. Her bir hiperparametre, en olası değerlerin veriden yinelenerek tahmin edilen birer ağırlığı temsil edecek şekilde yapılandırılır. Uygulama aşamasında, ağırlıkların birçoğunda sonsal dağılımda yaklaşık olarak sıfır değerini alan vektör makineleri bulunur. Bunların atılması seyrekliği sağlar.



Şekil 5.8 Aynı veri seti üzerinde hata ve vektör sayısı bakımından DVM ve İVM karşılaştırması (Tipping, M. E., 2000)

İVM'nin, DVM ile karşılaştırıldığında en gerekli ve belirgin özelliği daha az kernel fonksiyonu kullanmasıdır. Ayrıca bölümün girişinde bahsettiğimiz üzere, İVM, DVM'de görünen eksi noktaların hiçbirini içermemektedir.

Şekil 5.8'de aynı veri kümesi üzerine uygulanan DVM ve İVM sonuçları görülmektedir. İki farklı sınıfa ($\times$ ve $\bullet$) verilerin uzaydaki dağılımları verilmiştir. Çember içine alınan noktalar vektör makinelerini ifade etmektedir. DVM sonucunda 44 farklı vektör makinesi bulunurken, bu sayı İVM'de 3'tür. Buradan da anlaşılacağı üzere İVM'de kullanılan hesapsal yük DVM'ye göre çok düşüktür. Zira, uygulama ve test aşamalarında her bir değeri 44 farklı vektör makinesi kullanarak kernel fonksiyonundan geçirmek yerine, 3 kernel fonksiyonundan geçirmek yeterli olmaktadır.

Bu çalışmada, matematiksel biçimbilim işlemleri uygulanmış veri kümesine DVM ve İVM

teknikleri uygulanarak sınıflandırma yapılmaktadır. Bu iki değer arasındaki karşılaştırmanın yanısıra matematiksel biçimbilim uygulanmayan verilerin sınıflandırma sonuçları ile de karşılaştırmalar değerlendirilmektedir.

6. UYGULANAN YÖNTEM

Görüntü işleme çalışmalarına konu ve araç olan görüntülerin temeli iki bitlik siyah-beyaz olarak ifade edilen imgelere dayanır. Gelişen görüntüleme teknikleri ile beraber, bir ışık kaynağından gelen ve nesneler üzerinde farklı ışınım olaylarına yol açan farklı dalga boylarının kullanılabilir olması, görüntülerin daha da detaylandırılmasını sağlamıştır.

Görüntüleme tekniklerinin, siyah-beyaz imgelerden renkli imgelere geçiş basamağını 8-bitlik gri seviyeli imgeler oluşturur. Bu tekli görüntüler bant olarak tanımlanmaktadır. Bu tip imgelerde, renk değerleri 0 ile 255 arasında değişen değerler ile ifade edilir. Bu tip resimlere ait örnekler Şekil 4.13'te görülebilir. Renkli imge kavramı, gri seviyeli imgeler temel oluşturacak şekilde, imgeyi oluşturan piksel değerlerinin 8'den fazla bit değeri ile ifade edilmesi sonucunda elde edilir. Genel olarak kullanılan *RGB (Red-Green-Blue)* imgeler 3 farklı gri seviyeli imgeden (3 banttı) oluşuyormuş gibi ifade edilmektedir. İmge içerisindeki bir piksel değeri 0-255 kapalı aralığında 3 adet değer ile belirtilir.

Multispektral ve hiperspektral görüntüleme teknikleri, son yıllarında elde edilme kolaylığının bir getirisi olarak özellikle uzay, tıbbi ve coğrafi görüntülerin elde edilmesi amacıyla kullanılmaktadır. Multispektral görüntüler, Çizelge 2.1'de tanımlanan dalga boyları aralıklarından, mor ötesi ve görünür bölgeden elde edilen ve sayıları 9'ı geçmeyen bantlar ile ifade edilirler. Burada, her bant ayrı bir gri seviyeli imge ile gösterilmektedir. Konumuz olan hiperspektral veri ise multispektral ile hemen hemen aynı dalga boyu aralıklarından (yakın kızıl ötesi ile orta kızıl ötesi aralığı da dahil olmak üzere) yüzlerce banttı oluşur. Bu tip görüntülerde veri yoğunluğu multispektral imgelere göre çok fazladır. Yüzlerce farklı dalga boyunun, nesneler üzerindeki ışınımalarının değerlendirilmesi bize yüzlerce farklı banttı veri sağlamaktadır.

Bu çalışmada, hiperspektral imge kullanılmasının temel nedeni, yukarıda belirtilen veri yoğunluğudur. Bu yoğunluğun ışığında yapılan çalışmaların verimi, görüntülenen bölge ya da nesne hakkında araştırmacılara daha fazla bilgi vermesi sayesinde artmaktadır. Hiperspektral görüntülerin, çalışma konusunun sonunda kullanılan sınıflandırma yöntemleri öncesi, sınıflandırılacak pikseller hakkında daha detaylı bilgi içermesi sonucunda tek banttı veya multispektral imgelere göre daha etkili sonuçlar verdiği bilinmektedir. Çok miktarda veri, imge içerisindeki temel özelliklere ait çok fazla bilgi demektir. Bunun doğal sonucu olarak da elde edilen özellikler daha fazla nokta ile tanımlanmaktadır. Bu ayırma sınıflandırma aşamasında sınıflar arasındaki ayırmanın daha başarılı yapılmasının yolunu açar.

6.1 Veri Seti

Hipekspektral görüntülerin sınıflandırılması çalışmalarında kullanılan deneysel veri setleri farklı algıyıcılar ile elde edilen görüntülerden oluşabilmektedir. Bu görüntülerin arasında en çok kullanılan 3 veri, *DC-Mall*, *Pavia* ve *Indian Pine(IP)* olarak adlandırılan görüntülerdir. Bu görüntüler kendi aralarında boyut, bant sayısı, farklı bölge yapılarına sahip olmak gibi özellikler bakımından farklılıklar göstermektedir. Çizelge 6.1’de, bu görüntülere ait temel özelliklerin karşılaştırılmasına yer verilmiştir.

Çizelge 6.1 DC-Mall, Pavia ve Indian Pine görüntülerine ait temel özelliklerin karşılaştırılması

Görüntü Adı	Boyut	Özgün Bant Sayısı	Temiz Bant Sayısı	Algılayıcı Tipi	Bölge
DC-Mall	1280x307	189	38	HYDICE	Kentsel
Pavia	400x400	80	40	DAIS	Kentsel
Indian Pine	145x145	224	200	AVIRIS	Orman



(a)



(b)




(c)

Şekil 6.1 Temsili görüntüler (a) DC-Mall, (b) Pavia, (c) Indian Pine (IP)

Şekil 6.1’de hiperspektral görüntü işlemede en çok kullanılan 3 imgenin temsili görüntüleri verilmiştir. Bu görüntüler, imgelerin içinden rastgele seçilen bantların gri-seviyeli imge olarak ifade edilmesinden sonra, RGB sıralamasını sağlayacak şekilde oluşturulmuşlardır. Şekil içinde de boyutları, Çizelge 6.1’de ifade edilen gerçek boyutlarından daha küçük olarak gösterilmektedir.

Bu tez çalışması kapsamında, kullanılan yöntemlerin geliştirilmesinde, hiperspektral görüntü olarak NASA tarafından araştırmacıların kullanımına açık olan *AVIRIS (Airborne Visible/Infrared Imaging Spectrometer)* algılayıcı ile elde edilmiş olan IP görüntüsünden yararlanılmıştır. Bu görüntünün çalışmada yer almasındaki temel sebep, çalışmanın hareket noktasını oluşturan ve sonuçları, bu tez kapsamında elde edilen sonuçlar ile karşılaştırılan çalışmada bu görüntünün kullanılmış olmasıdır (Demir, B., Ertürk, S., 2007). Bu durum çıkan sonuçların tutarlılığı açısından önem taşımaktadır. Diğer bir sebep ise, görüntünün orman dokusuna sahip olmasıdır. Bu özellik görüntünün sınıflandırılabilirliğini etkilemektedir. Kentsel bir görüntü ile karşılaştırıldığında, kentsel doku içinde farklı sınıflara ait bölgeler arasındaki sınırlar sezgisel yöntemlerle bile kolayca belirlenmektedir. Orman dokusuna sahip görüntüler için ise bu durum tam tersidir. Zira, bu doku içerisinde birbirine çok yakın özelliklere sahip farklı sınıflar yer almaktadır. Bu durum sınıflandırılabilme özelliğini doğrudan etkilemektedir. IP görüntüsünün çalışma kapsamında deneysel olarak kullanılmasının son temel sebebi ise, sahip olduğu boyutların sistem kaynaklarını kullanma üzerine olan etkisidir. Yapılan işlemlerin yoğun hesapsal yük içermesi, kullanılan sistemlerin kapasitelerini zorlamaktadır. Bu yüzden, deneysel olarak kullanılan verinin boyutu hem sistemin çalışma hızını hem de sistem kaynağının kullanımını artı yönde etkilemektedir.

IP verisi, yöntemlerin test edilme ve geliştirilme aşamasında kullanılan AVIRIS algılayıcısı ile elde edilen görüntü olup, özgün bant sayısı 224’tür. Diğer bir deyişle, bu görüntü aynı bölgenin aynı anda, 0,4-2,5 μm aralığında 224 farklı dalgaboyu değerine sahip ışınımın, görüntülenen bölgeye ait geri dönüş değerleridir. Her bir bantın boyutu 145x145 pikseldir. Ancak, bu bantlar arasındaki 4 bant tamamen 0 değerlerinden oluştuğu için gözardı edilmektedir. Veri kümesi içinde geriye kalan 220 banttan, 20 tanesi de atmosferik gürültü içerdiğinden atılmaktadır. Başlangıç işlemleri, elde edilen 200 bant üzerinden gerçekleştirilmektedir. Ön işlem uygulanmadan yapılan sınıflandırma çalışmaları, 200 bantlık veri kullanılarak doğrudan yapılmaktadır. Ön işlem uygulanan çalışmalarda ise bu 200 bantlık veri, ön işlem giriş değeri olarak kullanılmaktadır.



Şekil 6.2 (a) *Indian Pine* görüntüsünün temsili örnek imgesi (b) *Indian Pine* görüntüsüne ait sınıf bilgilerini gösteren sınıf bilgisi imgesi


Bu veri için örnek temsili bant görüntüsü Şekil 6.2.(a)'da gösterilmektedir. Bu görüntü, IP verisinin Çizelge 6.1'de verilen özgün boyutlarından farklıdır. Şekil 6.2.(b)'de ise IP verisi için kullanılan *sınıf bilgisi (ground-truth)* imgesi bundan önceki çalışmalarda oluşturulmuş ve sınıflandırma öncesi eğitim, sınıflandırma sonrası ise test aşamalarında kullanılmıştır. Gerçekte, IP verisine ait 16 tane sınıf tanımlanmış olmasına rağmen, bazı sınıfların çok az miktarlarda piksel sayısı içermesi sebebiyle bu çalışmada en yüksek piksel sayısına sahip 9 tane sınıf kullanılmaktadır. Çizelge 6.2'de bu 9 sınıfa ait eğitim ve test piksellerinin sayısı ve toplam eğitim ve test piksel sayıları görülmektedir.

Çizelge 6.2 *Indian Pine* görüntüsü için ilk 9 sınıfın eğitim ve test piksel sayıları

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

6.2 Uygulanan Yöntemin Adımları

Bu çalışmanın içeriğinde uygulanan yöntemin temeli 3 adımdan oluşmaktadır. Bu adımlar sırasıyla; bant çıkarımı, matematiksel biçimbilim işlemleri ve sınıflandırma aşamasından oluşmaktadır. 200 bantlık özgün veri, bant çıkarımı yöntemlerinden TBA kullanılarak gerçekleştirilmekte, biçimbilimsel aşamada belirli bir yapısal eleman eşliğinde açma ve kapama işlemleri uygulanmakta ve bu elde edilen açma-kapama sonuçları, DVM ve İVM yöntemlerinde kullanılmak üzere sınıflandırma adımına giriş değeri olarak verilmektedir.




Şekil 6.3 Tez kapsamında uygulanan yöntem adımlarının akışı

Bu 3 temel adımın, giriş değerlerine nasıl uygulandığı ve varsa çıkış değerlerinin ne gibi sonuçlara önayak olduğu detaylı olarak ve akış sırasına uyularak alt bölümlerde anlatılmaktadır. Şekil 6.3'te de bu akış şekillendirilmektedir.

6.2.1 Giriş – Özgün Veri

Bölüm 6.1'de bahsedilen veri kümemiz, bu çalışmanın eğitim aşamasında veri kümesine ait test modelinin ortaya çıkarılması için kullanılmakta ve bütün test aşamasında da sınıf bilgisi imgesi çerçevesinde sınıflandırma sonuçları ele alınmaktadır.

Veri kümemiz bantlardan oluşmaktadır. Bant, hiperspektral imgelerde görüntüsü alınan bölgenin belirli *bir* dalga boyundaki görüntüsüdür. Işık kaynağı-Nesne (görüntülenen bölgedeki nesneler) etkileşimin bir sonucu olarak nesneden görüntü algılayıcıya doğru gelen ışık enerjisinin içeriğindeki sadece *bir* dalga boyuna ait ışınımın taşıdığı enerjinin sayısallaştırılması ile elde edilir. Veri kümemizin özgün halinde 224 adet bant bulunmaktadır. Bu demektir ki görüntümüz, aynı bölgenin aynı zamanda 224 farklı dalga boyundan gelen ışık enerjilerinin sayısallaştırılması ile elde edilmiştir. Görüntülenen bölgeden elde edilen bu değerler 145x145 boyutlarındaki bantları oluşturmuştur. Bu 224 adet banttan 4 tanesi bütün piksellerinde (145x145 adet pikselde) aynı değerleri içerdiğinden anlamsız bant olarak kabul edilmekte ve atılmaktadır. Geriye kalan 220 banttan 20 tanesi ise atmosferik gürültü içermesi bakımından bozuk kabul edilerek veri kümesi içine dahil edilmemektedir. Şekil 6.4'te geriye kalan 200 banttan rastgele seçilmiş bant örnekleri gri seviyeli olarak gösterilmektedir.



Şekil 6.4 200 bantlık IP görüntüsünden rastgele seçilmiş bant örnekleri

Şekil 6.4'te 200 farklı banttandır seçilmiş, 8 farklı bant örneği gösterilmektedir. Bu bantlar sırasıyla, 29, 43, 64, 82, 114, 135, 162, 200 nolu bantlara ait görüntülerdir.

Kullanılan yöntemin giriş verisi, 145x145 boyutlarındaki imgelerden oluşan bu 200 bantlık veri kümesidir. Veri kümesinin önışlem akışındaki ilk adımı, bant çıkarmıdır.

6.2.2 Bant Çıkarmı – Temel Bileşen Analizi

Hiperspektral görüntülerin doğası gereği çok miktarda spektral veri içermesi, elde edilen bantların çok yüksek miktarlara ulaşması veri üzerinde gerçekleştirilecek herhangi bir işlemin hesapsal yükünü ve çalışma zamanını olumsuz yönde etkileyerek arttırmaktadır. Ayrıca görüntülen bölgenin yüksek görüntü boyutları ile ifade edilmesi, buradaki veri yükünü daha da arttırmaktadır.

Yukarıda belirtilen bu dezavantajların ortadan kaldırılması ve hiperspektral veri kümelerinin içerdği verilerin daha etkili olarak korunması ve kullanılması amacıyla bant azaltımı yöntemleri kullanılmaktadır. Bölüm 3'te bahsedilen bant azaltımı alanlarından bant (özellik) seçimi hiperspektral imgeler üzerinde uygulanabilirliği çok mümkün olmayan bir durumdur. Bunun temel nedeni, pratikte hiperspektral verilerin içerdği genel spektral verinin belli dalga boylarında yoğunlaşmayıp görüntü alınan dalga boyu aralığındaki dalga boyu değerlerine yayılmasıdır. Bu yüzden, bu çalışmanın hareket noktasını oluşturan çalışmalar dahil (Benediktsson, J.A., Palmason, J.A., Sveinsson, J.R., 2005) birçok çalışmada verinin spektral niteliğini koruyarak niceliğinde azaltıma gitmeyi olanaklı kılan istatistiksel tabanlı bant çıkarmı yöntemleri kullanılmaktadır. Bu tez çalışmasında, bant çıkarmı yöntemlerinden Temel Bileşen Analizi (TBA) giriş verisi olan 145x145 boyutlarında 200 adet bant içeren Indian Pine verisine uygulanmıştır.

TBA, Bölüm 3.2.1'de verilen tanım gereği bir koordinat dönüşüm problemidir. Giriş verimiz 200 bant olduğundan, bir bant içinde yer alan 145x145 pikselden bir tanesi için (her bir banttandır o piksele ait bir piksel değeri gelmek üzere) 200 farklı değeri vardır. Bu da bir piksel değerinin 1x200 boyutlarında bir matris ile ifade edilmesini sağlar. Bu matrisi pikselin vektörü olarak da tanımlayabiliriz. Eşitlik 6.1'de görüntü içindeki i . pikselin 200 bant içinden aldığı değerleri ifade eden piksel vektörü gösterilmektedir. Bu eşitlikteki i değeri, pikselin 145x145 piksel içeren görüntümüzdeki hangi pikselin değerlerini içerdğini, 0-199 arasındaki sayılar ise pikselin hangi battaki değeri olduğu göstermektedir.

Buradan çıkan bir diğer sonuç ise bir pikseli ifade etmek için 200 boyutlu bir uzaya

ihtiyacımız olduğudur. TBA'nin temeli, bir koordinat dönüşümü sonucunda 200 farklı boyut ile ifade edilen veri kümemizi 200'den çok daha az bir veri uzayı içerisinde ifade edebilir hale getirmektir.

$$x_i^T = \begin{bmatrix} x_{i,0} \\ x_{i,1} \\ x_{i,2} \\ \dots \\ x_{i,199} \end{bmatrix} \quad (6.1)$$

Her pikselin Eşitlik 6.1'deki gibi bir yapıdaki vektör ile tanımlandığı sonucundan yola çıkarak bütün veri kümesini 200x21025 boyutlarındaki iki boyutlu bir matris ile ifade edebiliriz. Eşitlik 6.2'de bu matrisin matematiksel ifadesi görülmektedir. Bant sayısını ifade eden 200 satır sayısı, piksel sayısını ifade eden 21025 (145x145) ise sütun sayısı olmaktadır.

$$X = \begin{bmatrix} x_0 & x_1 & x_2 & \dots & x_{199} \end{bmatrix} = \begin{bmatrix} x_{0,0} & x_{0,1} & x_{0,2} & \dots & x_{0,21024} \\ x_{1,0} & x_{1,1} & x_{1,2} & \dots & x_{1,21024} \\ x_{2,0} & x_{2,1} & x_{2,2} & \dots & x_{2,21024} \\ \dots & \dots & \dots & \dots & \dots \\ x_{199,0} & x_{199,1} & x_{199,2} & \dots & x_{199,21024} \end{bmatrix} \quad (6.2)$$

Eşitlik 6.2'deki yazımda kullanılan x_i , bir bant içinde bulunan 21025 adet pikselin oluşturduğu 1x21025 boyutlarındaki matrissel yapıyı, $x_{i,j}$ ise i . bantta bulunan j . piksel değerini temsil eder.

TBA yönteminin veri setimiz üzerine uygulanma adımları aşağıda belirtilmektedir. Veri setinde satırlara göre ortalamalar alındıktan sonra, her piksel değerinin kendi imgesine ait ortalamaya değeri kendisinden çıkarılarak yeni değer elde edilir. Yeni durumdaki veri setinden de 200x200 boyutlarındaki kare kovaryans matrisi elde edilir. Kovaryans matrisinin özdeğer (eigen value) ve özvektörleri (eigen vector) hesaplanır. Büyükten küçüğe doğru sıraya konulan özdeğerlerin bu sırasına göre ait oldukları özvektörlerde sıralanır. Elde edilen bu son özvektör matriside çıktı olarak alınacak veri setinin hazırlanmasında kullanılmaktadır.

- Her bant için ortalama değeri hesaplanır :

$$ort(X) = \begin{bmatrix} ort(x_0) \\ ort(x_1) \\ ort(x_2) \\ \dots \\ ort(x_{199}) \end{bmatrix} = \begin{bmatrix} (x_{0,0} + x_{0,1} + x_{0,2} + \dots + x_{0,21024}) / 21025 \\ (x_{1,0} + x_{1,1} + x_{1,2} + \dots + x_{1,21024}) / 21025 \\ (x_{2,0} + x_{2,1} + x_{2,2} + \dots + x_{2,21024}) / 21025 \\ \dots \\ (x_{199,0} + x_{199,1} + x_{199,2} + \dots + x_{199,21024}) / 21025 \end{bmatrix} \quad (6.3)$$

Eşitlik 6.3'te giriş veri setimiz olan ve 200x21025 boyutlu X matrisi ile ifade edilen IP hiperspektral görüntüsünün her bandındaki piksel değerlerinin ortalaması ayrı ayrı hesaplanır.

- Eşitlik 6.3'te hesaplanan ortalamalar, her pikselden ait oldukları banta göre çıkarılır.

$$X' = \begin{bmatrix} x_{0,0} - ort(x_0) & x_{0,1} - ort(x_0) & x_{0,2} - ort(x_0) & \dots & x_{0,21024} - ort(x_0) \\ x_{1,0} - ort(x_1) & x_{1,1} - ort(x_1) & x_{1,2} - ort(x_1) & \dots & x_{1,21024} - ort(x_1) \\ x_{2,0} - ort(x_2) & x_{2,1} - ort(x_2) & x_{2,2} - ort(x_2) & \dots & x_{2,21024} - ort(x_2) \\ \dots & \dots & \dots & \dots & \dots \\ x_{199,0} - ort(x_{199}) & x_{199,1} - ort(x_{199}) & x_{199,2} - ort(x_{199}) & \dots & x_{199,21024} - ort(x_{199}) \end{bmatrix} \quad (6.4)$$

Eşitlik 6.4'te giriş verisinin, ait oldukları bantların ortalama değerlerine göre hesaplanmış yeni piksel değerleri gösterilmektedir. Boyutları giriş verisini temsil eden X matrisi ile aynı olup 200x21025'tir.

- Eşitlik 6.4'te ifade edilen matris (X'), giriş değerlerini içeren matrisin (X) kovaryans matrisinin hesaplanmasında kullanılır. Bu noktada, Eşitlik (6.5)'teki kovaryans hesaplaması Eşitlik 3.8'de belirtilen formül ile yapılmaktadır.

$$cov(X) = \frac{1}{N-1} * X' * X'^T = \frac{1}{N-1} * (X - ort(X)) * (X - ort(X))^T \quad (6.5)$$

Kovaryans matrisinin kare bir matris olup, boyutları 200x200 değerindedir. Bunun nedeni; matris çarpımında kullanılan X' ve X'^T matrislerinin boyutlarıdır. Eşitlik 6.4'te görüleceği üzere X' matrisinin boyutu 200x21025'tir. Bu matrisin *devrik (transpose)* hali olan X'^T de doğal olarak 21025x200 boyutlarında olacaktır. Bu iki matrisin, matrissel çarpımının sonucunda ortaya çıkan matrisin boyutları 200x200 değerinde olacaktır.

- Kovaryans matrisine ait özdeğer ve özvektörler hesaplanır. Özdeğer ve özvektör hesaplanması Bölüm 3.2.1'de ele alınmıştır.

$$od_{i,j}(X) = od(cov(X)) \quad (6.6)$$

$$ov_{i,j}(X) = ov(cov(X)) \quad ov_{ij} = 0, i \neq j \text{ olmak üzere} \quad (6.7)$$

Elde edilen özvektör ve özdeğer matrisleri 200x200 boyutlarında olup, özdeğer matrisi bir köşegen matristir. Yani sadece köşegen üzerine denk gelen değerleri bulunmaktadır. Bu değerler dışında kalan bütün değerler 0 değerini taşır.

- Özdeğer matrisi, köşegen matris olduğu için vektör haline getirilir ve sahip olduğu 200 değer büyükten küçüğe doğru sıralanır. Bu sıralama özvektörleri içeren matris için de aynı şekilde gerçekleştirilir. Bunun nedeni, her bir özdeğerin, bir özvektöre atanmış olmasıdır. Bu atanma düzenini kaybetmemek için, özdeğerler kendi aralarında büyükten küçüğe doğru sıralandıktan sonra, aynı sıralama özvektörler içinde gerçekleştirilir.

$$sıra = \text{siralama}(\text{diag}(\text{od}_{i,j}(X))) \quad (6.8)$$

$$ov'_{i,j}(X) = \text{vektor_siralama}(ov_{i,j}(X), sıra) \quad (6.9)$$

Eşitlik 6.8'de köşegen matristen (200x200) vektöre (1x200) dönüştürülen özdeğerlerin sıralanması gösterilmektedir. Bu sıralama da, Eşitlik 6.9'da görüleceği üzere giriş değeri olarak özvektör matrisinin (200x200) sıralanmasında kullanılır.

- Sıralanan özvektör matrisinin devriği ile ilk başta veri setini içeren X matrisinin çarpımı bize yeni bant değerlerini, X ile aynı yapıda olacak şekilde vermektedir.

$$X^{yeni} = (ov'_{i,j}(X))^T * X = \begin{bmatrix} x_{0,0}^{yeni} & x_{0,1}^{yeni} & x_{0,2}^{yeni} & \dots & x_{0,21024}^{yeni} \\ x_{1,0}^{yeni} & x_{1,1}^{yeni} & x_{1,2}^{yeni} & \dots & x_{1,21024}^{yeni} \\ x_{2,0}^{yeni} & x_{2,1}^{yeni} & x_{2,2}^{yeni} & \dots & x_{2,21024}^{yeni} \\ \dots & \dots & \dots & \dots & \dots \\ x_{199,0}^{yeni} & x_{199,1}^{yeni} & x_{199,2}^{yeni} & \dots & x_{199,21024}^{yeni} \end{bmatrix} = \begin{bmatrix} x_0^{yeni} \\ x_1^{yeni} \\ x_2^{yeni} \\ \dots \\ x_{199}^{yeni} \end{bmatrix} \quad (6.10)$$

Eşitlik 6.10'da dönüştürülen veri setinin matrissel ifadesi görülmektedir. Matristeki her satır yeni veri setindeki bir banta (x_i^{yeni}) karşılık gelmektedir. Özdeğerlerin sıralaması büyükten küçüğe doğru olduğu için, ilk bantlar dönüştürülen veriye ait daha fazla bilgi taşımaktadır. Bu yüzden, veriyi temsil etmede ilk bantlar kullanılabilir.


Bu sıralamada en yukarıda yer alan yeni imgeler 200 bantlık görüntüyü temsil edecek yeni bantlar olarak belirlenmektedirler. Çizelge 6.3'te elde edilen yeni bantlara atanan özdeğerler ve bunların genel toplama olan oranı yüzde olarak ifade edilmektedir. Bu oranlardan anlaşılacağı üzere, dönüşüm sonrasında yeni elde edilen bantlardan ilk 3 tanesi dönüşüm öncesi kullanılan 200 boyutlu veri kümesinin %97,09'luk kısmını içermektedir.

Çizelge 6.3 TBA sonucunda elde edilen bantların özdeğerleri ve bütün özdeğerler toplamına oranları

	Özdeğerler	Oran (%)= $\frac{l_i}{\sum_{i=1}^n l_i} * 100$
l_1	3.6687	83.9288
l_2	0.49687	11.3671
l_3	0.078402	1.7936
$l_4 + l_5 + \dots + l_{200}$	0.1272	2.9105

Çizelge 6.3 gösteriyor ki 200 boyutlu olarak ifade edilen giriş verimiz, TBA dönüşümleri uygulandıktan sonra dönüşüm sonrasında bulunan ilk 3 bant ile ifade edilebilmektedir. 200 boyutlu veriden 3 boyutlu veriye geçiş sadece %2.91 oranında bir kayba yol açmaktadır. Ancak bu kayıp, hafifleyen veri ve hesapsal yük göz önüne alındığında gözardı edilebilir bir kayıptır.

TBA sonucunda, giriş verisi olarak kullandığımız 200 bantlık veri artık 3 bant olarak ifade edilmekte ve bundan sonraki aşamalarda 3 bant olarak kullanılmaktadır. Şekil 6.5'te bu 3 bant gri seviyeli olarak gösterilmektedir.




Şekil 6.5 *Indian pine* verisi için ilk 3 bantlık TBA sonucu

Hiperspektral görüntülere, sahip olduğu yüksek yoğunluklu spektral verilerin niteliğinden ödün vermeden niceliğinde azaltıma gidebilmek için uygulanan TBA adımından sonra, imge içerisindeki piksellerin sahip olduğu komşuluk ilişkilerinin yorumlanması amacıyla biçimbilimsel işlemler uygulanmaktadır.


6.2.3 Matematiksel Biçimbilim – Açma / Kapama İşlemleri

TBA yöntemi ile bant azaltımına gidilen hiperspektral görüntüde, pikseller arasındaki komşuluk ilişkilerinin incelenmesi ve imgelerin yeniden oluşturulması matematiksel biçimbilim işlemlerini kullanarak gerçekleştirilmektedir. Hiperspektral veri kümeleri üzerinde

yapılan ve farklı biçimbilimsel işlemleri içeren çalışmalar, veri kümelerinin sahip olduğu spektral özellikteki verilerin yanısıra uzamsal özelliğe sahip verilerin ortaya çıkmasını olanaklı kılmaktadır (Benediktsson, J.A., Palmason, J.A., Sveinsson, J.R., 2005). TBA sonucunda ulaşılan ve veri hakkında en çok bilgiyi içeren bantlar 3x3, 5x5 ve 7x7’lik kare yapısal elemanları kullanılarak açma ve kapama işlemlerine tabi tutulurlar. Şekil 6.6’da kullanılan yapısal elemanlar ve merkez pikselleri gösterilmektedir. Bu işlemlerin uygulanmasındaki temel amaç, hiperspektral görüntüler üzerinde sadece spektral veriye dayanarak görüntü işleme yapılmasının yanı sıra, bu veri kümesinin uzamsal olarak da yorumlanmasını sağlamaktır.



Şekil 6.6 Kullanılan yapısal elemanlar (3x3, 5x5 ve 7x7)



Şekil 6.7 “Indian Pine” verisi için elde edilen 1. TBA bantı (a) için, 3x3, 5x5, 7x7’lik yapısal elemanlar kullanılarak oluşturulan açma-kapama işlemleri (b)(c)(d) açma (e)(f)(g) kapama işlemleri

TBA sonucunda elde edilen ve IP verisini yaklaşık olarak %97 oranında temsil eden 3 banta, 3x3, 5x5 ve 7x7 boyutlarındaki yapısal elemanlar uygulanarak 3 açma ve 3 kapama işlemi gerçekleştirilmektedir. Şekil 6.7’de TBA sonucunda elde edilen ve verinin %83.93 gibi bir

kısmını içeren 1. banta 3 açma ve 3 kapama uygulanması işleminin sonuçları görülmektedir.

Uygulanan açma ve kapama işlemleri, kullanılan yapısal elemanların kapsadığı piksel değerlerinin açma ve kapama durumuna göre gerekli değeri almasıyla elde edilir. Yapısal elemanın kapsama durumu ise; her pikselin, yapısal elemanın merkez pikseline denk gelecek şekilde imge üzerine yerleştirilmesi demektir. Yapısal elemanın sınırlarına dahil olan merkeze komşu piksel ile açma ve kapama işlemleri gerçekleştirilir. Buradaki merkeze komşu olma durumu, pikseller arasındaki komşuluk ilişkilerinin ortaya çıkarılması, imge üzerinde yanyana duran fakat farklı değerlere sahip olan, bu yüzden de sınıflandırma aşamasında yanlış sınıflandırılacak pikseller için komşu pikseller ile aynı değeri alma durumunu sağlar.

Şekil 6.7’de, TBA sonucunda elde edilen 1. banta uygulanan 3 açma ve 3 kapama işlemi sonucunda bu bant için –kendisi de dahil olmak üzere- 7 farklı bant elde edilir. Bu durumun TBA sonucunda elde edilen her 3 bant içinde gerçekleştirildiği düşünülürse, matematiksel biçimbilim işlemleri sonucunda 21 adet yeni bant elde edilmektedir. 145x145 boyutundaki bu 21 bantlık veri bir sonraki aşama olan sınıflandırma için giriş değeri olarak kullanılmaktadır.

6.2.4 Sınıflandırma Yöntemleri – DVM ve İVM

TBA ve matematiksel biçimbilim işlemlerinden açma-kapama işlemleri, bu çalışma kapsamında tanımlanan ön işlemleri oluşturmaktadır. Biçimbilimsel işlemlerin çıkış verisi olarak görülen 21 bantlık sınıflandırma aşamasının giriş verileridir.

Hiperspektral görüntüler üzerinde eğitici ve eğitici olmayan olmak üzere farklı sınıflandırma yöntemleri uygulanmıştır (Long W., Srihann S., 2004). Çok miktarda veri bulunması ve istatistiki yorum yapılabilmesi nedeniyle DVM bu yöntemler arasında sınıflandırma başarımı ile öne çıkan yöntemdir. DVM, sınıflandırma yöntemi olarak hiperspektral veriler üzerine uygulanması (Fauvel, M., Chanussot, J., Benediktsson J.A., Sveinsson J.R., 2007) bu çalışmada ele alınmıştır. Matematiksel biçimbilim işlemlerinin uygulandığı görüntülere DVM uygulanması da bu sınıflandırma işlemleri alanında üzerinde çalışılmış bir konudur (Fauvel, M., Chanussot, J., Benediktsson J.A., Sveinsson J.R., 2007). Diğer yandan hiperspektral verilere herhangi bir band azaltma yöntemi kullanılmadan İVM sınıflandırma yönteminin kullanılması da DVM sınıflandırmasında ortaya çıkan aşırı hesapsal yükü azaltması bakımından DVM’ne alternatif olarak gerçek zamanlı sistemler için önerilmiştir (Demir, B., Ertürk, S., 2007).

Band azaltma yöntemlerinden olan TBA’nın uygulandığı verilerin matematiksel biçimbilim

işlemleri ile uzamsal olarak da incelenip, DVM ile sınıflandırılması daha önce hiperspektral görüntüler için uygulanmasına karşın, İVM ile sınıflandırılması ilk kez bu tez kapsamında ele alınmıştır. İVM ile sınıflandırmanın da sonuçları DVM ile sınıflandırma sonuçları ile karşılaştırılmıştır.

İVM ve DVM için radyal tabanlı kernel fonksiyonu $g = 2$ alınarak kullanılmıştır ve DVM’de C parametresi 40 seçilmiştir. Sınıflandırmada kullanılan eğitim ve test piksellerinin sayısı Çizelge 6.2’de belirtildiği üzere sırasıyla 4757 ve 4588’dir.

Çizelge 6.4 DVM için farklı TBA bant ve farklı açma-kapama işlemlerinin sonuçları. İBS=İlk Bant Sayısı, TBA-BS=TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, % DVM=% olarak DVM Başarımı

İBS	TBA-BS	AS	KS	TBS	% DVM
200	1	3	3	7	66.17
200	2	3	3	14	86.92
200	3	3	3	21	95.44
200	1	2	2	5	56.88
200	2	2	2	10	75.32
200	3	2	2	15	85.98
200	3	1	1	9	74.52

Çizelge 6.4’te, TBA sonucunda elde edilen yeni bantlardan ilk n tanesi için yapılan farklı seçimler (ilk, ilk 2 ve ilk 3 olmak üzere 3 seçim) ve biçimbilimsel işlemlerin kaç kere gerçekleştirileceğini belirleyen farklı açma ve kapama sayıları ile DVM sonuçları karşılaştırılmıştır. Bu sonuçlar arasında en iyi başarıma, TBA sonuçlarının ilk 3 bandının alınması ve biçimbilimsel işlemlerde 3 adet açma ve 3 adet kapama yapılması şeklindeki bir önışlem grubuyla ulaşıldığı görülmektedir. Bu yüzden bu çalışmanın İVM kısmında da karşılaştırmaların sağlıklı olması açısından bu parametrelerle önışlemler gerçekleştirilmektedir.

DVM ve İVM ile sınıflandırma karşılaştırılması için yapılan önışlemler eşit koşulların sağlanması amacıyla, DVM ile sınıflandırmada en iyi sonucun alındığı önışlem parametreleri ile gerçekleştirilmektedir. Önışlem akışının ilk adımını oluşturan bant çıkarım yöntemi TBA sonucunda elde edilen yeni 200 adet banttan, veri kümesinin yaklaşık olarak %97’sini içeren ilk 3 bant alınmaktadır. İkinci adım olarak önışlemden kullanılan matematiksel biçimbilim işlemlerinden açma ve kapama işlemleri de, DVM de en iyi sonucun alındığı durumdaki sayılarla İVM-DVM karşılaştırılmasında kullanılmıştır. Bu durum da farklı yapısal elemanlarla elde edilen 3 adet açma ve 3 adet kapama işlemidir. Önışlem akışı sonunda 21

adet yeni bant elde edilir. DVM ve İVM sınıflandırmaları bu yöntemler üzerinden gerçekleştirilmektedir.

Çizelge 6.5 İVM sonuçları. TBA-BS= TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, İV=İlgililik Vektör Sayısı, % İVM= % olarak Başarım, ES (s)=Eğitim Süresi, TS (s)=Test Süresi

TBA-BS	AS	KS	TBS	İV	%İVM	ES (s)	TS (s)
-	-	-	200	592	90.32	48621	1957
3	6	6	39	203	98.08	1914	1016
3	5	5	33	266	97.86	1812	1125
3	4	4	27	299	97.77	1749	1309
3	3	3	21	332	96.14	1379	1443


Çizelge 6.6 DVM sonuçları. TBA-BS= TBA sonucu seçilen ilk n Bant Sayısı, AS=Açma Sayısı, KS=Kapama Sayısı, TBS=Toplam Bant Sayısı, İV=Destek Vektör Sayısı, % DVM= % olarak Başarım, ES (s)=Eğitim Süresi, TS (s)=Test Süresi

TBA-BS	AS	KS	TBS	DV	%DVM	ES (s)	TS (s)
-	-	-	200	3393	92.67	12469	12043
3	6	6	39	1190	99.12	9080	7700
3	5	5	33	1358	98.58	8920	7480
3	4	4	27	1571	97.34	8100	8150
3	3	3	21	1610	95.44	7500	9200


Çizelge 6.5'te İVM, Çizelge 6.6'da ise DVM ile sınıflandırma sonuçları verilmektedir. Her iki çizelge içinde ortak olan nokta, İV (İlgililik Vektörü) ve DV (Destek Vektörü) sayılarıdır. Önışlem uygulanmadan, doğrudan sınıflandırılmaların yapıldığı durumlarda bu vektörlerin sayıları her iki sınıflandırma yöntemi içinde, önışlem uygulanan duruma göre fazla çıkmaktadır. Bu nokta, önışlem uygulamanın sınıflandırma aşamasında hesapsal yükü azalttığı şeklinde yorumlanabilir. DVM-İVM yöntemlerinin karşılaştırılmasında ise vektör sayıları bakımından İVM, DVM'ye göre daha az vektör ile sınıfları tanımlayabilmektedir.

Doğrudan İVM ve doğrudan DVM'nin uygulandığı durumlarda test süresi bakımından İVM'nin DVM'ye göre oluça önde olduğu görülmektedir (Demir, B., Ertürk, S., 2007). Ancak buradaki dezavantaj, İVM'de eğitim süresinin artmasıdır. Bu durum, özellikle gerçek zamanlı çalışan sistemler için İVM ile sınıflandırmanın DVM ile sınıflandırmaya göre avantajlı olduğunu göstermektedir. Önışlem uygulanması durumunda ise, eğitim için harcanan sürede ciddi bir azalma olduğu görülmektedir. Özellikle İVM ile sınıflandırma yönteminde, doğrudan İVM ile sınıflandırmaya göre yaklaşık olarak %97 oranında bir zaman tasarrufu sağlamaktadır.

Sınıflandırma başarımlarının görsel ifadesi, İVM için Şekil 6.8’de ve DVM için Şekil 6.9’da farklı toplam bant sayıları (21, 27, 33, 39) için gösterilmektedir.



Şekil 6.8 İVM Sınıflandırma başarımlar haritaları. (a) 21 bant, (b) 27 bant, (c) 33 bant, (d) 39 bant üzerinden yapılan sınıflandırma başarımları



Şekil 6.9 DVM Sınıflandırma başarımlar haritaları. (a) 21 bant, (b) 27 bant, (c) 33 bant, (d) 39 bant üzerinden yapılan sınıflandırma başarımları

Eđitim ve test sűrelerinin yanında, sınıflandırma bařarımı aısından da İVM ile sınıflandırmanın öniřlem uygulanması durumunda, DVM ile sınıflandırmaya g re daha iyi sonular verdiđi g r lmektedir. Ama ve kapama iřlem sayılarının azaltıldıđı, diđer bir deyiřle öniřlem sonrası toplam bant sayısının azaldıđı durumda İV ve DV sayıları artmaktadır. Bu řartlar altında, öniřlem uygulanmıř İVM ile sınıflandırmada, öniřlem uygulanmıř DVM ile sınıflandırmaya g re sınıflandırma bařarımı aısından daha bařarılı sonular elde edilmektedir.

7. SONUÇ

Hiperspektral görüntülerin kullanımının yaygınlaşması ve bu görüntülerindeki verilerin işlenmesindeki adımların belirginleştiği son yıllarda, araştırmacıların yoğunlaştığı alanlar ortaya çıkmaya başlamıştır. Özellikle, tıp ve uzay görüntüleme sistemleri için geniş bir araştırma alanı sunmaktadır.

Uzaktan algılama alanında hiperspektral görüntüler elde edilmesiyle birlikte, bu tip görüntülerden yeryüzü hakkında veri toplanması, bu verilerin kaydedilmesi ve belli uygulamalar, yöntemler ışığında incelenmesine başlanmıştır. Bu tip görüntülerin sınıflandırılması, görüntülenen bölgedeki nesnelerin yapılarının ve isimlerinin belirlenmesi diğer bir deyişle bir etiketlenme yapılması bu yöntemlerin uygulandığı bir alandır.

Bu tez kapsamında, hiperspektral görüntülerin sınıflandırılmasına yeni bir bakış açısı getirilmiş olup, sınıflandırma başarımlarında iyileştirmeler hedeflenmiştir. Kullanılan yöntemlerin, bu iyileştirmeler ile sınıflandırma başarımları üzerindeki etkileri incelenip, önceki çalışmalardaki sonuçlar ile karşılaştırılmıştır.

Bu çalışmanın hareket noktasını oluşturan hiperspektral görüntüler üzerinde yapılan sınıflandırma çalışmalarında, sınıflandırma yöntemi olarak Destek Vektör Makineleri (DVM) ve İlgililik Vektör Makineleri (İVM) kullanılmaktadır. Bu yöntemlerde, sınıflandırma öncesi ön işlemler sadece DVM ile sınıflandırma öncesinde kullanılmıştır. İlk kez bu tez kapsamında, İVM ile sınıflandırma öncesinde ön işlemler kullanılıp, eldeki veri sınıflandırılmaya çalışılmıştır.

Yukarıda belirtilen ön işlem grubu, iki adımdan oluşmaktadır. Bu adımlardan ilki, hiperspektral görüntülerin sahip oldukları yoğun veri miktarının sebebi olan yüksek bant sayılarının gözardı edilebilir bir kayıpla azaltılmasıdır. Bu işlemin temel amacı, birbirini tekrar eden veya birbiriyle benzerlik gösteren verilerin azaltılması ve verinin daha kolay işlenebilir hale gelmesidir. Bant çıkarımı, yöntemlerinden Temel Bileşen Analizi (TBA) bu çalışmada bant azaltımı yöntemi olarak kullanılmaktadır. Ön işlem grubunun ikinci adımını matematiksel biçimbilim işlemleri oluşturmaktadır. Biçimbilim işlemlerinin, ön işlem grubu içerisindeki amacı, yoğun spektral veriye sahip hiperspektral görüntülerin sahip olduğu uzamsal verinin de ortaya çıkarılmasıdır. Pikseller arasındaki komşuluk ilişkilerine dayanarak biçimbilimsel işlemlerden açma ve kapama işlemleri kullanılarak imgelerin uzamsal yapıdaki verilerine ulaşılmaktadır.

Hiperspektral görüntü üzerine uygulanan TBA ve biçimbilim işlemlerinden sonra elde edilen

veri, sınıflandırma aşamasına yönlendirilmektedir. Sınıflandırma aşamasında DVM ve İVM ile sınıflandırma yöntemleri kullanılmıştır.

Kullanılan bant sayısı, buna bağlı olarak açma ve kapama sayıları, TBA sonucunda kullanılmaya karar verilen bant sayısı, sisteme giriş olarak verildiğinde, başarımlı oranı, eğitim süresi, test süresi ve destek veya ilgililik vektör sayıları, karşılaştırma ölçütü olarak kullanılmıştır.

Bu çalışma sonucunda elde edilen sonuçlar, önişleme uğrayan verilerin sınıflandırma başarımlı oranı, herhangi bir önişleme uğramadan, doğrudan sınıflandırmaya gönderilen hiperspektral verilerin sınıflandırma başarımlı oranından daha fazladır. Bu noktada, bu başarımlı artışı hem İVM, hem de DVM ile sınıflandırma için geçerlidir.

Önişlem uygulanarak yapılan sınıflandırma çalışmalarında ise İVM ile sınıflandırma, DVM ile sınıflandırmaya göre eğitim ve test süreleri, vektör sayıları bakımından daha iyi sonuçlar vermektedir. Bu noktalardaki başarılı sonuçlar, az bant ile gerçekleştirilen sınıflandırma durumlarında (açma ve kapama sayılarının azaltıldığı durumlarda) sınıflandırma başarımlı da yansıyarak sınıflandırma başarımlı İVM lehinde artırmaktadır.

Bu çalışmanın ışığında yapılacak gelecek çalışmalarda, bu çalışmada kullanılan önişlem yöntemlerinin en iyi duruma getirilmesi (optimizasyon), hızlandırılması ve biçimbilim işlemlerinde kullanılan yapısal elemanların farklı şekillerde denenmesi gerçekleştirilebilir.

KAYNAKLAR

- Acito, N., Corsini, G., Diani, M., (2003), "An Unsupervised Algorithm For Hyperspectral Image Segmentation Based on the Gaussian Mixture Model", Geosidence and Remote Sensing Symposium (IGARSS'03), 6, 3745-3747.
- Akça, M.D., Doğan, S., (2002), "Sayısal Görüntülerde Ana Bileşenler Dönüşümü", Harita Dergisi, Sayı 129, sf:1-15.
- Alpaydın, E., (2004), "Introduction to Machine Learning", The MIT Press, 105-130.
- Benediktsson, J.A., Palmason, J.A., Sveinsson, J.R., (2005), "Classification of Hyperspectral Data from Urban Areas Based on Extended Morphological Profiles", IEEE Trans. on Geoscience and Remote Sensing, vol. 43, no. 3, pp.480-491.
- Campbell, J.B., (2006), "Introduction to Remote Sensing", Guildford Press, 28-52, London.
- Camps-Valls, G., Bruzzone, L., (2005), "Kernel-based methods for hyperspectral image classification", IEEE Trans. on Geoscience and Remote Sensing, 43, 1352-1362.
- Chang, L., (2004), "Multispectral image compression using eigenregion-based segmentation", Pattern Recognition, 36, 1233-1243.
- Demir, B., Ertürk, S., (2007), "Hyperspectral Image Classification Using Relevance Vector Machines," IEEE Geoscience and Remote Sensing Letters, 4, 586-590.
- Diamantaras, I., Zimerman K.H., Kung S.Y., (1990), "Integrated Fast Implementation of Mathematical Morphology Operations in Image Processing", IEEE International Symposium on Circuits and Systems, 1-3 May 1990, New Orleans, 2:1442-1445.
- Fauvel, M., Chanussot, J., Benediktsson J.A., Sveinsson J.R., (2007), "Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles", 2007 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'07), July 23-July 27 2007, Barcelona, Spain.
- Goswami, A., Ruoming J., Agrawal G., (2004), "Fast and Exact Out-of-Core K-Means Clustering", Fourth IEEE International Conference on Data Mining, 83-90, Brighton, UK.
- Gualtieri, J. A., Chettri, S. R., Crompt, R. F., and Johnson, L. F., (1999), "Support vector machine classifiers as applied to AVIRIS data", 8th JPL Airborne Earth Science Workshop, JPL Pub. 99-17, 217-227.
- Hsu, P.H., Tseng, Y.H., (1999), "Feature Extraction for Hyper Spectral Image", The 20th Asian Conference on Remote Sensing, 22-25 Nov. 1999.
- Huang, C., Davis, L. S., and Townshend, J. R. G., (2002), "An Assesment of Support Vector Machines for Land Cover Classification", Int. J. Remote Sensing, 23, 725-749.
- Hunt, E.R., Parker-Williams, A., (2004), "Comparison of hyperspectral and multispectral remote sensing for leafy spurge", Society for Range Management, p. 88.
- Kittler, J., (1986), "Feature selection and extraction", Academic Press, New York.
- Li, Y., Liu Q., Ruan, X., (2004), "Cancer molecular classification based on support vector machines", Fifth World Congress on Intelligent Control and Automation, (WCICA), 6, 5521-5524.

Lillesand, T.M., Kiefer, R.W., Chipman, J.W., (2003), "Remote Sensing and Image Interpretation", Wiley, 193-208, New York.

Long, W., Srihann, S., (2004), "Land cover classification of SSC image: unsupervised and supervised classification using ERDAS Imagine", IEEE International Geoscience and Remote Sensing Symposium, 4, 2707 – 2712.

Lybanon, M., (1995), "Maltese Front Variability from Satellite Observations Based on Automated Detection", IEEE Transactions on Geoscience and Remote Sensing, Vol. 34, No. 5.

Mallat, S.G., (1989). "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation", IEEE Trans. On Pattern Analysis And Machine Intelligence, Vol. 11, No. 7, p. 674-693.

Markowska-Kaczmar, U., Kubacki, P., (2005), "Support vector machines in handwritten digits classification", Proceedings. 5th International Conference on Intelligent Systems Design and Applications, 1, 252 – 256.

Melgani, F., and Bruzzone, L., (2004), "Classification of Hyperspectral Remote Sensing Images with Support Vector Machines", IEEE Trans. on Geoscience and Remote Sensing, 42, 1778-1790.

Mercir, G., Derrode, S., Lennon, M., (2003), "Hyperspectral image segmentation with markov chain model", Geoscience and Remote Sensing Symposium (IGARSS'03), 6, 3766-3768.

Ortiz, F., Torres, F., Gil, P., (2004), "Gaussian Noise Elimination In Clour Images By Vector-Connected Filters", Proceedings of the 17th International Conference on Pattern Recognition.

Pesaresi, M., Benediktsson, J.A., (2001), "A New Approach for the Morphological Segmentation of High-Resolution Satellite Imagery", IEEE Transactions on Geoscience and Remote Sensing, Vol. 39, No. 2, p. 309-320.

Plaza, A., Martinez, P., Plaza, J., Perez, R., (2005), "Dimensionality Reduction and Classification of Hyperspectral Image Data Using Sequences of Extended Morphological Transformations", IEEE Transactions on Geoscience and Remote Sensing, Vol. 43, No. 3, p. 466-479.

Qian, S-E., Hollinger, A.B., Williams, D., Manak, D., (1999), "Vector Quantization Using Spectral Index-Based Multiple Subcodebooks for Hyperspectral Data Compression", IEEE Transactions on Geoscience and Remote Sensing, 38, 756-770.

Qin, Jun., He, Zhong-Shi., (2005), "A SVM face recognition method based on Gabor-featured key points", International Conference on Machine Learning and Cybernetics, 8, 5144 -5149.

Serra, J., (1982), "Image Analysis and Mathematical Morphology", Academic Press.

Silvermann, J., Rotman, S.R., Caefer, C.E., (2002), "Segmentation of hyperspectral images based on histograms of principal components", SPIE Proceedings: Imaging Spectrometry VIII, 4816, 270-277.

Smith, L.I., (2002), "A Tutorial on Principal Component Analysis", sf. 3-11.

Tipping, M. E., (2000), "The relevance vector machine", in Advances in Neural Information Proc-essing Systems 12, S. A. Solla, T. K. Leen, and K.-R. Müller, Eds. Cambridge, MA:

MIT Press.

Tipping, M. E., (2001), “Sparse Bayesian learning and the relevance vector machine”, *Journal of Machine Learning Research*, 1, 211–244.

Ulaby, F.T., Moore, R.K., Fung, A.K., (1981), “Microwave Remote Sensing : Fundamentals and Radiometry”, Artech House Publishers, Norwood, Massachusetts.

Zortea, M.; Haertel, V, (2004), “Experiments on feature extraction in remotely sensed hyperspectral image data”, *Geoscience and Remote Sensing Symposium IGARSS’04*, 20-24 Sept. 2004, 2:964-967.

NASA, (2004), Earth Observatory Image Library, “http://earthobservatory.nasa.gov/Newsroom/NewImages/images.php3?img_id=16777”, Son Ziyaret : 02-01-2008.

UHUZAM, (1999), “<http://www.cscrs.itu.edu.tr/page.tr.php?id=12>”, Son Ziyaret : 02-01-2008.

ÖZGEÇMİŞ

Doğum tarihi	22.12.1981	
Doğum yeri	Edirne	
Lise	1995-1999	Edirne Anadolu Öğretmen Lisesi
Lisans	1999-2004	Galatasaray Üniversitesi Mühendislik ve Tek. Fak. Bilgisayar Mühendisliği Bölümü
Yüksek Lisans	2004-	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Müh. Anabilim Dalı

Çalıştığı kurum(lar)

Ekim 2005-Temmuz 2007	ISI Emerging Markets Web Geliştirici&Sistem Yöneticisi
Ağustos 2007-Devam ediyor	ISI Emerging Markets IT Müdürü