

KOCAELİ ÜNİVERSİTESİ *FEN BİLİMLERİ ENSTİTÜSÜ

**HİPERSPEKTRAL GÖRÜNTÜLERİN YÜKSEK DOĞRULUKLU
SINIFLANDIRILMASI**

DOKTORA TEZİ

Begüm DEMİR

Anabilim Dalı: Elektronik ve Haberleşme Mühendisliği

Danışman: Prof. Dr. Sarp Ertürk

KOCAELİ, 2010

**HİPERSPEKTRAL GÖRÜNTÜLERİN YÜKSEK DOĞRULUKLU
SINIFLANDIRILMASI**

DOKTORA TEZİ

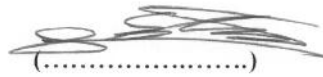
Begüm DEMİR

Tezin Enstitüye Verildiği Tarih: 14 Haziran 2010

Tezin Savunulduğu Tarih: 20 Ağustos 2010

Tez Danışmanı

Prof. Dr. Sarp ERTÜRK


(.....)

Üye

Prof. Dr. Bülent SANKUR


(.....)

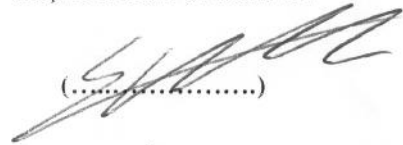
Üye

Doç. Dr. Oğuzhan URHAN


(.....)

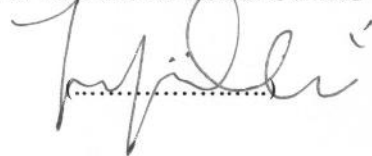
Üye

Doç. Dr. Cem ÜNSALAN


(.....)

Üye

Yrd. Doç. Dr. M. Kemal GÜLLÜ


(.....)

KOCAELİ, 2010

ÖNSÖZ ve TEŞEKKÜR

Bu tez çalışması, Türkiye Bilimsel ve Teknik Araştırma Kurumu, TÜBİTAK tarafından "Hiperspektral Sınıflandırma, Bölütleme ve Tanıma" (HİSSET) isimli araştırma projesi kapsamında desteklenmiştir.

Hiperspektral görüntülerin sınıflandırılması üzerine çalışmaya yaklaşık 4 yıl önce hayatımda neleri değiştirebileceğini tahmin edemeden başladım. Benim için sadece bir araştırma konusu, tez konusu olmasından öte hayatımda çok büyük önemi olan birçok kişiyi tanımama vesile oldu. İlk olarak hayatımı tamamıyla değiştiren bu konuyla tanışmamı sağlayan danışman hocam Sarp Ertürk'e tüm yardımları ve destekleri için çok teşekkür ederim. Kendisinin, tez çalışmalarım sırasında karşılaştığım problemlere zaman ayırabilmek için yaptığı fedakarlıkları hiç unutmuyacağım.

Birkaç yıl aynı odada çalıştığım ve bu alanda kendimi geliştirebilmemde büyük katkıları olan KULIS'in en melek hocası Kemal Güllü'ye ve en disiplinli hocası Oğuzhan Urhan'a hiç yorulmadan bana yardım ettikleri için teşekkür ederim. Başta Aysun, Orhan ve Ersin olmak üzere diğer tüm lab arkadaşlarıma benimle paylaştıkları her an için teşekkür ederim. Aysun'la yaptığımız sohbetleri özleyeceğim.

Bu üç yıllık süreçte en zorlu görev ailemindi. Biliyorum ki bu çalışma temposu içerisinde bana destekleri olmasaydı, ihtiyacım olan her an yanımda olmasalardı, bu başarı olmazdı. En mutlu günlerimde olduğu gibi en zorlu günlerimde de yanımda olan aileme ne kadar teşekkür etsem azdır. Bana her zaman güvenip, destekledikleri için onlara minnettarım. İki tane hayat dolu kardeşe sahip olduğum için çok şanslıyım. En zor günlerimde kendi sorunlarını unutarak beni hayata bağlamaya çalıştıkları için çok teşekkür ederim.

Benim için önemini kelimelerle ifade edemeyeceğim Zafer'e sonsuz destekleri için, bana kendime güvenmeyi öğretmeye çalıştığı için, her zaman sabırla beni dinlediği için, makalelerimden sıkılmadığı için (☺) çok teşekkür ederim. İyi ki varsın.

Yılların eskitemediği arkadaşlığımızın başkahramanı Serap'a her zaman yanımda olarak verdiği tavsiyeler için çok teşekkür ederim.

Bana laboratuvarında çalışma imkanı sunan ve akademik kariyerimde aldığım yolu hızlandıran Prof. Dr.Lorenzo Bruzzone'ye RSLAB'daki birbirinden iyi arkadaşlarımı tanıma fırsatı vererek onlarla birlikte çalışma imkânı sağladığı için ve her zaman büyük bir özveriyle beni dinleyerek yol gösterdiği için teşekkür ederim. RSLAB'daki tüm arkadaşlarıma, özellikle Francesca ve Silvia'ya her zaman yanımda oldukları için sonsuz teşekkürler. Claudio'ya çalışmalarımızda gösterdiği sabırdan dolayı ve bana uzaktan algılama ile ilgili öğrettiği her şey için teşekkür ederim.

İÇİNDEKİLER

ÖNSÖZ ve TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	v
TABLolar DİZİNİ	viii
SİMGELER DİZİNİ	xiii
KISALTMALAR	xiv
ÖZET	xv
ABSTRACT	xvi
1. GİRİŞ	1
1.1. Hiperspektral Görüntüleme	1
1.2. Hiperspektral Görüntülerin Sınıflandırılmasında Karşılaşılan Sorunlar ve Çözümüne Yönelik Son Gelişmeler.....	4
1.3. Tez Çalışmasının Amaç ve Kapsamı	8
2. VERİ KÜMELERİ.....	13
3. AMPİRİK KİP AYRIŞIMI TEMELLİ HİPERSPEKTRAL SINIFLANDIRMA.....	19
3.1. GÜDÜLENME.....	19
3.2. 2-B Ampirik Kip Ayrışımı	21
3.3. Hızlı 2-B Ampirik Kip Ayrışımı	25
3.4. Düşük Dereceli İKF'lerin Toplanması Temelli Hiperspektral Görüntü Sınıflandırması	28
3.4.1. GÜDÜLENME ve önerilen yöntem	28
3.4.2. Deneysel sonuçlar	32
3.5. İçkin Kip Fonksiyonlarına Dalgacık Uzayında Gürültü Giderimi Uygulanması.....	42
3.5.1. GÜDÜLENME ve önerilen yöntem	42
3.5.2. Dalgacık uzayında gürültü giderimi.....	43
3.5.3. Deneysel sonuçlar	47
3.6. Ampirik Kip Ayrışımı ve Birleşik Çekirdek Temelli Yüksek Doğruluklu Hiperspektral Görüntü Sınıflandırması.....	54
3.6.1. GÜDÜLENME ve önerilen yöntem	54
3.6.2. Deneysel sonuçlar	55
3.7. Hiperspektral Görüntü Sınıflandırması için Ampirik Kip Ayrışımı Temelli Karar Tümlleştirme	60
3.7.1. GÜDÜLENME ve önerilen yöntem	60
3.7.2. Deneysel sonuçlar	63
3.8. Vargılar.....	67
4. BİR-BİT DÖNÜŞÜMÜ TEMELLİ YAKLAŞIMLAR.....	68
4.1. GÜDÜLENME.....	68
4.2. Bir-Bit Dönüşümü	69
4.3. Bir-Bit Dönüşümü Temelli Bant Azaltımı	74
4.3.1. Önerilen yöntem.....	74
4.3.2. En hızlı tırmanış (EHT) bant seçimi algoritması	78
4.3.3. Deneysel sonuçlar	80

4.4. Bir-Bit Dönüşümü Temelli Renkli Görüntüleme	83
4.4.1. Önerilen yöntem.....	84
4.4.2. Deneysel sonuçlar	85
4.5. Vargılar	90
5. YÜKSEK DOĞRULUKTA DVM SINIFLANDIRMA İÇİN SINIR EĞİTİM ÖRNEKLERİNİN TOPAKLAMA TEMELLİ ÇIKARIMI	91
5.1. GÜDÜLENME.....	91
5.2. Sınır Eğitim Örneklerinin Seçimi	92
5.2.1. <i>K</i> -ortalama topaklama yöntemi.....	92
5.2.2. Destek vektörlerinin belirlenmesi	93
5.3. Deneysel Sonuçlar	94
5.4. Vargılar	99
6. ÇOK-ÇÖZÜNÜRLÜKLÜ YAPILARLA TÜMLEŞTİRME	100
6.1. GÜDÜLENME.....	100
6.2. Önerilen Yöntem	101
6.3. Deneysel Sonuçlar	104
6.4. Vargılar	107
7. FAZ İLİNTİSİ TEMELLİ YAKLAŞIMLAR.....	108
7.1. GÜDÜLENME.....	108
7.2. Faz İlintisi	108
7.3. Faz İlintisi Temelli Eğitimli Sınıflandırma Yöntemi	109
7.3.1. Önerilen yöntem.....	109
7.3.2. Deneysel sonuçlar	112
7.4. Faz İlintisi Temelli Bant Azaltımı Yöntemi	112
7.4.1. Faz ilintisi ve öznelik ağırlıklandırma temelli bant seçimi yöntemi.....	113
7.4.2. Deneysel sonuçlar	115
7.5. Vargılar	116
8. SPEKTRAL GENLİK VE SPEKTRAL TÜREV bilgilerinin BİRLEŞTİRİLEREK HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA BAŞARIMININ ARTTIRILMASI.....	117
8.1. GÜDÜLENME.....	117
8.2. Önerilen Yöntem	117
8.3. Temel Bileşen Analizi (TBA).....	121
8.4. Deneysel Sonuçlar	123
8.5. Vargılar.....	126
9. DÜŞÜK SAYIDA EĞİTİM VERİSİNE SAHİP HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRMA BAŞARIMININ ÖRNEK ARADEĞERLEME YAKLAŞIMI KULLANILARAK ARTTIRILMASI.....	127
9.1. GÜDÜLENME.....	127
9.2. Önerilen Yöntem	127
9.3. Deneysel Sonuçlar	129
9.4. Vargılar.....	130
10. SPEKTRAL BÜKME İLE SINIFLANDIRMA BAŞARIMININ ARTTIRILMASI	131
10.1. GÜDÜLENME.....	131
10.2. Spektral Bükme ve Önerilen Yöntem.....	132
10.3. Deneysel Sonuçlar	143
10.4. Vargılar	146
11. VARGILAR	147

11.1. Geliştirilen Yöntemlerin Hesaplanma Süreleri ve Sınıflandırma Başarımlarının Değerlendirilmesi.....	149
11.2. Gelecek Çalışmalar.....	152
KAYNAKLAR.....	154
EKLER.....	164
KİŞİSEL YAYINLAR ve ESERLER.....	172
ÖZGEÇMİŞ.....	175

ŞEKİLLER DİZİNİ

Şekil 2.1: Indian Pine verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi.....	14
Şekil 2.2: DC Mall verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi	15
Şekil 2.3: Botswana verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi.....	16
Şekil 2.4: Pavia verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi	17
Şekil 2.5: Salinas verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi.....	18
Şekil 3.1: Gerçekleştirilen AKA temelli algoritmaların blok şeması	21
Şekil 3.2: Indian Pine verisinde 28. bandın 2-B AKA dönüşümü sonuçları (a) orijinal bant, (b)1. İKF, (c) 1. kalan, (d) 2. İKF, (e) 2. kalan, (f) 3. İKF, (g) 3. kalan, (h) 4. İKF, (i) 4. kalan.	24
Şekil 3.3: Indian Pine verisinde 28. bandın hızlı 2-B AKA dönüşümü sonuçları (a) orijinal bant, (b)1. İKF, (c) 1. kalan, (d) 2. İKF, (e) 2. kalan.....	28
Şekil 3.4: Indian Pine verisi 28. bant (a) orijinal bant, (b) 1. İKF, (c) ilk iki İKF'nin toplanması, (d) ilk üç İKF'nin toplanması ve (e) ilk dört İKF'nin toplanması.....	30
Şekil 3.5: Indian Pine verisinde ayrılması zor üç sınıfın (a) orijinal piksel değerleri kullanılarak elde edilen ortalama spektral imzaları ve (b) bu sınıfların birinci İKF ile ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları	32
Şekil 3.6: Indian Pine verisi 28. bant (a) ilk iki İKF'nin toplamı, (b) dalgacık uzayında gürültü giderimi sonucu, (c) alçak geçiren süzgeç (AGS) sonucu ve (d) keskinleştirici süzgeç (KS) sonucu	38
Şekil 3.7: Indian Pine verisi 6. bant (a) orijinal bant, (b) 1.İKF (c) gürültü giderimi uygulanmış 1.İKF, (d) 1. İKF ve gürültü giderimi uygulanmış 1.İKF arasındaki fark imgesi	46
Şekil 3.8: Pavia verisi 3. bant (a) orijinal bant, (b) 1.İKF (c) gürültü giderimi uygulanmış 1.İKF, (d) 1. İKF ve gürültü giderimi uygulanmış 1. İKF arasındaki fark imgesi	47
Şekil 3.9: Indian Pine verisinde ayrılması zor üç sınıfın (a) orijinal piksel değerleri kullanılarak elde edilen ortalama spektral imzaları , (b) bu sınıfların birinci İKF ve ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları ve (c) bu sınıfların birinci İKF'lere gürültü giderimi uygulanması sonrası birinci İKF ve ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları	53
Şekil 3.10: Indian Pine verisi 28. bant (a) orijinal bant, (b) 1. İKF, (c) 2. İKF ve (d) ilk iki İKF'nin toplamı	61
Şekil 4.1: Gerçekleştirilen 1-BD temelli algoritmaların blok şeması	69
Şekil 4.2: 1-BD'de kullanılan çekirdek süzgecinin frekans yanıtı.....	70
Şekil 4.3: Indian Pine verisi 113. bant (a) orijinal bant ve (b) çoklu bant geçiren süzgeç ile süzgeçlendikten sonra oluşan bant	71
Şekil 4.4: 113. bandın (a) [43]'de önerilen yöntem ve (b) sabit eşik kullanılarak elde edilen 1-BD'leri	72
Şekil 4.5: Çarpmasız 1-BD'de kullanılan çekirdek süzgecinin frekans yanıtı.....	73
Şekil 4.6: (a) 104. bandın 1-BD, önemsiz bant (değişim sayısı 16465) (b) 113. bandın 1-BD, önemli bant (değişim sayısı 5686) (c) 104. bandın çarpmasız 1-BD,	

önemsiz bant (değişim sayısı 17249) (d) 113. bandın çarpmasız 1-BD, önemli bant (değişim sayısı 6271)	75
Şekil 4.7: Indian Pine görüntüsüne 1-BD dönüşümü uygulayarak elde edilen toplam 0-1 bit değişim sayıları ve yerel eşik değerleri	77
Şekil 4.8: Indian Pine görüntüsüne çarpmasız 1-BD dönüşümü uygulayarak elde edilen toplam 0-1 bit değişim sayıları ve yerel eşik değerleri	78
Şekil 4.9: Indian Pine verisi: (a) 5. bant, (b) 75. bant, (c) 169. bant, (d) 5. bandın 1-BD, (e) 75. bandın 1-BD, (f) 169. bandın 1-BD, g) renkli görüntüsü.....	87
Şekil 4.10: Cuprite verisi: (a) 216. bant, (b) 152. bant, (c) 116. bant,(d) renkli görüntüsü.....	88
Şekil 4.11: (a) Indian Pine verisi TBA renkli görüntüleme sonuçları (b) Indian Pine verisi 1-BD temelli renkli görüntüleme sonuçları, (c) Cuprite verisi TBA renkli görüntüleme sonuçları (d) Cuprite verisi 1-BD temelli renkli görüntüleme sonuçları	89
Şekil 5.1: Gerçekleştirilen algoritmanın birinci aşaması	93
Şekil 5.2: Gerçekleştirilen algoritmanın ikinci aşaması.....	94
Şekil 5.3: (a) Doğrudan DVM, SB: 92.59 (b) sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) (aşama 2’de oran=%72, SB: 93.48), ve (c) aktif öğrenme temelli DVM (AÖ-DVM) (aşama 2’de oran=%72, SB: 92.94), sonucu oluşan sınıflandırma haritaları.....	98
Şekil 6.1: Gerçekleştirilen algoritmanın akış şeması	104
Şekil 6.2: Indian Pine görüntüsü (a) 146. orijinal hiperspektral bant, (b) 1. seviyede alçak frekans bileşeni (c) 2. seviyede alçak frekans bileşeni (d) 3. seviyede alçak frekans bileşeni.....	106
Şekil 6.3 (a) Orijinal sınıf bilgileri haritası, (b) %10 eğitim verisi ve doğrudan DVM kullanılması sonucu oluşan sınıflandırma haritası, (c) %10 eğitim verisi ve çok çözünürlüklü DVM (ÇÇ-DVM) kullanılması sonucu oluşan sınıflandırma haritası, (d) %50 eğitim verisi ve doğrudan DVM kullanılması sonucu oluşan sınıflandırma haritası ve (e) %50 eğitim verisi ve ÇÇ-DVM kullanılması sonucu oluşan sınıflandırma haritası.....	106
Şekil 7.1: Birinci algoritmanın test verisini sınıflandırma aşaması	111
Şekil 7.2: İkinci algoritmanın test verisini sınıflandırma aşaması	111
Şekil 8.1: Gerçekleştirilen algoritmaların akış şeması	118
Şekil 8.2: Üç farklı sınıf için spektral genlik öznitelik vektörleri.....	120
Şekil 8.3: Üç farklı sınıf için birinci spektral türev öznitelik vektörleri.....	121
Şekil 8.4: Üç farklı sınıf için spektral ikinci türev öznitelik vektörleri	121
Şekil 9.1: Gerçekleştirilen algoritmaların akış şeması	128
Şekil 10.1: Gerçekleştirilen algoritmanın akış şeması	132
Şekil 10.2: Spektral bükme ağı	133
Şekil 10.3: SPB ağındaki ilk süzgecin genlik ve faz yanıtı	134
Şekil 10.4: SPB ağındaki ikinci süzgecin genlik ve faz yanıtı.....	135
Şekil 10.5: SPB ağındaki ilk iki süzgeç ile oluşan sistemin genlik ve faz yanıtı....	135
Şekil 10.6: SPB ağındaki tüm geçiren süzgecin genlik ve faz yanıtı.....	136
Şekil 10.7: (a) orijinal işaret, (b) $a=0.1$ iken bükülmüş işaret , (c) $a=0.3$ iken bükülmüş işaret	139
Şekil 10.8: Şekil 10.7’de gösterilen orijinal verinin (a) $a=0.5$ iken bükülmüş işaret , (b) $a=0.7$ iken eğriltilmiş işaret , (c) $a=0.9$ iken bükülmüş işaret	140
Şekil 10.9: (a) orijinal veri, (b) $a=0.3$ ile bükülmüş veri ve (c) $a=-0.3$ ile bükülmüş veri için AFD sonuçları	141

Şekil 10.10: (a) orijinal veri, (b) $a = 0.8$ ile bükülmüş veri ve (c) $a = -0.8$ ile bükülmüş veri için AFD sonuçları	142
Şekil 10.11: Orijinal ve geri çatılmış spektral veri	143
Şekil 11.1: Geliştirilen tüm yöntemlerin sınıflandırma başarımları ve DVM eğitim ve test aşamalarında harcanan toplam hesaplanma süreleri.....	150
Şekil 11.2: Geliştirilen tüm yöntemlerin sınıflandırma başarımları ve DVM test aşamalarında harcanan toplam hesaplanma süreleri	151

TABLolar DİZİNİ

Tablo 1.1: Başlıca hiperspektral algılayıcılar ve spektral özellikleri [2]	3
Tablo 2.1: Indian Pine verisi için kullanılan 9 sınıfın toplam piksel sayıları (TPS). 13	13
Tablo 2.2: DC Mall verisi için kullanılan 7 sınıfın toplam piksel sayıları (TPS)	14
Tablo 2.3: Botswana verisi için kullanılan 14 sınıfın toplam piksel sayıları (TPS))	16
Tablo 2.4: Pavia verisi için kullanılan 9 sınıfın toplam piksel sayıları (TPS)	17
Tablo 2.5: Salinas verisi için kullanılan 7 sınıfın toplam piksel sayıları (TPS).....	18
Tablo 3.1: Indian Pine görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı.....	31
Tablo 3.2: Önerilen yöntem ve önerilen yöntemin başarımını karşılaştırmada kullanılan yöntemlerin kısa isimleri, her bir yöntemin açıklaması ve kullanıcı girişli parametreleri	35
Tablo 3.3: Farklı τ ve P değerleri için 2-B AKA ve hızlı 2-B AKA yöntemlerinin hesapsal süreleri ve toplam İKF sayıları	36
Tablo 3.4: Indian Pine verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (AGS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), orijinal verinin ve biçimbilimsel profillerin ardı ardına eklenerek DVM ile sınıflandırılması (Spek-BP), öznitelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere uygulandıktan sonra elde edilen spektral verilerin ardı ardına eklenerek DVM ile sınıflandırılması (ÖÇ-Spek-BP), 2-B AKA ile DVM sınıflandırma (2B-AKA-DVM), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA- DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kappa katsayıları (k), Z değerleri	39
Tablo 3.5: Indian Pine verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (AGS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), orijinal verinin ve biçimbilimsel profillerin ardı ardına ekleyerek DVM ile sınıflandırma (Spek-BP), öznitelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere uygulandıktan sonra elde edilen spektral verilerin ardı ardına eklenerek DVM ile sınıflandırılması (ÖÇ-Spek-BP), 2-B AKA ile DVM sınıflandırma (2B-AKA-DVM), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA- DVM) yöntemlerinin %65 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kappa katsayıları (k), Z değerleri.....	40
Tablo 3.6: Indian Pine verisinde bulunan her bir sınıfın ortalama sınıf başarımları.	41
Tablo 3.7: DC Mall verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırılması (KS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-	

AKA-DVM) yöntemlerinin %5, %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kappa katsayıları (k), Z değerleri	41
Tablo 3.8: Salinas verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırılması (KS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA-DVM) yöntemlerinin %5, %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kappa katsayıları (k), Z değerleri	41
Tablo 3.9: Indian Pine görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB).....	50
Tablo 3.10: Pavia görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB).....	50
Tablo 3.11: Salinas görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB).....	51
Tablo 3.12: Indian Pine görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı.....	51
Tablo 3.13: Pavia görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı.....	52
Tablo 3.14: Salinas görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı.....	52
Tablo 3.15: Indian Pine görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), 2-B AKA temelli birleşik çekirdek (AKA-BÇ-DVM), hızlı 2-B temelli birleşik çekirdek (H-AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kappa katsayıları (k).....	58
Tablo 3.16: DC Mall görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), hızlı 2-B AKA temelli birleşik çekirdek (H-AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kappa katsayıları (k).....	59

Tablo 3.17: Salinas görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), 2-B AKA temelli birleşik çekirdek (AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kapa katsayıları (k)	60
Tablo 3.18: Indian Pine görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)	65
Tablo 3.19: Pavia görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)	65
Tablo 3.20: Salinas görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)	65
Tablo 3.21: Indian Pine görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)	65
Tablo 3.22: Pavia görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)	66
Tablo 3.23: Salinas görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)	66
Tablo 3.24: Indian Pine verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)	66
Tablo 3.25: Pavia verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)	67
Tablo 3.26: Salinas verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)	67
Tablo 4.1: Indian Pine verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant), 1-BD temelli bant eleme yöntemi sonrası EHT (1-BD-EHT) (125 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (125 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)	81
Tablo 4.2: Indian Pine verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant), 1-BD temelli bant eleme yöntemi sonrası EHT (1-BD-EHT) (90 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (90 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)	82
Tablo 4.3: DC Mall verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (90 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)	82
Tablo 4.4: Farklı bant sayılarında (BS), 1-BD sonrası en hızlı tırmanış bant azaltımı (1-BD-EHT) (125 bant) ve ayrışım ölçütü hesabında her bandın kendisinden bir önceki ve bir sonraki bant ile D-VEYA işlemi sonucu elde edilen her iki veri için satır ve sütundaki değişimlerin sayılarının toplamını kullanan 1-BD-EHT yöntemi (1-BD-EHT-2) (125 bant) için elde edilen sınıflandırma başarımları (SB)	83

Tablo 4.5: İlk bant seçimi (İBS) ve İkinci Bant Seçimi (KBS) sonucu seçilen bant indisleri.....	86
Tablo 4.6: Indian Pine verisinde 1-BD temelli yöntem ile elde edilen KYM bileşenleri arasında ilinti katsayıları.....	89
Tablo 4.7: Indian Pine verisinde TBA ile elde edilen KYM bileşenleri arasında ilinti katsayıları.....	89
Tablo 4.8: Cuprite verisinde 1-BD temelli yöntem ile elde edilen KYM bileşenleri arasında ilinti katsayıları.....	89
Tablo 4.9: Cuprite verisinde TBA ile elde edilen KYM bileşenleri arasında ilinti katsayıları.....	90
Tablo 5.1: Indian Pine verisinde toplam verinin %10'unun eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	96
Tablo 5.2: Indian Pine verisinde toplam verinin %20'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	97
Tablo 5.3: Indian Pine verisinde toplam verinin %50'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma(ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	97
Tablo 5.4: Botswana verisinde toplam verinin %10'unun eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, SEÖ-DVM ve AÖ-DVM sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	97
Tablo 5.5: Botswana verisinde toplam verinin %20'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	98
Tablo 5.6: Botswana verisinde toplam verinin %50'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss)değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran).....	98
Tablo 6.1: Doğrudan DVM ve çok çözünlüklü DVM (ÇÇ-DVM) sınıflandırma başarımları (SB) ve sınıflandırma süreleri (T).....	105
Tablo 7.1: Eğitim ve test örneklerinin sayısı.....	112
Tablo 7.2: Üç farklı algoritma için elde edilen sınıflandırma başarımları (SB).....	112

Tablo 7.3: Indian Pine verisi için faz ilintisi temelli öznitelik azaltımı (ÖA-Fİ) ve standart çapraz ilinti temelli öznitelik azaltımı (ÖA-Sİ) sonrası farklı bant sayılarında (BS) elde edilen DVM sınıflandırma başarımları (SB).....	116
Tablo 7.4: DC Mall verisi için faz ilintisi temelli öznitelik azaltımı (ÖA-Fİ) ve standart çapraz ilinti temelli öznitelik azaltımı (ÖA-Sİ) sonrası farklı bant sayılarında (BS) elde edilen DVM sınıflandırma başarımları (SB).....	116
Tablo 8.1: Spektral genlik özniteliklerinin (GÖ), spektral birinci türev özniteliklerinin (TÖ1), spektral ikinci türev özniteliklerinin (TÖ2) ayrı ayrı kullanılması, GÖ ve TÖ1 veri kümelerinin ardı ardına eklenmesi (GÖ-TÖ1), ve ayrıca üç veri kümesinin ardı ardına eklenmesi (GÖ-TÖ1-TÖ2) ile oluşan verilerin DVM sınıflandırma başarımları (SB)	124
Tablo 8.2: Farklı bant sayılarında (BS) TBA sonucu sadece spektral genlik özniteliklerinden bant seçilmesi (TBA-GÖ), spektral genlik ve spektral birinci türev özniteliklerinden bant seçilmesi (TBA-GÖ+TÖ1), ve spektral genlik, spektral birinci türev ve spektral ikinci türev özniteliklerinden bant seçilmesi (TBA-GÖ+TÖ1+TÖ2) sonucu DVM sınıflandırma başarımları.....	125
Tablo 8.3: TBA-GÖ+TÖ1+TÖ2, 1-BD-EHT, ÖA-Fİ yöntemlerinin farklı bant sayılarında (BS) sınıflandırma başarımları	126
Tablo 9.1: Indian Pine görüntüsünde %5 ve %10 eğitim verisi oranı (EVO) kullanılarak elde edilen standart DVM, önerilen 1. aradeğerleme yaklaşımı ve 2. örnek aradeğerleme yaklaşımı sınıflandırma başarımları (SB).....	130
Tablo 10.1: Indian Pine verisi için farklı Spektral Bükme Parametrelerinde (SBP) %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen DVM Sınıflandırma Başarımları (SB)	145
Tablo 10.2: Indian Pine verisi için spektral bükme temelli bant eleme sonrası farklı Bant Sayılarında (BS) Sınıflandırma Başarımları (SB)	145
Tablo 10.3: Indian Pine verisi için SPB temelli bant azaltımı sonrası DVM (SPB-BA-DVM), TBA sonrası DVM (TBA-DVM) ve ÇDS sonrası DVM (ÇDS-DVM) sonuçları.....	146
Tablo 11.1: Geliştirilen tüm yöntemlerin kısa isimleri ve bu yöntemlerin kısa açıklamaları.....	152

SİMGELER DİZİNİ

- a : Spektral bükme parametresi
 $A(l)$: l . hiperspektral bandın toplam deęişim sayısı
 b_{hk} : h ve k sınıfları arasındaki Bhattacharyya uzaklığı
 $B_l()$: l . hiperspektral bant
 B_l^{BD} : l . hiperspektral bandın bir-bit dönüşümü
 β : Gürültüsüz dalgacık katsayısı
 C : DVM düzenleme (ceza) parametresi
 C_i : i . sınıfın ortak deęişinti matrisi
 D_{ort} : Ortalama ıraksaklık deęeri
 d : Toplam bant sayısı
 $E_{enbüyük}$: Üst zarf işareti
 $E_{enküçük}$: Alt zarf işareti
 $f()$: Sınıflandırma fonksiyonu
 F : İki boyutlu ayrık Fourier dönüşümü
 F^{-1} : İki boyutlu ters ayrık Fourier dönüşümü
 I : İmge çerçevesi
 I_F : Süzgeçlenmiş imge çerçevesi
 H : Hilbert öznitelik uzayı
 $İKF_{l,m}$: l . bandın m . İçkin Kip Fonksiyonu
 J : En uygun şekle sokma ölçütü
 k : Kappa katsayısı
 K : Topak sayısı
 $K()$: Çekirdek fonksiyonu
 L : Toplama işlemine dahil edilecek toplam İKF sayısı
 M_i : i . sınıfın ortalaması
 N : Toplam eğitim verisi sayısı
 n : Toplam sınıf sayısı
 r : Toplam dalgacık dönüşüm sayısı
 P : Pencere boyutu
 R_m : Ampirik Kip Ayrışımı sonucu oluşan m . kalan işaret
 s : Komşu öznitelik vektörü sayısı
 S_i : i . sınıf
 T : İşlem süresi
 $t(l)$: l . banda ait yerel eşik deęeri
 X : Eğitim verileri kümesi
 \mathbf{x}_i : i . örnek
 V : d -boyutlu hiperspektral veri

v	: Biçimlendirme parametresi
Y	: Eğitim verilerinin sınıf bilgilerini içeren veri
y_i	: i . örneğin sınıf bilgisi
Z	: İstatiksel test sonucu
z	: Yerel uzamsal etkinlik göstergesi
α	: Lagrange çarpanı
μ	: Uzamsal ve spektral bilgiler arasında değiş tokuş sağlayan parametre
ξ	: Yapay değişken
Σ	: Ortak değişinti matrisi
$\phi()$: Doğrusal olmayan dönüşüm
γ	: Çekirdek fonksiyonu parametresi
λ	: Ölçekleme parametresi
$\lambda_i^{(c)}$: c . sınıfın ilinti matrisinin l . özdeğeri
$\Gamma()$: Gamma fonksiyonu
ψ	: Eşik ağırlıklandırma parametresi

KISALTMALAR

1-BD	: Bir-Bit Dönüşümü
2-B AKA	: İki boyutlu Ampirik Kip Ayrışımı
AGS	: Alçak Geçiren Süzgeç
AFD	: Ayrık Fourier Dönüşümü
AKA	: Ampirik Kip Ayrışımı
BP	: Biçimbilimsel Profiller
BS	: Bant Sayısı
ÇDS	: Çift doğrusal örnek seyreltme
ÇFA	: Çekirdek Fisher Ayırtaç
DV	: Destek Vektörleri
DVM	: Destek Vektör Makineleri
EHT	: En Hızlı Tırmanış
EVO	: Eğitim Verisi Oranı
Fİ	: Faz İlintisi
İKF	: İçkin Kip Fonksiyonu
İVM	: İlgililik Vektör Makineleri
JM	: Jeffries-Matusita uzaklığı
KYM	: Kırmızı-Yeşil-Mavi
RTF	: Radyal Taban Fonksiyonu
SB	: Sınıflandırma Başarımı
SPB	: Spektral Bükme
ST	: Sınıf Temsilcisi
TBA	: Temel Bileşen Analizi
TPS	: Toplam Piksel Sayıları

HİPERSPEKTRAL GÖRÜNTÜLERİN YÜKSEK DOĞRULUKLU SINIFLANDIRILMASI

Begüm DEMİR

Anahtar Kelimeler: Uzaktan Algılama, Hiperspektral Görüntüleme, Hiperspektral Görüntülerde Sınıflandırma, Ampirik Kip Ayrışımı, Spektral (Frekans) Bükme, Faz İlintisi, Bir-bit Dönüşümü, Bant Azaltımı, Hiperspektral Görüntülerde Renkli Görüntüleme

Özet: Hiperspektral algılayıcılar dar bantlı ve sürekli aralıklandırılmış yüzlerce spektral bantta veri toplayarak yüksek çözünürlükte spektral bilgi sağlamaktadır. Hiperspektral görüntülerin birçok uygulama alanı bulunmakta ve verinin etkili analizi için otomatik yöntemlere ihtiyaç duyulmaktadır. Bu tez çalışmasında hiperspektral görüntülerin sınıflandırılması üzerine çalışılmıştır. Son yıllarda Destek Vektör Makineleri (DVM) hiperspektral görüntülerin sınıflandırılmasında yüksek başarımlar sağlanmasından dolayı yaygın olarak kullanılmaktadır. Bu tez çalışmasında DVM sınıflandırma başarımlarını daha da arttıran özgün yöntemler geliştirilmiştir: i) Ampirik Kip Ayrışımı temelli yaklaşımlar kullanılarak DVM sınıflandırma başarımları büyük oranda arttırılmıştır, ii) uzamsal ve spektral bilgilerin bir arada kullanılması amacı ile çok-çözünürlüklü DVM sınıflandırma yöntemi geliştirilerek DVM sınıflandırma başarımları arttırılmıştır, iii) sınıfları birbirinden ayıran ayırtaç düzlemine yakın olan eğitim örneklerinin DVM eğitim aşamasında kullanılmasıyla DVM sınıflandırma başarımları arttırılmıştır, iv) işaretin frekans bileşenlerini spektral ekseninde doğrusal olmayan şekilde değiştiren spektral bükme yöntemi kullanılarak DVM sınıflandırma başarımları arttırılmıştır.

Hiperspektral görüntülerin yüksek bant sayısına sahip olması sınıflandırma yöntemlerinin hesapsal yükünü arttırmaktadır. Ayrıca dar dalga boylarında veri yakalandığı için ardışık bantlar arasında ilinti yüksek olmakta ve bunun sonucunda artıklık oluşmaktadır. Bu nedenle sınıflandırma öncesi bant azaltımı yöntemleri kullanılarak artıklık elenebilir ve hesapsal yük azaltılabilir. Bu tez çalışmasında faz ilintisi temelli bir bant seçme yöntemi geliştirilmiştir ve ayrıca mevcut bant seçme yöntemlerinin hesapsal yükünü azaltmak amacı ile bir-bit dönüşümü temelli bir yöntem önerilmiştir.

Hiperspektral görüntülerin yorumlanması nedeniyle renkli görüntülenmesi önemlidir ve bu tez çalışmasında bir-bit dönüşümü temelli düşük hesapsal maliyetli renkli görüntüleme yöntemi önerilmiştir.

HYPERSPECTRAL IMAGE CLASSIFICATION WITH HIGH ACCURACY

Begüm DEMİR

Keywords: Remote Sensing, Hyperspectral Imaging, Hyperspectral Image Classification, Empirical Mode Decomposition, Spectral (Frequency) Warping, Phase Correlation, One Bit Transform, Band Reduction, Color Display of Hyperspectral Images

Abstract: Hyperspectral imaging sensors provide high resolution spectral information acquiring data corresponding to hundreds of narrow spectral bands. Hyperspectral images provide very useful information for several applications, and it is necessary to develop automatic techniques for efficient analysis of the data. In this thesis, we focus our attention on hyperspectral image classification. Support Vector Machine (SVM) classifier became very popular in recent years because of its high accuracy. In this thesis, we have developed novel methods to further improve the classification performance of SVM: i) Empirical Mode Decomposition based methods have been proposed and resulted in significantly improved SVM accuracy, ii) in order to use both spectral and spatial information, multi-resolution SVM classifier has been presented with improved SVM accuracy, iii) an accurate SVM classification algorithm, which uses border training patterns that are close to the separating hyperplane has been proposed and resulted in improved SVM accuracy and iv) it has been proposed to increase SVM classification accuracy using spectral warping which is a non-linear transformation that warps the frequency content of a signal.

The computational complexity of processing hyperspectral images is very high due to the high number of image bands. Also close image bands have high spatial correlation and therefore have redundancy. It is possible to remove redundancy and as a result reduce the computational complexity before classification by means of band reduction algorithms. In this thesis, a phase correlation based band selection algorithm has been proposed and a one bit transform based pre-processing approach has been presented in order to reduce the complexity of standard band selection algorithms.

In order to interpret hyperspectral images, color display algorithms are needed. In this thesis we have also presented a low computational complexity color display approach based on one bit transform.

1. GİRİŞ

1.1. Hiperspektral Görüntüleme

Uzaktan algılama yeryüzünün ve yer kaynaklarının fiziksel bağlantı kurmadan algılayıcı sistemleri kullanarak incelenmesini sağlamaktadır. Uzaktan algılama kullanılan enerji kaynaklarına göre aktif algılama ve pasif algılama olmak üzere ikiye ayrılmaktadır. Pasif algılama yapan algılayıcılar güneş gibi doğal bir kaynağın gönderdiği ışınlar vasıtasıyla nesnelere yansıyan veya yayılan elektromanyetik ışınımı algılar. Pasif algılayıcılarda ölçülen enerji genellikle birçok spektral bantta toplanmaktadır. Bu çeşit algılayıcılar multispektral algılayıcılar olarak bilinmektedir. İleri multispektral algılayıcılar, yüzlerce dar spektral bantta veri alan hiperspektral algılayıcılar. Aktif algılama sistemlerinde ise algılayıcılar güneş enerjisine ihtiyaç duymazlar ve yapay bir enerji kaynağı tarafından üretilen enerjinin hedeften saçılımını algırlar. Radar sistemleri, (örneğin gerçek açıklıklı radar (real aperture radar) ve yapay açıklıklı radar (synthetic aperture radar) aktif algılayıcıya örnek olarak verilebilir.

Günümüzde, yeni kuşak uzaktan algılama sistemleri yeryüzünü incelemek için birçok olanak sunmaktadır (örneğin iklim değişimleri, kentleşme, orman yangınları, kıyı kesimleri, su kalitesi, toprak kayması gibi olayların incelenmesi, kirlilik yaratan etmenlerin belirlenmesi). Bu sorunların çözümü için kullanılan hiperspektral algılayıcılar yeryüzü arazisinin sınıflandırılması ve bu yapıya ait sınıfların belirlenmesinde yüksek başarımlar sunmaktadır [1]. Hiperspektral görüntüleme algılayıcıları elektromanyetik spektrumun oldukça geniş bir aralığında yüksek çözünürlüklü spektral bilgi sağlamaktadır. Bu nedenle uzaktan algılama uygulamalarında, örneğin sahne içerisindeki bölgelerin sınıflandırılmasında veya belirli malzeme/nesnelerin tanınmasında, hiperspektral görüntüler kullanılarak yüksek başarımlar elde edilebilmektedir. Hiperspektral sınıflandırma ve tanıma yöntemlerinin; askeri ve savunma, medikal, tarım, hayvancılık, tekstil, çevre,

madencilik, kimlik tespiti gibi deęişik alanlarında uygulamaları bulunmaktadır. Hiperspektral görüntüleme ile her görüntü elemanı için çok yüksek bir veri miktarı elde edilebildiğinden, özellikle algılama uygulamaları ve örselemeyen (non-destructive) incelemeler için çok kullanışlıdır. Hiperspektral algılama, farklı malzemelerin moleküler birleşimlerine baęlı olarak belirli dalga boylarında farklı örüntülerde elektromanyetik enerji yansıma, soęurma ve salım 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 uçaktan ve MODIS, CHRIS/Proba, Hyperion uydularından alınabilmektedir. Tablo 1.1'de başlıca hiperspektral algılayıcılar ve spektral özellikleri gösterilmektedir. Yakın gelecekte İtalyan Uzay Merkezi ASI ve Alman Uzay Merkezi DLR yüksek çözünürlüklü hyperpektral algılayıcı içeren, isimleri sırasıyla PRISMA ve En-MAP olan yeni uydular fırlatacaktır. PRISMA algılayıcısı, spektral çözünürlüğü 10 nm, spektral aralığı 400-2500 nm ve uzamsal çözünürlüğü 20-30 m olan bir hiperspektral algılayıcı ile uzamsal çözünürlüğü 2.5-5 m olan bir pankromatik kamera içerecektir.

Tablo 1.1: Başlıca hiperspektral algılayıcılar ve spektral özellikleri [2]

Algılayıcı	Üretici	Platform	Toplam Bant Sayısı	Spektral Çözünürlük	Spektral Aralık
Hyperion on EO-1	NASA Goddard Space Flight Center	Uydu	220	10 nm	0.4 -2.5 μm
MODIS	NASA	Uydu	36	40 nm	0.4-14.3 μm
CHRIS Proba	ESA	Uydu	63	1.25 nm	0.415-1.05 μm
AVIRIS	NASA Jet Propulsion Lab	Uçak	224	10 nm	0.4 -2.5 μm
HYDICE	Naval Research Lab	Uçak	210	7.6 nm	0.4 -2.5 μm
PROBE-1	Earth Search Sciences Inc.	Uçak	128	12 nm	0.4-2.45 μm
CASI 550	ITRES Research Limited	Uçak	288	1.9 nm	0.4-1 μm
CASI 1500	ITRES Research Limited aerial	Uçak	288	2.5 nm	0.4-1.05 μm
SASI 600	ITRES Research Limited	Uçak	100	15 nm	0.95 - 2.45 μm
TASI 600	ITRES Research Limited	Uçak	64	250 nm	8- 11.5 μm
HyMap	Integrated Spectronics	Uçak	125	17 nm	0.4- 2.5 μm
RODIS	DLR	Uçak	84	7.6 nm	0.43-0.85 μm
EPS-H (Environmental Protection System)	GER Corporation	Uçak	133	0.67 nm	0.43 - 12.5 μm
EPS-A (Environmental Protection System)	GER Corporation	Uçak	31	23 nm	0.43 - 12.5 μm
AISA	Eagle Spectral Imaging	Uçak	244	2.3 nm	0.4 -0.97 μm
AISA	Eaglet Spectral Imaging	Uçak	200	-	0.4 -1.0 μm
AISA	Hawk Spectral Imaging	Uçak	320	8.5 nm	0.97-2.45 μm
AISA	Dual Spectral Imaging	Uçak	500	2.9 nm	0.4-2.45 μm
AVNIR	OKSI	Uçak	60	10 nm	0.43-1.03 μm

1.2. Hiperspektral Görüntülerin Sınıflandırılmasında Karşılaşılan Sorunlar ve Çözüme Yönelik Son Gelişmeler

Bir önceki bölümde bahsedilen hiperspektral görüntü uygulamalarını gerçekleştirebilmek amacıyla hiperspektral görüntülerin etkili analizini gerçekleştirebilecek algoritmalara ihtiyaç duyulmaktadır. Bu tez çalışmasında hiperspektral görüntülerin sınıflandırılması üzerine çalışılmıştır. Hiperspektral görüntüler ile yüksek miktarda veri elde edilmesi sınıflandırma problemlerini karmaşık hale getirmektedir. Aşağıda belirtilen bazı kritik problemler hiperspektral veri sınıflandırması için önemlidir. Bu sorunlar şu başlıklarda toplanabilir: (i) büyük miktardaki spektral bant sayısı, (ii) spektral imzanın uzamsal değişebilirliği, (iii) doğru sınıflandırmanın yüksek maliyeti, (iv) verinin kalitesi. Özellikle, büyük miktardaki spektral bant sayısı ve düşük miktardaki etiketlenmiş eğitim kümesi, yüksek miktardaki boyut problemine (yani, Hughes olgusu) sebep olmaktadır ve bunun bir sonucu olarak da eğitim kümesinin aşırı uydurulması (overfitting) riski oluşmaktadır [3].

Hiperspektral verilerin sınıflandırılmasında istenen özellikler büyük miktardaki spektral bant sayısı ve düşük miktardaki eğitim kümesi kullanarak başarıyı yüksek sınıflandırma sonuçları elde etmektir [3]. Multispektral ve hiperspektral görüntülerin sınıflandırılması için literatürde farklı sınıflandırma yöntemleri önerilmiştir. Multispektral görüntülerin sınıflandırılmasında yapay sinir ağları (örneğin çok katmanlı algılayıcılar (multilayer perceptrons)) [4]-[6] ve merkezci taban fonksiyonlu sinir ağları (radial basis function neural networks) [7]-[10] başarıyla kullanılmış olmasına rağmen, bu yöntemler hiperspektral görüntülerdeki yüksek miktardaki bant sayısından dolayı kullanışlı değildir. Son yıllarda Destek Vektör Makineleri (DVM) hiperspektral görüntülerin sınıflandırılmasında yaygın olarak kullanılmaktadır [11-16]. DVM'nin hiperspektral görüntülerin sınıflandırılmasındaki başarıyı iki sebep ile açıklanabilir: i) büyük miktardaki giriş verisini etkili şekilde kullanabilir, ii) seyrek çözümler sağlar (sınıfları birbirinden ayıran karar düzlemi eğitim verisinin alt kümesinin fonksiyonu olarak tanımlanır) [11]. Hiperspektral görüntülerin sınıflandırılması için uzaktan algılama literatüründe son yıllarda kullanılmaya başlanılan diğer bir yöntem ise çekirdek Fisher ayırtaç (ÇFA), (kernel

Fisher discriminant) [17], [18] ve İlgililik Vektör Makineleri (İVM) [19] yöntemleridir. DVM, İVM ve ÇFA sınıflandırma yöntemleri çekirdek (kernel) temelli yöntemler grubunda yer almaktadır. Çekirdek temelli yöntemler veriyi giriş öznitelik uzayından doğrusal olmayan bir dönüşümle yüksek boyutlu bir çekirdek öznitelik uzayına taşımaktadır ve bu uzayda doğrusal sınıflandırma problemini çözmektedir. Son yıllarda örüntü tanıma alanında birçok etkili çekirdek temelli sınıflandırma yöntemi önerilmiştir (örneğin DVM [20], ÇFA analizi [17], destek vektör toplama (support vector clustering) [21], düzenlenmiş AdaBoost algoritması [22]). Çekirdek temelli yöntemlerin farklı alanlardaki başarılı uygulamaları [23]'de belirtilmiştir. Hiperspektral görüntülerin sınıflandırılmasında farklı çekirdek temelli yöntemlerin karşılaştırılması üzerine [11]'de çalışılmıştır. [11]'de önerilen çalışmada DVM tabanlı hiperspektral görüntü sınıflandırma yöntemlerinin, diğer çekirdek temelli yöntemler ile karşılaştırıldığında daha yüksek başarımlar sağladığı gösterilmiştir. Son yıllarda devam eden çalışmalar iki noktada verimliliğin artırılmasına çalışmaktadır: 1) sınıflandırma başarımlarının daha da artırılması, 2) sınıflandırma yöntemlerinin eğitim ve test aşamasındaki hesapsal yükünün azaltılması.

Hiperspektral görüntülerin sınıflandırılmasında spektral öznitelikler birincil ayırma özellikleri olarak kullanılmasına rağmen, uzamsal özniteliklerin de kullanılmasının sınıflandırma başarımlarını arttırdığı gözlemlenmiştir. Bu nedenle hiperspektral görüntülerin sınıflandırılması için spektral ve uzamsal bilgileri birlikte kullanan algoritmalar önerilmiştir [24]-[28]. [24]'de uzamsal ve spektral bilgilerin birleştirilmesini sağlayan birleşik çekirdekler kullanılarak DVM sınıflandırma başarımlarının artırılabilirliği gösterilmiştir. Uzamsal ve spektral öznitelik vektörleri için çekirdek matrisleri ayrı ayrı hesaplanmaktadır ve sonrasında farklı çekirdek birleştirme yaklaşımları kullanılarak çekirdekler birleştirilmektedir. Her bir uzamsal öznitelik vektörü komşu piksellerin ortalama değerleri ya da komşu piksellerin ortalama ve standart sapma değerleri olarak elde edilmektedir. [25] ve [26]'da hiperspektral görüntülerin sınıflandırılması için biçimbilimsel profiller kullanılması önerilmiştir. Başlangıç olarak Temel Bileşen Analizi (TBA) hiperspektral görüntülere uygulanarak temel bileşenler elde edilmektedir. Sonrasında, temel bileşenlere ardı ardına açma-kapama işlemleri uygulanarak biçimbilimsel profiller

elde edilmektedir. [25]'de önerilen çalışmada biçimbilimsel profiller doğrudan yapay sinir ağları ile sınıflandırmada kullanılmıştır. [26]'da ise orijinal spektral veriler ve biçimbilimsel profiller birleştirilerek (ardı ardına eklenerek) DVM ile sınıflandırılmıştır. Spektral ve uzamsal bilgilerin Markov Rassal Alanlar (Markov Random Field) temelli birleştirilmesi [27]'de ve havza (watershed) toplama yöntemi temelli birleştirilmesi [28]'de önerilmiştir.

Son zamanlarda DVM sınıflandırma başarımını arttırmak amacıyla önerilen diğer bir yaklaşım ise karar tümleştirme algoritmalarının kullanımudur. Bu yöntemlerde sınıflandırma algoritmalarının sonuçları birbirinden bağımsız olarak elde edilmektedir ve karar tümleştirme algoritmaları kullanarak sonuçlar tümleştirilmektedir. [29]'da önerilen çalışmada spektral bantlar arası ilintiye göre hiperspektral veriler farklı gruplara ayrılmakta ve her bir grup diğer gruptan bağımsız olacak şekilde DVM ile sınıflandırılmaktadır. Son olarak, karar tümleştirme işlemi ile sonuçlar birleştirilmektedir.[30]'da ise ayrık dalgacık dönüşümü kullanarak çoklu sınıflandırıcılar elde edilmektedir. Ayrık dalgacık dönüşümü sonucu farklı seviyelerde oluşan alçak frekans bileşenleri birbirinden bağımsız olarak DVM ile sınıflandırılmaktadır. Karar tümleştirme işlemi çoğunluk oylaması yöntemi (majority voting) kullanarak gerçekleştirilmektedir. [31]'de, spektral ve uzamsal bilgilerin karar tümleştirme algoritmaları temelli birleştirilmesi önerilmiştir. Uzamsal bilgiler biçimbilimsel profiller ile ifade edilmektedir. Biçimbilimsel profiller TBA'nın hiperspektral görüntülere uygulanması sonucu temel bileşenlerin elde edilmesi ve elde edilen temel bileşenlere ardı ardına açma-kapama işlemleri uygulanması sonucu elde edilmektedir. Sonrasında orijinal hiperspektral veri ve biçimbilimsel profiller ayrı ayrı DVM ile sınıflandırılmakta ve sınıflandırma sonuçları çoğunluk oylaması gibi karar tümleştirme algoritmaları ile birleştirilmektedir. [32]'de ise DVM sınıflandırma yönteminin sonuçlarının, eğitimsiz sınıflandırma yöntemi olan K -ortalama toplama yöntemi sonuçlarıyla tümleştirilmesi önerilmiştir. Bu çalışmada K -ortalama yöntemi kullanılarak spektral imzaların sınıf içi değişiminin etkisi azaltılmakta ve DVM sınıflandırma yönteminin başarımı artırılmaktadır.

Hiperspektral görüntülerin yüksek öznitelik (bant) sayısına sahip olması nedeniyle sınıflandırma ve tanıma uygulamalarının hesapsal karmaşıklığı fazla olmaktadır.

Birbirine benzer spektral bantlar arasındaki artıklık bant azaltımı yöntemleri kullanılarak azaltılmaktadır. Bu yöntemler genel olarak öznitelik seçimi ve öznitelik çıkarımı olmak üzere iki kategoride incelenmektedir. Öznitelik çıkarımı yöntemleri kullanarak orijinal özniteliklerin birleşimi ile oluşan istenen sayıda yeni öznitelikler içeren veri kümesi elde edilmekte ve d boyutlu öznitelik uzayından, giriş verisini en iyi şekilde temsil edecek m adet özniteliğin ($m < d$) belirlenmesi amaçlanmaktadır [33-37]. Hiperspektral görüntülerde bant çıkarımı için TBA (TBA ile ilgili detaylı bilgi Bölüm 8.3’de verilmiştir) ve bağımsız bileşen analizi sırasıyla [33] ve [34]’de önerilmiştir. İki farklı öznitelik çıkarımı yöntemi, karar sınırı öznitelik çıkarımı (decision boundary feature extraction) ve parametrik olmayan ağırlıklandırılmış öznitelik çıkarımı (nonparametric weighted feature extraction) [35]’de kullanılmıştır. Dalgacık dönüşümü birçok işaret işleme alanında olduğu gibi hiperspektral görüntülerde de öznitelik ayrıştırımı için kullanılmıştır [36]. Hiperspektral görüntülerde bant çıkarımı için uygulanan çeşitli eğitimsiz bant çıkarımı yöntemleri ve bu yöntemlerin sınıflandırma yöntemleri üzerindeki etkileri [37]’de karşılaştırılmıştır. Öznitelik seçimi yöntemleri alt-küme seçme algoritmaları ve öznitelik ağırlıklandırma algoritmaları olarak iki grupta incelenebilir. Alt-küme seçme algoritmaları çeşitli arama stratejileri kullanarak d boyutlu orijinal veri kümesini ifade eden en iyi m adet öznitelik ($m < d$) içeren alt-kümeyi bulmayı hedeflemektedir [38]-[41]. Elde edilen m adet özniteliğin veri hakkında en fazla bilgiyi temsil etmesi amaçlanmaktadır. Öznitelik seçimi yöntemleri, sınıflandırma yöntemlerinin eğitim ve test sürelerinin azaltılmasını ve gürültülü ve yararsız özniteliklerin elenmesini sağlamaktadır. Öznitelik ağırlıklandırma temelli yöntemlerde, her bir öznitelik için ağırlık değerleri belirlenmekte ve yüksek ağırlığa sahip olan öznitelikler korunurken, düşük ağırlığa sahip olan öznitelikler elenmektedir. Hiperspektral görüntüler için öznitelik ağırlıklandırma temelli bant seçimi yaklaşımı [38]’de önerilmiştir. [38]’de artık bantların atılması aşamasında standart çapraz ilinti kullanılmaktadır. Bant seçimi için kullanılan en temel alt küme seçme yöntemleri, ileriye doğru ve geriye doğru öznitelik seçme yöntemleridir [39]. İleriye doğru öznitelik seçme algoritması boş öznitelik kümesinden başlayarak ve en yararlılarını ekleyerek en iyi alt kümeyi bulmaktayken, geriye doğru öznitelik seçme algoritması ise tüm öznitelik kümesinden başlayarak en yararsızları eleyerek en iyi alt kümeyi elde etmektedir. Alt küme seçimi yöntemleri [40]’da karşılaştırılarak

sınıflandırma yöntemlerine etkileri incelenmiştir. En hızlı tırmanış (Steepest Ascent) bant seçimi algoritması hiperspektral görüntülerde öznelik seçimi amacı ile [41]'de önerilmiştir.

1.3. Tez Çalışmasının Amaç ve Kapsamı

Bu tez çalışmasının genel amaç ve kapsamı, hiperspektral görüntülerin sınıflandırılmasında yaygın olarak kullanılan DVM sınıflandırma yönteminin sınıflandırma başarımının artırılması ve hesapsal yükünün azaltılması amacıyla özgün yöntemler geliştirmektir. Geliştirilen özgün yöntemler aşağıda belirtilen çalışma paketleri ile özetlenmektedir.

1- Ampirik Kip Ayırışımı (AKA) temelli hiperspektral sınıflandırma: AKA uyarlamalı ve doğrusal olmayan bir işaret ayırışım yöntemidir [42]. Fourier dönüşümünde verinin doğrusal ve durağan olduğu varsayılıyorken, AKA veri hakkında hiçbir varsayımda bulunmamaktadır ve veriyi içkin (intrinsic) kip fonksiyonlarına (İKİF) ayırıştırmaktadır. Bu nedenle AKA'nın özellikle doğrusal olmayan ve/veya durağan olmayan zaman serilerinde Fourier ve Dalgacık dönüşümlerinden daha başarılı olduğu literatürdeki çalışmalarda gösterilmiştir. AKA sonucunda veri yerel frekans bileşenlerine ayırışmaktadır: Birinci İKİF yerel en yüksek frekans bileşenlerini içermektedir, ikinci İKİF bir sonraki yerel en yüksek frekans bileşenlerini içermektedir. Yüksek dereceli İKİF'ler ise yerel düşük frekans bileşenlerini içermektedir. Bu çalışma paketinde AKA temelli yöntemler geliştirilerek hiperspektral görüntülerdeki her bir bandın piksel değerlerinin satır satır taranarak elde edilmesi sırasında oluşan yerel düşük frekans bileşenlerinin veriden arındırılması amaçlanmaktadır. Bu sayede DVM sınıflandırma başarımının artması beklenmektedir. Ayrıca geliştirilen AKA temelli yöntemler ile uzamsal ve spektral bilgilerin birlikte kullanılması amaçlanmaktadır ve bunun sonucunda sınıflar arası uzaklıkların önemli bir oranda artması ve sınıf içi değişimlerin azalması beklenmektedir. Ayrıca satır satır tarama işlemlerinden dolayı oluşan yerel düşük frekanslarının sınıflandırmaya dahil edilmemesi nedeniyle hiperspektral verilerin sınıflandırılmasında yüksek başarımlar elde edilmesi amaçlanmaktadır. Bu amaçla bu tez kapsamında AKA ilk defa hiperspektral görüntü bantlarına uygulanarak her bir

bant ile ilişkili İKF'ler elde edilmektedir. Sonrasında gerçekleştirilen özgün çalışmalar 4 alt başlıkta özetlenebilir: i) üst seviyedeki İKF'lerin toplanarak elde edilen yeni veri üzerinden DVM sınıflandırma gerçekleştirilmiştir, ii) birinci İKF'ye gürültü giderimi uygulandıktan sonra üst seviyedeki İKF'lerin toplanarak elde edilen yeni veri üzerinden DVM sınıflandırma uygulanmıştır, iii) her bir bant için elde edilen birinci ve ikinci İKF'lerin içerdiği bilgiler birleşik çekirdekler kullanılarak birleştirilmiştir ve iv) AKA temelli karar tümleştirme yöntemi geliştirilmiştir.

2- Bir-bit dönüşümü (1-BD) temelli yaklaşımlar: 1-BD [43, 44], videoda basit ve hızlı hareket kestirimi için video çerçevesinin bir-bit derinliğe indirilmesi ve bu sayede mantıksal D-VEYA tabanlı hızlı bir karşılaştırma yapılması için önerilmiştir. Bu çalışma paketinde ise gerçekleştirilmesi basit, hesapsal yükü az ve donanımsal olarak gerçekleştirilmeye uygun 1-BD temelli bant eleme yöntemi geliştirilmesi amaçlanmaktadır. Bir-bit dönüşümü özgün olarak hiperspektral verilere uygulanarak, i) hiperspektral verilerde bant azaltımı yöntemlerinin hesapsal karmaşıklığının 1-BD temelli bir ön işlem kullanılarak azaltılması ve ii) hiperspektral görüntülerin 1-BD temelli özgün bir yöntem kullanılarak renkli görüntülenmesi amaçlanmaktadır. Geliştirilen özgün 1-BD temelli yöntemler donanımsal olarak gerçekleştirilmeye uygundur ve FPGA ile gerçekleştirilmesi üzerine [117]'de çalışılmıştır.

3- Yüksek doğrulukta DVM sınıflandırma için sınır vektörlerinin toplama temelli çıkarımı: Sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın olan eğitim örneklerinin DVM eğitimde kullanılması sonucu DVM sınıflandırma başarımı arttırılmaktadır. Literatürde var olan çalışmalarda sınır eğitim örnekleri görüntü yorumlama (photo-interpretation) teknikleri kullanılarak bulunmuştur [76-78]. Bu bölümde geliştirilen çalışma ile sınır eğitim örneklerinin toplama temelli bir yöntem geliştirilerek otomatik olarak elde edilmesi amaçlanmaktadır. Sınır eğitim örneklerinin toplama temelli çıkarımı ilk defa bu tez kapsamında önerilmiştir. Geliştirilen yöntem toplama maliyeti ve SVM eğitim aşamasının iki kere uygulanması nedeniyle sınıflandırma öncesi işlem yükünü arttırmaktadır fakat sınıflandırma (test) aşaması hesaplanma süresi doğrudan DVM yöntemiyle benzerdir.

4- Çok-çözünürlüklü yapılarla tümleştirme: Bu bölümde geliştirilen çalışma ile sıradüzensel DVM sınıflandırma yöntemi geliştirilerek uzamsal ve spektral bilgilerin birlikte kullanılması amaçlanmaktadır. DVM sınıflandırma yönteminin çok-çözünürlüklü yapılarla birleştirilerek hız ve başarımların artırılması elde edilmesi amaçlanmaktadır. Çok-çözünürlüklü yapıları elde etmek için dalgacık dönüşümü kullanılmıştır. Bu çalışmada her banda r ($r > 1$) seviye dalgacık dönüşümü uygulanarak çok-çözünürlüklü bir yapı elde edilmiştir. Her seviyede önce alçak frekans bileşenleri sınıflandırmada kullanılmakta ve sonrasında bu sonuçlar üzerinden yüksek çözünürlüklü bilgiye geçilmekte ve bu sayede çok-çözünürlüklü bir yapı üzerinden sınıflandırma gerçekleştirilmektedir. Önerilen yöntem ile sınıflandırma aşaması çok-çözünürlüklü bir yapı üzerinden gerçekleştiği için sınıflandırma (test) aşamasındaki hesapsal yük azalmaktadır.

5- Faz ilintisi temelli yaklaşımlar: Faz ilintisi, iki işaret arasındaki benzerliğin ve işaretler arasındaki ötelemenin bulunmasında kullanılan bir frekans uzayı yöntemidir [45]. Literatürde faz ilintisi yönteminin standart çapraz ilintiye göre daha başarılı bir benzerlik ölçütü olduğu gösterilmiştir. Bu çalışma paketinde faz ilintisi hiperspektral görüntülere uygulanarak i) özgün faz ilintisi temelli bant azaltımı yöntemi geliştirilmektedir ve bantlar arası benzerliğin bulunmasında faz ilintisi ve çapraz ilintinin başarımlarını karşılaştırması yapılmaktadır ve ii) özgün faz ilintisi temelli eğitimli sınıflandırma yöntemi geliştirilmektedir ve spektral veriler arasında benzerlik ölçütü olarak faz ilintisi kullanılmasının sınıflandırma başarımına etkisi değerlendirilmektedir.

6- Spektral genlik ve spektral türev özniteliklerini birleştirerek hiperspektral görüntülerde sınıflandırma: Hiperspektral görüntülerde spektral genlik öznitelikleri (piksellerin farklı dalga boylarındaki yansıtıcılık değerleri) sınıflandırma algoritmalarında yaygın olarak kullanılmaktadır. Spektral türev öznitelikleri atmosferik etkilerden ve aydınlatma hatalarından etkilenmemesi nedeniyle önemli özniteliklerdir. Fakat hiperspektral görüntülerde sınıflandırma başarımına etkisi daha önce araştırılmamıştır. Bu çalışma paketinde hiperspektral görüntülerde, spektral genlik ve spektral türev özniteliklerinin öznitelik çıkarımı yöntemi ile veya doğrudan ardı ardına eklenerek birleştirilerek elde edilen DVM sınıflandırma başarımının

değerlendirilmektedir. Spektral genlik ve spektral türev özniteliklerinin birleştirilmesi yöntemleri ilk defa bu tez kapsamında önerilmiştir.

7-Düşük sayıda eğitim verisine sahip hiperspektral görüntülerin sınıflandırma başarımının örnek aradeğerleme yaklaşımı kullanılarak artırılması: Güvenilir eğitim verisi elde etmek zaman alıcı ve masraflı işlemler gerektirmektedir ve DVM sınıflandırma başarımı doğrudan eğitim verisinin kalitesine bağlıdır. Ayrıca hiperspektral görüntülerde yüksek miktardaki bant sayısı ve düşük miktardaki eğitim örneği sayısı yüksek boyut problemine sebep olmaktadır. Bunun sonucunda sınıflandırma başarımı düşmektedir. Bu çalışma paketinde düşük sayıda eğitim verisine sahip hiperspektral görüntülerin sınıflandırma verimliliğini arttırmak amacıyla orijinal eğitim verisinin iki farklı aradeğerleme yaklaşımı kullanılarak basit bir yaklaşım ile artırılması amaçlanmaktadır. Geliştirilen örnek aradeğerleme yöntemleri ilk defa bu tez kapsamında önerilmiştir.

8-Spektral bükme ile sınıflandırma başarımının artırılması: Spektral bükme (warping) işleminde, frekans bileşenleri, spektral eksende doğrusal olmayan şekilde değiştirilmektedir ve bu işlem birinci dereceden seri tüm geçiren süzgeçler kullanılarak elde edilmektedir [46]. Bu işlem sonucunda işaretin frekans bileşenleri frekansta yayılmaktayken, zamanda işaretle daralma olmaktadır ve bu nedenle işaretin enerjisi ilk zaman örneklerinde toplanmaktadır. Bu bölümde önerilen çalışma ile spektral bükme yöntemi kullanılarak yüksek boyut probleminin (Hughes olgusunun) etkisinin azaltılması amaçlanmaktadır ve bunun sonucunda DVM sınıflandırma başarımında artış beklenmektedir. Spektral bükme yöntemi ilk defa bu tez çalışmasında hiperspektral görüntülerin her bir pikseli ile ilişkili spektral verilere uygulanmaktadır.

Bu tez çalışması 11 bölümde düzenlenmiştir. 1. Bölüm'de hiperspektral görüntüler ve uygulamaları hakkında bilgi verilmektedir. Ayrıca bu bölümde hiperspektral görüntülerin sınıflandırılmasında karşılaşılan sorunlar ve çözüme yönelik son gelişmeler ile birlikte bu tez çalışmasının amaç ve kapsamı açıklanmıştır. Bölüm 2'de tez kapsamında kullanılan hiperspektral veriler hakkında detaylı bilgiler verilmiştir. Bölüm 3'de AKA temelli hiperspektral sınıflandırma yöntemi ve Bölüm

4’de 1-BD temelli yaklaşımlar detaylı olarak açıklanmıştır. Bölüm 5’de sınır vektörlerinin toplama temelli bulunması anlatılmıştır. Bölüm 6’da dalgacık dönüşümü temelli çok-çözünürlüklü yapılar kullanılarak DVM sınıflandırma başarımının artırılacağı gösterilmiştir. Faz ilintisi temelli yaklaşımlar detaylı olarak Bölüm 7’de incelenmiştir. Genlik ve türev özniteliklerinin birleştirilmesi sonucu elde edilen DVM sınıflandırma sonuçları ise Bölüm 8’de verilmiştir. Bölüm 9’da düşük sayıda eğitim verisine sahip hiperspektral görüntülerin sınıflandırma başarımının örnek aradeğerleme yaklaşımı kullanılarak artırılabilirdiği gösterilmiştir. Spektral bükme yönteminin DVM sınıflandırma sonuçlarına etkisi Bölüm 10’da değerlendirilmiştir. Bölüm 11’de ise temel vargılar verilerek, gelecek çalışmalar hakkında bilgiler verilmiştir. Destek Vektör Makineleri (DVM) ile ilgili detaylı bilgi ise Ekler bölümünde verilmiştir.

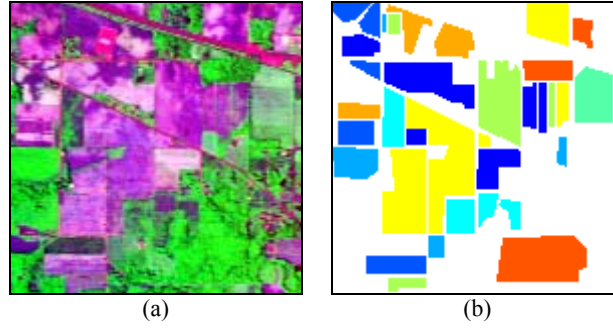
2. VERİ KÜMELERİ

Tez kapsamındaki yöntemlerin geliştirilmesi aşamasında Indian Pine, DC Mall, Botswana, Pavia ve Salinas olmak üzere 5 farklı hiperspektral veri kümesi kullanılmıştır.

Indian Pine hiperspektral görüntüsü, 220 bant içermektedir ve 1992 yılının Haziran ayında kuzeybatı Indiana'nın Indian Pine test alanında alınmıştır [47]. Uygulamada atmosferik etki ve gürültü içeren bantlar atılarak 200 bant kullanılmıştır. Her bir bant 145×145 piksel boyutlarındadır. Kullanılan her sınıf için mevcut yer doğrusu verisinin (ground truth) toplam piksel sayıları Indian Pine verisi için Tablo 2.1'de verilmiştir. Şekil 2.1'de ise Indian Pine verisinin renkli görüntüsü ve yer doğrusu verisi verilmiştir. Indian Pine verisinin renkli görüntüsü rasgele seçilen 3 bandın kırmızı-yeşil-mavi bileşenler olarak alınması sonucu elde edilmiştir. Yer doğrusu verisinde her bir sınıf için kullanılan etiketlenmiş örnekler (pikseller) farklı bir renkte gösterilmektedir. Beyaz renk ile gösterilen örnekler için ise etkilenmiş veri bulunmamaktadır ve sınıflandırmaya dahil edilmemektedir. Indian Pine veri kümesi yakın özelliklerdeki farklı sınıfların spektral imzalarındaki yüksek benzerlikten dolayı sınıflandırılması göreceli olarak daha zor olan bir veri kümesidir.

Tablo 2.1: Indian Pine verisi için kullanılan 9 sınıfın toplam piksel sayıları (TPS)

Sınıf	TPS
Corn-no till	1434
Corn-min till	834
Grass/Pasture	497
Grass/Trees	747
Hay-windrowed	489
Soybean-no till	968
Soybean-min till	2468
Soybean-clean till	614
Woods	1294
Toplam	9345




Şekil 2.1: Indian Pine verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi

DC Mall hiperspektral görüntüsü 210 bant içermektedir. Uygulamada atmosferik etki ve gürültü içeren bantlar atılarak DC Mall verisi için 191 bant kullanılmıştır [1]. DC Mall verisinde her bir bant 1280×307 piksel boyutlarındadır. Kullanılan her sınıf için mevcut yer doğrusu verisinin toplam örnek sayıları DC Mall verisi için Tablo 2.2'de gösterilmektedir. Şekil 2.2'de ise DC Mall verisinin renkli görüntüsü ve yer doğrusu verisi gösterilmektedir. DC Mall verisinin renkli görüntüsü rasgele seçilen 3 bandın kırmızı-yeşil-mavi bileşenler olarak alınması sonucu elde edilmiştir. Yer doğrusu verisinde her bir sınıf için kullanılan etiketlenmiş örnekler (pikseller) farklı bir renkte gösterilmektedir. Beyaz renk ile gösterilen örnekler için ise etkilenmiş veri bulunmamaktadır ve sınıflandırmaya dahil edilmemektedir.

Tablo 2.2: DC Mall verisi için kullanılan 7 sınıfın toplam piksel sayıları (TPS)

Sınıf	TPS
Roof	3834
Street	416
Path	175
Grass	1928
Trees	405
Water	1224
Shadow	97
Toplam	8079




Şekil 2.2: DC Mall verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi

Botswana hiperspektral görüntüsü 242 bant içermektedir ve deneylerde atmosferik etki ve gürültü içeren bantların elenmesi sonucu kalan 145 bant kullanılmıştır [48]. Bu veride kullanılan her sınıf için mevcut yer doğrusu verisinin toplam piksel sayıları Tablo 2.3’de verilmiştir. Şekil 2.3’de ise Botswana verisinin renkli görüntüsü ve yer doğrusu verisi verilmiştir. Botswana verisinin renkli görüntüsü rasgele seçilen 3 bandın kırmızı-yeşil-mavi bileşenler olarak alınması sonucu elde edilmiştir. Yer doğrusu verisinde her bir sınıf için kullanılan etiketlenmiş örnekler (pikseller) farklı bir renkte gösterilmektedir. Beyaz renk ile gösterilen örnekler için ise etkilenmiş veri bulunmamaktadır ve sınıflandırmaya dahil edilmemektedir.

Tablo 2.3: Botswana verisi için kullanılan 14 sınıfın toplam piksel sayıları (TPS))

Sınıf	TPS
Water	270
Hippo grass	101
Floodplain grasses1	251
Floodplain grasses2	215
Reeds1	269
Riparian	269
Firescar2	259
Island interior	203
Acacia woodlands	314
Acacia shrublands	248
Acacia grasslands	305
Short mopane	181
Mixed mopane	268
Exposed soils	95
Toplam	3248



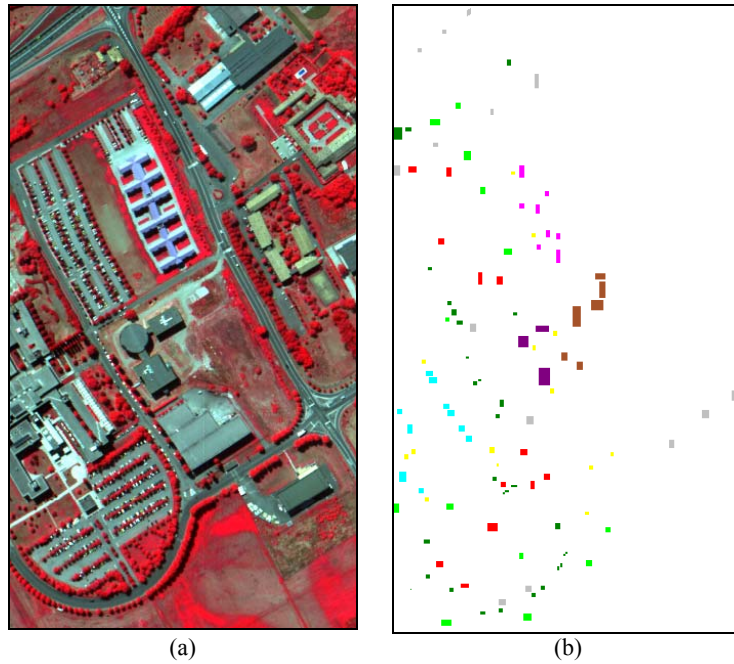
Şekil 2.3: Botswana verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi

Pavia Üniversitesi hiperspektral görüntüsü 115 bant içermektedir. Uygulamada atmosferik etki ve gürültü içeren bantlar atılarak Pavia verisi için 103 bant

kullanılmıştır [49]. Pavia verisinde her bir bant 610×340 piksel boyutlarındadır. Bu veride kullanılan her sınıf için mevcut yer doğrusu verisinin toplam piksel sayıları Tablo 2.4’de verilmiştir. Şekil 2.4’de ise Pavia verisinin renkli görüntüsü ve yer doğrusu verisi verilmiştir. Pavia verisinin renkli görüntüsü rasgele seçilen 3 bantın kırmızı-yeşil-mavi bileşenler olarak alınması sonucu elde edilmiştir. Yer doğrusu verisinde her bir sınıf için kullanılan etiketlenmiş örnekler (pikseller) farklı bir renkte gösterilmektedir. Beyaz renk ile gösterilen örnekler için ise etkilenmiş veri bulunmamaktadır ve sınıflandırmaya dahil edilmemektedir.

Tablo 2.4: Pavia verisi için kullanılan 9 sınıfın toplam piksel sayıları (TPS)

Sınıf	TPS
Asphalt	548
Meadows	540
Gravel	392
Trees	524
Metal Sheets	265
Bare Soil	532
Bitumen	375
Bricks	514
Shadow	231
Toplam	3921




Şekil 2.4: Pavia verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi

Salinas hiperspektral görüntüsü 224 bant içermektedir [119] ve deneylerde atmosferik etki ve gürültü içeren bantların elenmesi sonucu kalan 200 bant kullanılmıştır. Bu veride kullanılan her sınıf için mevcut yer doğrusu verisinin toplam piksel sayıları Tablo 2.5’de verilmiştir. Şekil 2.5’de ise Salinas verisinin renkli görüntüsü ve yer doğrusu verisi verilmiştir. Salinas verisinin renkli görüntüsü rasgele seçilen 3 bandın kırmızı-yeşil-mavi bileşenler olarak alınması sonucu elde edilmiştir. Yer doğrusu verisinde her bir sınıf için kullanılan etiketlenmiş örnekler (pikseller) farklı bir renkte gösterilmektedir. Beyaz renk ile gösterilen örnekler için ise etkilenmiş veri bulunmamaktadır ve sınıflandırmaya dahil edilmemektedir.

Tablo 2.5: Salinas verisi için kullanılan 7 sınıfın toplam piksel sayıları (TPS)

Sınıf	TPS
Vineyard-untrained	7134
Grapes-untrained	10365
Celery	1970
Fallow	2001
Fallow-smooth	1396
Fallow-rough-plow	735
Stubble	1725
Toplam	25326



Şekil 2.5: Salinas verisinin (a) renkli görüntüsü ve (b) yer doğrusu verisi

3. AMPİRİK KİP AYRIŞIMI TEMELLİ HİPERSPEKTRAL SINIFLANDIRMA

Bu bölümde hiperspektral görüntülerin yüksek başarımla sınıflandırılması için bu tez kapsamında geliştirilen Ampirik Kip Ayrışımı (AKA) temelli yaklaşımlar detaylı olarak incelenmektedir.

3.1. Güdülenme

Hilbert-Huang dönüşümü doğrusal ve durağan olmayan zaman serileri analizi için önerilmiştir [42] ve Ampirik Kip Ayrışımı (AKA) (Empirical Mode Decomposition) ve Hilbert spektral analizi olmak üzere iki temel bölüm içermektedir. AKA [42], doğrusal olmayan bir işaret ayrıştırma yöntemidir ve işareti İçkin Kip Fonksiyonlarına (İKF) (Intrinsic Mode Functions) ayırmakta, ek olarak kalan işaretini de vermektedir. İKF'ler bazı özellikler ile karakterize edilmektedir. Örneğin sıfır geçişlerinin sayısı, uç noktalarının (extreme points) sayısına eşit olmalı ya da aralarındaki fark bir olmalıdır. Diğer bir özellik ise işaretin her bir zaman örneği (time instant) için üst zarf ve alt zarfın ortalama değerinin sıfır olmasıdır. Üst zarf, işaretin yerel maksimum noktalarının aradeğerlemesi ile alt zarf ise yerel minimum noktalarının aradeğerlemesi ile bulunmaktadır.

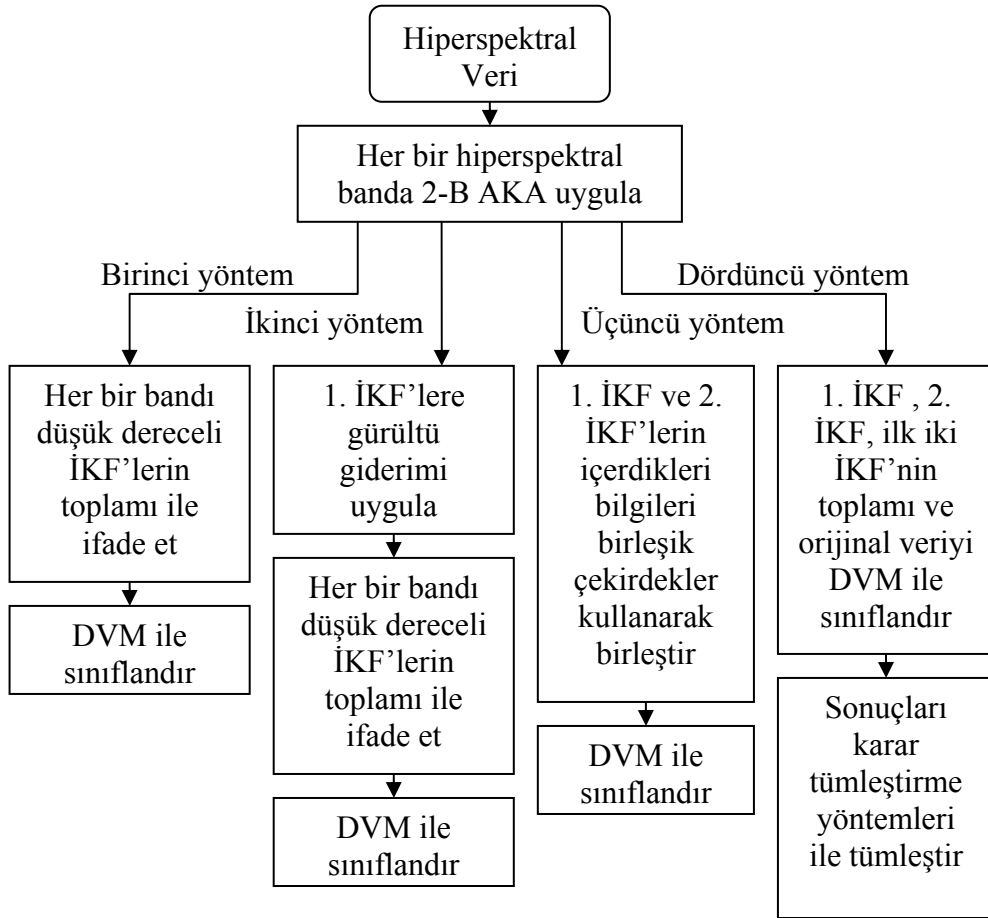
AKA, dalgacık ve Fourier dönüşümlerinden farklı olarak, doğrusal olmayan şekilde, daha verimli bir ayrıştırma sağlayabilmektedir. Birçok gerçek sistem doğrusal ve durağan olmamasına rağmen, Fourier dönüşümü gibi yaygın kullanılan dönüşümler tipik olarak sistemin doğrusal ve sinyalin durağan olduğunu varsaymaktadır [53]. İşaretlerin ayrıştırılmasında yaygın olarak kullanılan diğer bir yaklaşım olan dalgacık dönüşümü için farklı dalgacık tipleri kullanılabilir ve ayrıştırma başarımı dalgacık türüne göre değişebilmektedir. Bunun yanında, dalgacık dönüşümünde frekans ölçeği her zaman kullanılan ayrıştırma seviyesine bağlıdır. AKA ise taban fonksiyonlar içermemekte ve işareti içkin karakteristiğine göre ayrıştırmaktadır. Bu

nedenle, ayrıştırma sonucu oluşan alt işaretlerin frekansları değişkendir ve daha etkin bir ayrıştırma sağlanabilmektedir [54].

AKA'nın farklı işaret işleme uygulamaları bulunmaktadır. [54]'de önerilen çalışmada AKA ve dalgacık dönüşümü kullanılarak insanlarda oluşan katarakt algılama üzerine çalışılmıştır ve deneysel sonuçlar AKA'nın algılama yeteneğinin dalgacık dönüşümünden daha başarılı olduğunu göstermiştir. AKA ve dalgacık dönüşümü oransal kırıpca boyutu (fractal dimension) kestirimi amacıyla [55]'de karşılaştırılarak, AKA'nın dalgacık dönüşümüne göre başarımı gösterilmiştir. Öncelikle bir boyutlu (1-B) işaretler için uygulanmış olan bu ayrıştırma yöntemi [53], sonrasında iki boyutlu (2-B) işaretler için de uygulanır hale getirilmiştir. AKA, 2-B yüz görüntülerinde aydınlatma hatalarını kaldırmada ön işlem olarak [56]'da önerilmiştir. Burada 2-B yüz görüntüleri 1-B işaretlere dönüştürülerek 1-B AKA uygulanmıştır. AKA'nın doğrudan 2-B sinyaller için uygulanır hale getirilmesi üzerine [57, 58]'de çalışılarak 2-B AKA temelli görüntü sıkıştırılması algoritması geliştirilmiştir. [57, 58]'de 2-B AKA için hesapsal yükü özellikle piksel boyutu büyük veri kümeleri için oldukça fazla olan 2-B eğri aradeğerlemesi kullanılması önerilmiştir. [59, 60]'da ise 2-B eğri aradeğerleme yerine istatistiksel süzgeçler kullanan, düşük hesapsal maliyetli, hızlı ve özyinelemeli 2-B AKA algoritması önerilmiştir. İris tanıma [61], gürültü giderimi [62] gibi değişik kullanımları olan AKA, hiperspektral görüntülere sadece boyut azaltımı amacıyla uygulanmıştır [63].

AKA gerçek sistemlerin frekans bileşenlerine ayrıştırılmasında daha etkin olmasına rağmen, hiperspektral görüntülerde sadece bant azaltımı için kullanılmıştır [63]. Hiperspektral görüntülerin sınıflandırma performansını artırmak amacı ile her banda 2-B olarak uygulanması ilk defa bu tez çalışması kapsamında gerçekleştirilmiştir. Bu tez çalışmasında AKA temelli dört farklı yöntem geliştirilmiştir. Önerilen yaklaşımlarda, öncelikle, 2-B AKA hiperspektral görüntülerin her bir bandına uygulanmaktadır ve her bir bant ile ilişkili İKF'ler elde edilmektedir. Sonrasında dört farklı yöntem geliştirilmiştir: i) düşük dereceli İKF'lerin toplanarak elde edilen yeni veri üzerinden DVM sınıflandırma gerçekleştirilmiştir (detaylı bilgi Bölüm 3.4'de verilmektedir), ii) AKA ve dalgacık uzayında gürültü giderimi yöntemi birleştirilmiştir (detaylı bilgi Bölüm 3.5'de verilmektedir), iii) her bir bant için elde

edilen birinci ve ikinci İKF'lerin içerdiği bilgiler birleşik çekirdekler kullanılarak birleştirilmiştir (detaylı bilgi Bölüm 3.6'da verilmektedir) ve iv) AKA temelli karar tümleştirme yöntemi geliştirilmiştir (detaylı bilgi Bölüm 3.7'de verilmektedir). Geliştirilen AKA temelli yöntemlerin blok şeması Şekil 3.1'de gösterilmektedir. 2-B AKA'nın gerçekleştirilmesinde [57, 58]'de önerilen eğri aradeğerlemesi kullanan 2-B AKA ve [59, 60]'da önerilen istatistiksel süzgeçler kullanan hızlı 2-B AKA yöntemleri kullanılmıştır. 2-B AKA ve hızlı 2-B AKA algoritmaları sırasıyla Bölüm 3.2 ve Bölüm 3.3'de anlatılmaktadır.



Şekil 3.1: Gerçekleştirilen AKA temelli algoritmaların blok şeması

3.2. 2-B Ampirik Kip Ayrışımı

2-B AKA algoritması aşamalı olarak İKF'leri bulmaktadır ve algoritma aşağıda detaylı olarak açıklanmaktadır. Kullanılan gösterimlerde, $B_l(i, j)$, l . ($l=1,2,\dots,d$, d

toplam bant sayısını göstermektedir) orijinal hiperspektral bandı ve (i, j) uzamsal konumu göstermektedir. $\dot{I}KF_{l,m}$ l . hiperspektral bandın m . ($m = 1, 2, \dots, M$) İKF değerlerini göstermektedir ve $I_{l,m}^{(n)}$, l . bandın m . İKF değerlerini bulmak için kullanılan n . özyineleme değerleridir. 2-B AKA algoritması başlangıç olarak orijinal bant değerlerinden başlamaktadır.

$$I_{l,1}^{(1)}(i, j) = B_l(i, j) \quad (3.1)$$

1- $I_{l,m}^{(n)}(i, j)$ işaretinin bütün yerel maksimum ve yerel minimum noktalarının genlik ve pozisyonları bulunmaktadır.

2-Yerel maksimum noktalarının eğri aradeğerlenmesi ile üst zarf $E_{enbüyük}(i, j)$ oluşturulmakta ve yerel minimum noktalarının eğri aradeğerlenmesi ile alt zarf $E_{enküçük}(i, j)$ oluşturulmaktadır. Tez kapsamında geliştirilen çalışmalarda 2-B AKA için eğri aradeğerleme [57, 58]'de tavsiye edilen ince metal plaka eğrileri (thin plate spline interpolation) kullanılarak elde edilmiştir.

3-Üst zarf ve alt zarfın ortalaması hesaplanmaktadır.

$$(A_m^{(n)}(i, j) = (E_{enbüyük}(i, j) + E_{enküçük}(i, j)) / 2)$$

4-Ortalama zarf işareti, giriş işaretinden çıkarılmaktadır.

$$(S_m^{(n)}(i, j) = I_{l,m}^{(n)}(i, j) - A_m^{(n)}(i, j))$$

5- Ortalama zarf işareti sonlandırma ölçütünü sağlıyor mu diye test edilmektedir. İKF için sonlandırma ölçütü, ortalama işaret sıfıra yaklaştığı zaman elde edilmektedir ve bu ölçüt (3.2) ile ifade edilmektedir.

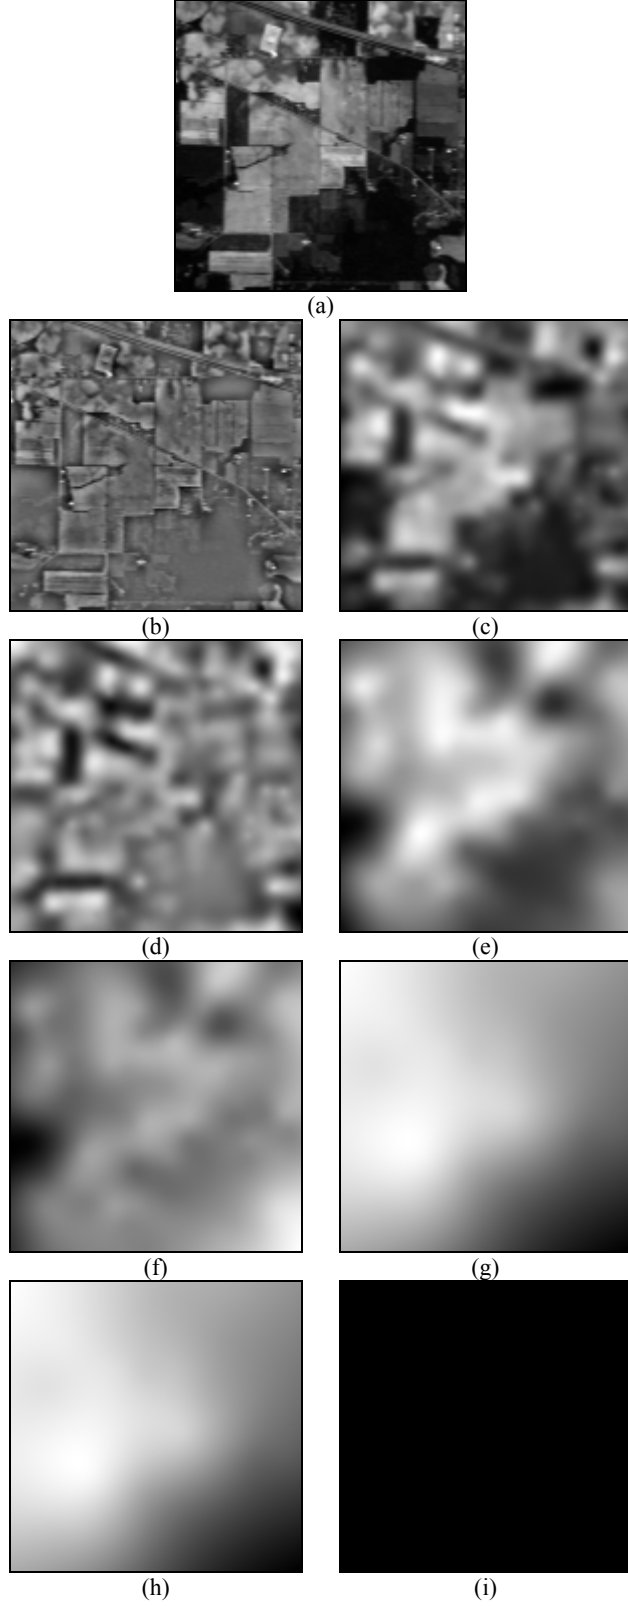
$$\frac{\sum_{i=1}^P \sum_{j=1}^R |A_m^{(n)}(i, j)|}{P \times R} < \tau \quad (3.2)$$

Burada P ve R $A_m^{(n)}(i, j)$ işaretinin piksel boyutlarıdır ve τ eşik değeridir. Sonlandırma ölçütü, söz konusu İKF'nin sinyal özelliklerini sağladığını garanti etmektedir. Sonlandırma için uygun ölçüt $n = N$ özyinelemede elde edildiğinde, İKF, $\dot{I}KF_{l,m}(i, j) = S_m^{(N)}(i, j)$ olarak tanımlanmaktadır. Sonlandırma ölçütü sağlanmadığında ise, bir sonraki özyineleme $I_{l,m}^{(n+1)}(i, j) = S_m^{(n)}(i, j)$ ile başlamaktadır ve 1. aşamadan itibaren işlemler tekrarlanmaktadır.

6- İKF bulunduktan sonra, kalan işaret giriş işareti ile İKF işaretinin farkından elde edilmektedir ($R_m(i, j) = I_{l,m}^{(n)}(i, j) - \dot{I}KF_{l,m}(i, j)$). AKA, kalan işaretin ideal olarak uç nokta içermemesi durumunda sonlandırılmaktadır. Kalan işaretin uç nokta içermesi durumunda ise bir sonraki İKF, giriş işareti $I_{l,m+1}^{(1)}(i, j) = R_m(i, j)$ olarak alınarak 1. aşamadan itibaren işlemler tekrarlanmaktadır. Orijinal işaret İKF'lerin ve en son elde edilen artık işaretin toplamı ile ifade edilmektedir ve denklem (3.3) ile gösterilmektedir.

$$B_l(i, j) = \sum_{m=1}^M \dot{I}KF_{l,m}(i, j) + R_M(i, j) \quad (3.3)$$

Şekil 3.2'de Indian Pine hiperspektral görüntüsünün örnek bir hiperspektral bandına 2-B AKA uygulanması sonucu elde edilen İKF'ler ve artık işaretleri gösterilmektedir. $\dot{I}KF_{l,1}$ en yüksek frekans bileşenlerini içermektedir ve her bir İKF farklı uzamsal konumlarda olmak üzere alçak frekans ve yüksek frekans bileşenlerini içermektedir. $\dot{I}KF_{l,1}$ yüksek geçiren süzgeç kullanılarak süzgeçlenmiş işareti ve diğer İKF'ler ise bant geçiren süzgeç ile süzgeçlenmiş işarete karşılık gelmektedir [57, 58].



Şekil 3.2: Indian Pine verisinde 28. bandın 2-B AKA dönüşümü sonuçları (a) orijinal bant, (b)1. İKF, (c) 1. kalan, (d) 2. İKF, (e) 2. kalan, (f) 3. İKF, (g) 3. kalan, (h) 4. İKF, (i) 4. kalan.

3.3. Hızlı 2-B Ampirik Kip Ayrışımı

Hızlı 2-B AKA algoritması aşağıda detaylı olarak açıklanmaktadır. Kullanılan gösterimlerde, $B_l(i, j)$, l . ($l=1,2,\dots,d$, d toplam bant sayısını göstermektedir) orijinal hiperspektral bantı ve (i, j) uzamsal konumu göstermektedir. $IKF_{l,m}$ l . hiperspektral bandın m . ($m=1,2,\dots,M$) İKF değerlerini göstermektedir ve $I_{l,m}(i, j)$, l . bandın m . İKF değerlerini bulmak için kullanılan giriş değerleridir. Hızlı 2-B AKA algoritması başlangıç olarak orijinal bant değerlerinden başlamaktadır.

$$I_{l,1}(i, j) = B_l(i, j) \quad (3.4)$$

$1-I_{l,m}(i, j)$ işaretinin bütün 2-B yerel maksimum ve yerel minimum noktalarının genlik ve pozisyonları elde edilmektedir.

2-Üst zarf ($E_{enbüyük}(i, j)$) işaretini elde edebilmek amacı ile en büyükleme süzgeci, alt zarf ($E_{enküçük}(i, j)$) işaretini elde edebilmek amacı ile en küçükleme süzgeci $I_{l,m}(i, j)$ 'ye uygulanmaktadır. Üst zarf ve alt zarf (3.5) ile elde edilmektedir.

$$\begin{aligned} E_{enbüyük}(i, j) &= \text{enbüyük}_{(q,p) \in Z_{ij}} \{I_{l,m}(q, p)\} \\ E_{enküçük}(i, j) &= \text{enküçük}_{(q,p) \in Z_{ij}} \{I_{l,m}(q, p)\} \end{aligned} \quad (3.5)$$

Burada Z_{ij} , (i, j) uzamsal pozisyonu etrafında yer alan en büyükleme süzgeci için, $s_{enbüyük} \times s_{enbüyük}$ boyutlarında kare şeklinde uzamsal pencereyi, en küçükleme süzgeci için ise $s_{enküçük} \times s_{enküçük}$ boyutlarında kare şeklinde uzamsal pencereyi göstermektedir. $s_{enbüyük}$ ve $s_{enküçük}$ değerleri, $I_{l,m}(i, j)$ 'nin yerel maksimum ve yerel minimum noktalarının konumlarına göre aşamalı olarak bulunmaktadır [59, 60]. Her bir yerel maksimum noktasının, en yakın yerel maksimum noktasına olan Öklid uzaklığı hesaplanmaktadır ve bir dizilimde saklanmaktadır ($dizilim_{enbüyük}$). Aynı işlemler her bir yerel minimum noktası içinde gerçekleştirilmektedir ve her bir yerel minimum noktasının en yakın yerel minimum noktasına olan Öklid uzaklığı bir dizilimde

saklanmaktadır ($dizilim_{enküçük}$). Sonrasında $s_{enbüyük}$ ve $s_{enküçük}$ (3.6)'daki yaklaşımlardan biri seçilerek belirlenmektedir. Bu durumda $s_{enbüyük}$ ve $s_{enküçük}$ aynı değerler almaktadır.

$$\begin{aligned}
s_{enbüyük} &= s_{enküçük} = enküçük \left\{ enküçük \left\{ dizilim_{enbüyük} \right\}, enküçük \left\{ dizilim_{enküçük} \right\} \right\} \\
s_{enbüyük} &= s_{enküçük} = enbüyük \left\{ enbüyük \left\{ dizilim_{enbüyük} \right\}, enbüyük \left\{ dizilim_{enküçük} \right\} \right\} \\
s_{enbüyük} &= s_{enküçük} = enbüyük \left\{ enküçük \left\{ dizilim_{enbüyük} \right\}, enküçük \left\{ dizilim_{enküçük} \right\} \right\} \\
s_{enbüyük} &= s_{enküçük} = enküçük \left\{ enbüyük \left\{ dizilim_{enbüyük} \right\}, enbüyük \left\{ dizilim_{enküçük} \right\} \right\}
\end{aligned} \tag{3.6}$$

Burada enbüyük, dizilimdeki en büyük değeri, enküçük ise dizilimdeki en küçük değeri göstermektedir. Ayrıca $s_{enbüyük}$ ve $s_{enküçük}$ (3.7)'deki seçeneklerden birisi seçilerek de elde edilebilmektedir. Bu durumda $s_{enbüyük}$ ve $s_{enküçük}$ farklı değerler almaktadır.

$$\begin{aligned}
s_{enküçük} &= enküçük \left\{ dizilim_{enbüyük} \right\} \\
s_{enküçük} &= enbüyük \left\{ dizilim_{enküçük} \right\} \\
s_{enbüyük} &= enküçük \left\{ dizilim_{enbüyük} \right\} \\
s_{enbüyük} &= enbüyük \left\{ dizilim_{enbüyük} \right\}
\end{aligned} \tag{3.7}$$

Sonrasında $s_{enbüyük}$ ve $s_{enküçük}$ en yakın tek tam sayıya yuvarlanmakta ve en büyükleme ve en küçükleme süzgeçlerinin boyutları sırasıyla $s_{enbüyük} \times s_{enbüyük}$ ve $s_{enküçük} \times s_{enküçük}$ olarak belirlemektedir.

4- $E_{enbüyük}(i, j)$ ve $E_{enküçük}(i, j)$ işaretlerine alçak geçiren süzgeçler uygulanarak düzgün (smooth) zarflar elde edilmektedir. Bu amaçla $s_{enbüyük} \times s_{enbüyük}$ ve $s_{enküçük} \times s_{enküçük}$ boyutlarında standart süzgeç çekirdekleri kullanılarak düzgün üst zarf $E'_{enbüyük}(i, j)$ ve düzgün alt zarf $E'_{enküçük}(i, j)$ elde edilmektedir. Bu işlemler (3.8) ile formüle edilmiştir.

$$E'_{enbüyük}(i, j) = \frac{1}{S_{enbüyük} \times S_{enbüyük}} \sum_{(q,p) \in Z_{ij}} E_{enbüyük}(q, p) \quad (3.8)$$

$$E'_{enküçük}(i, j) = \frac{1}{S_{enküçük} \times S_{enküçük}} \sum_{(q,p) \in Z_{ij}} E_{enküçük}(q, p)$$

5-Sonrasında, 4. aşamada elde edilen üst zarf ve alt zarfın ortalaması hesaplanmaktadır ($A_m(i, j) = (E'_{enbüyük}(i, j) + E'_{enküçük}(i, j)) / 2$).

6-Ortalama zarf işareti, giriş işaretinden çıkarılmaktadır. ($S_m(i, j) = I_{l,m}(i, j) - A_m(i, j)$).

7- m. İKF $\hat{IKF}_{l,m}(i, j) = S_m(i, j)$ olarak elde edilmektedir.


8- Kalan işaret $R_m(i, j) = I_{l,m}(i, j) - \hat{IKF}_{l,m}(i, j)$ olarak elde edilmektedir ve işlemler, kalan işaretin birden fazla uç nokta içermemesi durumunda sonlanmaktadır. Eğer kalan işaret birden fazla uç nokta içeriyor ise bir sonraki İKF, 1. aşamadan başlanarak bulunmaktadır ve 1. aşama için giriş işareti bir önceki İKF'den elde edilen kalan işarettir ($I_{l,m+1}(i, j) = R_m(i, j)$).

Hızlı 2-B AKA algoritmasında 2-B eğri aradeğerlemesi yerine istatistiksel süzgeçler kullanılması nedeniyle hesapsal yükü 2-B AKA'ya göre oldukça düşüktür. Orijinal işaret İKF'lerin ve en son elde edilen kalan işaretin toplamı ile ifade edilmektedir ve (3.9) ile gösterilmektedir.

$$B_l(i, j) = \sum_{m=1}^M IMF_{l,m}(i, j) + R_M(i, j) \quad (3.9)$$

Şekil 4.3'de Indian Pine hiperspektral görüntüsünün örnek bir hiperspektral bandına hızlı 2-B AKA uygulanması sonucu elde edilen İKF'ler gösterilmektedir. Aynı bant için 2-B AKA ile dört İKF elde edilmesine rağmen, hızlı 2-B AKA ile iki İKF elde edilmektedir. $\hat{IKF}_{l,1}$ en yüksek frekans bileşenlerini içermektedir ve her bir İKF farklı uzamsal konumlarda olmak üzere alçak frekans ve yüksek frekans bileşenlerini

içermektedir. $\dot{I}KF_{l,1}$ yüksek geçiren süzgeç kullanılarak süzgeçlenmiş işarete ve diğer İKF'ler ise bant geçiren süzgeç ile süzgeçlenmiş işarete karşılık gelmektedir [57, 58].



Şekil 3.3: Indian Pine verisinde 28. bandın hızlı 2-B AKA dönüşümü sonuçları (a) orijinal bant, (b)1. İKF, (c) 1. kalan, (d) 2. İKF, (e) 2. kalan.

3.4. Düşük Dereceli İKF'lerin Toplanması Temelli Hiperspektral Görüntü Sınıflandırması

3.4.1. Güdülenme ve önerilen yöntem

Hiperspektral görüntülerin uydudan ya da uçaktan alınması sırasında yeryüzü arazisi satır satır taranarak sayısal veriye dönüştürülmektedir. Her bir satırın taranması sırasında, yeryüzü arazisinin eğimi ve/veya hava şartlarından kaynaklı etkiler (örneğin rüzgar) veriyi etkilemektedir. Bu nedenle oluşan hiperspektral bantta her bir

satırdaki tarama esnasındaki fiziksel etkilerden kaynaklanan yerel alçak frekans bileşenleri oluşmaktadır ve bu nedenle sınıflandırma başarımı olumsuz yönde etkilenebilir. Hiperspektral bantlara 2-B AKA uygulanması sonucu oluşan düşük dereceli İKF'ler hızlı uzamsal salınım kiplerini içermekte, yüksek dereceli İKF'ler ise yavaş uzamsal salınım kiplerini içermektedir [64]. Şekil 3.2 ve Şekil 3.3'de düşük dereceli İKF'ler de yerel uzamsal bilgilerin belirgin olduğu ve yüksek dereceli İKF'ler de ise yerel uzamsal bilgilerin neredeyse kaybolduğu görülmektedir. Bu bölümde önerilen çalışma ile hiperspektral görüntülerin satır satır taraması aşamasında meydana gelen alçak frekans bileşenlerinin (yani yavaş uzamsal salınım kiplerinin) veriden arındırılması amacıyla yüksek dereceli İKF'lerin atılması önerilmektedir. Bu amaçla her bant için AKA uygulandıktan sonra elde edilen düşük dereceli belirli sayıda İKF toplanarak her hiperspektral bant sınırlı sayıdaki İKF'den geri çatılmaktadır ($\dot{IKF}_{l,m}(i,j)$ m . derece İKF'yi göstermektedir). Daha sonra bu geri çatılan bantlar üzerinden DVM sınıflandırma gerçekleştirilmektedir. Yüksek dereceli İKF'ler doğrudan atılarak ihmal edilmektedir. Bu sayede yerel alçak frekans bileşenler elenmektedir ve bu nedenle hiperspektral veriden satır satır taramanın neden olduğu yerel alçak frekans bileşenleri (yavaş uzamsal salınım kipleri) arındırılmaktadır. Önerilen çalışmada, her bir hiperspektral bandın yeni tanımlaması $B'_l(i,j)$ denklem (3.10) ile elde edilmektedir.


$$B'_l(i,j) = \sum_{m=1}^L \dot{IKF}_{l,m}(i,j) \quad (3.10)$$

Burada L toplama işlemine dahil edilecek toplam İKF sayısını göstermektedir. Önerilen yöntemde yeni oluşan hiperspektral verinin sınıflandırmada kullanılacak her bir pikseli denklem (3.11) ile gösterilmektedir.

$$\mathbf{x}_u = B'_l(ui,uj) , \quad l=1,2,\dots,d \quad (3.11)$$

Burada (ui,uj) \mathbf{x}_u pikselinin uzamsal konumunu göstermektedir. Şekil 3.4'de Indian Pine görüntüsü için düşük dereceli İKF'lerin toplanması sonuçları gösterilmektedir. Şekilde örnek bir orijinal bant için birinci İKF ($L=1$), ilk iki İKF'nin toplanması ($L=2$), ilk üç İKF'nin toplanması ($L=3$) ve ilk dört İKF'nin toplanması ($L=4$)

sonucu oluşan yeni bant tanımlamaları gösterilmektedir. Bu veriler 2-B AKA kullanılarak elde edilmiştir. Şekilden görüldüğü gibi birinci İKF ile ince uzamsal detaylar (fine spatial details) ve ilk iki İKF'nin toplamı ile ise bütün detaylar oldukça başarılı bir şekilde temsil edilmektedir. İlk üç ve ilk dört İKF'nin toplamı ile oluşan veriler ise orijinal veriye benzemektedir.



Şekil 3.4: Indian Pine verisi 28. bant (a) orijinal bant, (b) 1. İKF, (c) ilk iki İKF'nin toplanması, (d) ilk üç İKF'nin toplanması ve (e) ilk dört İKF'nin toplanması

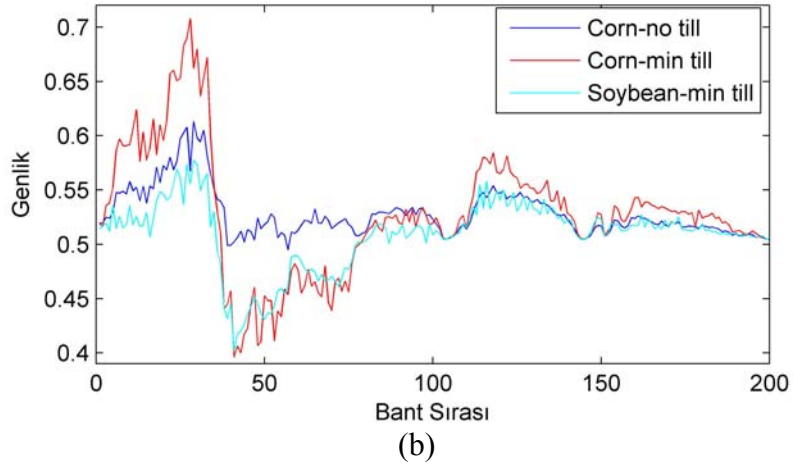

Tablo 3.1'de Indian Pine görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı [108] verilmektedir. Bhattacharyya uzaklığı denklem (3.12) ile hesaplanmaktadır.

$$b_{hk} = \frac{1}{8} (M_h - M_k)^T \left(\frac{C_h + C_k}{2} \right)^{-1} (M_h - M_k) + \frac{1}{2} \ln \left(\frac{1}{2} \frac{|C_h + C_k|}{\sqrt{|C_h| |C_k|}} \right) \quad (3.12)$$

Burada b_{hk} , h ve k sınıfları arasındaki Bhattacharyya uzaklığını, M_i i . sınıfın ortalamasını, C_i i . sınıfın $d \times d$ boyutlarında ortak değişinti (covariance) matrisini ve T devrik (transpose) işlemini göstermektedir. Sınıflar arası uzaklık hesaplanırken her bir sınıfın diğer tüm sınıflara olan uzaklığı hesaplanmıştır. Örneğin h . sınıfın diğer tüm sınıflara uzaklığı hesaplanırken diğer tüm sınıflar tek bir sınıfa aitmiş gibi düşünülmektedir. Sonuçlar orijinal veri için ve düşük dereceli İKF'lerin toplamı sonucu oluşan veriler için, farklı L değerlerinde, verilmektedir. Bu sonuçlar 2-B AKA'da sonlandırma eşik eđeri $\tau=0.006$ kullanılarak elde edilmiştir. Sonuçlar sınıflar arası uzaklığın $L=2$ iken en uzak olduğunu göstermektedir. Ayrıca birbirinden ayrılması en zor 3 sınıfın orijinal piksel değerleri kullanılarak elde edilen her bir sınıfın ortalama spektral imzaları ve bu sınıfların birinci İKF ile ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları Şekil 3.5'de gösterilmektedir. Şekillerden görüldüğü üzere orijinal spektral imzaları birbirine çok benzer olan bu üç sınıfın ayrımsallığı (yani spektral imzalar arası farklılık) düşük dereceli İKF'lerin toplamı sonucu artmıştır.

Tablo 3.1: Indian Pine görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı

	Orijinal veri	Düşük dereceli İKF'lerin toplamı sonucu oluşan veri			
		$L=1$	$L=2$	$L=3$	$L=4$
1	7.45	20.23	28.66	18.32	15.95
2	10.05	26.01	38.24	25.31	22.75
3	18.42	32.40	49.23	33.61	30.28
4	14.28	26.50	42.19	31.12	28.18
5	29.83	34.05	79.23	61.24	56.62
6	8.90	23.12	33.98	21.53	18.61
7	5.59	18.60	29.71	17.46	14.96
8	13.40	31.09	46.26	32.47	28.56
9	16.09	23.29	46.04	39.13	34.96



Şekil 3.5: Indian Pine verisinde ayrılması zor üç sınıfın (a) orijinal piksel değerleri kullanılarak elde edilen ortalama spektral imzaları ve (b) bu sınıfların birinci İKF ile ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları

3.4.2. Deneysel sonuçlar

Önerilen yaklaşımın sınıflandırma başarımını göstermek amacı ile DVM sınıflandırma algoritması, RTF çekirdeği ile kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma kullanılmıştır. Deneysel sonuçlar Indian Pine, DC Mall ve Salinas hiperspektral görüntüleri kullanılarak elde edilmiştir. Sınıflandırma başarımları yüzde olarak genel başarımlar (overall accuracy) ve kappa katsayısı (k) [65] verilerek gösterilmektedir. Eğer $k = 1$ ise %100 sınıflandırma başarımı elde edilmiştir. Bu

nedenle k değerinin 1'e yakın olması iyi bir sınıflandırma başarımı elde edildiğini göstermektedir. Farklı yöntemlerin sınıflandırma başarımları arasındaki farkın istatistiksel önemi McNemar testi [66] kullanılarak ölçülmüştür. McNemar testinde 0.05 başarımlar seviyesi için, $|Z| > 1.96$ ise sınıflandırma sonuçları arasındaki fark istatistiksel olarak önemlidir [66]. Eğer Z 'nin işareti pozitif ise birinci sınıflandırıcı ikinci sınıflandırıcıya göre istatistiksel olarak başarılıdır. Eğer Z 'nin işareti negatif ise ikinci sınıflandırıcı birinci sınıflandırıcıya göre istatistiksel olarak başarılıdır. Bu çalışmada ikinci sınıflandırıcı doğrudan DVM ve birinci sınıflandırıcı ise karşılaştırılacak olan sınıflandırma yöntemleri olarak belirlenmiştir.

Deneysel sonuçlarda 2-B AKA ile DVM sınıflandırma 2B-AKA-DVM, hızlı 2-B AKA ile DVM sınıflandırma ise H-2B-AKA-DVM olarak gösterilmiştir. Sonuçlarda 2-B AKA ve hızlı 2-B AKA sonucu her bant için elde edilen İKF'ler kullanılarak bantların geri çatılması yapılırken, sadece ilk İKF'nin kullanılması (1 İKF), ilk iki İKF'nin toplamının kullanılması (2 İKF), ve benzer şekilde ilk üç İKF'nin toplamının kullanılması (3 İKF) ve ilk dört İKF'nin toplamının kullanılması (4 İKF) durumlarında elde edilen sınıflandırma başarımları gösterilmektedir. 2-B AKA'da aradegerleme işlemleri [57, 58]'de tavsiye edilen ince metal plaka eğrileri kullanılarak elde edilmiştir. Hızlı 2-B AKA'da kullanılan $s_{enbüyük}$ ve $s_{enküçük}$ değerlerinin belirlenmesi için (3.6) ve (3.7)'deki tüm durumlar denenmiştir ve iki veri kümesi için de (3.7)'de belirtilen 'enbüyük' ölçütünün $s_{enbüyük}$ ve $s_{enküçük}$ değerlerini belirlemede en uygun ölçüt olduğu deneysel olarak belirlenmiştir.

Deneysel sonuçlar hiperspektral görüntünün her bir bandına dalgacık uzayında gürültü giderimi [67] uygulandıktan sonra DVM ile sınıflandırılması sonuçları (D-DVM), alçak geçiren süzgeç (AGS) ile süzgeçlendikten sonra DVM ile sınıflandırılması sonuçları (AGS-DVM) ve keskinleştirici süzgeç (KS) ile süzgeçlendikten sonra DVM ile sınıflandırılması sonuçları (KS-DVM) ile karşılaştırılmıştır. Dalgacık uzayında gürültü giderimi yöntemi için [67]'de önerildiği üzere sekiz sönen moment (vanishing moment) ile Symmlets dalgacıkları kullanılmış, bütün bantlar için dört yeniden oluşturma seviyesi kullanılarak karesel pencere boyu 7×7 olarak alınmıştır. AGS ile süzgeçleme için ise 5×5 boyutlarında ortalama alan

çekirdek kullanılmıştır. KS ile süzgeçleme multispektral verilerdeki yüksek frekans bileşenlerini (örneğin kenar bilgisini) açığa çıkarmak amacı ile [114]'de kullanılmıştır. KS ile süzgeçlenmiş veri, orijinal verinin kendisinin, AGS ile süzgeçlenmiş değerlerinden çıkarılması ile elde edilmektedir [114]. Bu tez kapsamında ise KS ile süzgeçlenmiş hiperspektral veri, AGS ile süzgeçlenmiş verinin bir katsayı ile çarpılmasıyla elde edilen sonucun orijinal veri ile farkı alınarak elde edilmiştir. Katsayı değerleri [0.1, 1] arası değerler alacak şekilde sonuçlar elde edilmiştir ve en iyi sonucun katsayı değeri 0.1 iken elde edildiği gözlemlenmiştir. Ayrıca deneysel sonuçlar [25] ve [26]'da önerilen biçimbilimsel profiller temelli yöntemler ile de karşılaştırılmıştır. Biçimbilimsel profilleri elde etmek amacı ile başlangıç olarak hiperspektral görüntülere bant çıkarımı amacıyla spektral TBA (TBA ile ilgili detaylı bilgi Bölüm 8.3'de verilmiştir) uygulanarak temel bileşenler elde edilmektedir. Sonrasında, ilk üç temel bileşene ardı ardına dört açma-kapama işlemi uygulanarak toplamda 27 bant içeren biçimbilimsel profiller elde edilmektedir. Deneysel sonuçlar biçimbilimsel profillerin doğrudan sınıflandırmada kullanılması sonuçları (BP olarak isimlendirilmiştir), orijinal spektral verinin biçimbilimsel profiller ile doğrudan birleştirilmesi [26] (yani orijinal verinin ve biçimbilimsel profillerin ardı ardına eklenmesi) sonuçları (Spek-BP olarak isimlendirilmiştir) ve orijinal spektral verinin biçimbilimsel profiller ile öznelik çıkarımı yöntemleri vasıtasıyla birleştirilmesi (öznelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere ayrı ayrı uygulanmakta ve elde edilen spektral veriler ardı ardına eklenmektedir) sonuçları (ÖÇ-Spek-BP olarak isimlendirilmiştir) ile karşılaştırılmıştır. Spek-BP ve ÖÇ-Spek-BP sonuçları sadece Indian Pine görüntüsü için elde edilmiştir. ÖÇ-Spek-BP yönteminde öznelik çıkarımı orijinal veriye ve biçimbilimsel profillere ayrı ayrı uygulanmaktadır. Burada, öznelik çıkarımı yöntemi olarak parametrik olmayan ağırlıklandırılmış öznelik çıkarımı yöntemi %98 değişinti (variance) ölçütü esas alınarak kullanılmıştır [26]. Bu yöntem sonucunda orijinal Indian Pine verisinden 10 bant, biçimbilimsel profillerden ise 5 bant çıkarılmıştır. Önerilen yöntem ve önerilen yöntemin başarımını karşılaştırmada kullanılan yöntemlerin kısa isimleri ve her bir yöntemin açıklaması kullanıcı girişli parametreleriyle birlikte Tablo 3.2'de özetlenmektedir.

Tablo 3.2: Önerilen yöntem ve önerilen yöntemin başarımını karşılaştırmada kullanılan yöntemlerin kısa isimleri, her bir yöntemin açıklaması ve kullanıcı girişli parametreleri

Yöntemlerin Kısa İsimleri	Yöntemlerin Açıklamaları	Kullanıcı Girişli Parametreleri
2B-AKA-DVM	2-B AKA ile elde edilen düşük dereceli İKF'lerin toplamını DVM ile sınıflandırma	τ, P
H-2B-AKA-DVM	Hızlı 2-B AKA ile elde edilen düşük dereceli İKF'lerin toplamını DVM ile sınıflandırma	P
D-DVM	Dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma	P
KS-DVM	Keskinleştirici süzgeç sonrası DVM ile sınıflandırma	P
AGS-DVM	Alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma	P
BP	Biçimbilimsel profilleri DVM ile sınıflandırma	Biçimbilimsel açma-kapama sayısı
Spek-BP	Orijinal verinin ve biçimbilimsel profillerin ardı ardına eklenerek DVM ile sınıflandırılması	Biçimbilimsel açma-kapama sayısı
ÖÇ-Spek-BP	Öznetelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere uygulandıktan sonra elde edilen spektral verilerin ardı ardına eklenerek DVM ile sınıflandırılması	Biçimbilimsel açma-kapama sayısı

Indian Pine görüntüsünde 2-B AKA sonlandırma eşik değeri τ için [0.004-0.01] arasında değerler için sonuçlar elde edilmiştir. Bu durumda pencere boyutu $P=3 \times 3$ olarak sabitlenmiştir. Ayrıca 3×3 , 5×5 ve 7×7 pencere boyutları içinde 2-B AKA (bu durumda $\tau=0.006$ olarak sabitlenmiştir) ve hızlı 2-B AKA sonuçları elde edilmiştir. Toplam İKF sayıları her bant için farklı olmaktadır. Farklı P ve τ değerleri için elde edilen İKF sayıları ve hesaplama süreleri Tablo 3.3'de

gösterilmektedir. Hesaplanma süreleri saniye cinsinden işlemcinin piksel başına harcacağı süre olarak verilmiştir. Özellikle düşük P değerleri seçilmesi durumunda Hızlı 2-B AKA, 2-B AKA'dan daha hızlı çalışmaktadır. Büyük P değerlerin seçilmesi durumunda ise yerel maksimum ve minimum noktalarının sayısının az olması nedeni ile 2-B AKA hesapsal karmaşıklığı azalmaktadır ve bu nedenle Hızlı 2-B AKA ve 2-B AKA işlem süreleri benzerdir. Tablolarda gösterilen İKF sayıları şu şekilde yorumlanmalıdır: $P = 3 \times 3$ ve $\tau = 0.01$ iken 8 tane bandın 1 İKF'si, 147 tane bandın 3 İKF'si, 45 tane bandın 4 İKF'si bulunmaktadır ve sadece 2 İKF'ye ve 5 İKF'ye sahip hiç bir bant bulunmamaktadır. Her bir bandın İKF sayıları 2-B AKA algoritması için z ve P değerlerine, hızlı 2-B algoritması için ise P , $s_{enbüyük}$ ve $s_{enküçük}$ değerlerine bağlıdır. z ve P kullanıcı girişi parametrelerdir fakat $s_{enbüyük}$ ve $s_{enküçük}$ otomatik olarak hesaplanmaktadır. P değerinin artırılması veya P değerinin sabitlenerek z değerinin azaltılması sonucu daha çok sayıda yüksek dereceli İKF elde edilmektedir.

Tablo 3.3: Farklı τ ve P değerleri için 2-B AKA ve hızlı 2-B AKA yöntemlerinin hesapsal süreleri ve toplam İKF sayıları

Yöntem	τ	P	AKA Süresi	1 İKF sayısı	2 İKF sayısı	3 İKF sayısı	4 İKF sayısı	5 İKF sayısı
2-B AKA	0.01	3x3	0.033	8	0	147	45	-
	0.008	3x3	0.036	3	-	142	55	-
	0.006	3x3	0.039	-	-	143	58	-
	0.004	3x3	0.043	-	-	122	78	-
	0.006	5x5	0.003	-	-	1	187	12
	0.006	7x7	0.002	-	-	43	157	-
Hızlı 2-B AKA	-	3x3	0.002	-	177	23	-	-
	-	5x5	0.002	-	-	156	42	2
	-	7x7	0.001	-	-	185	15	-


Tablo 3.4 ve Tablo 3.5 DVM, D-DVM, AGS-DVM, BP, Spek-BP, ÖÇ-Spek-BP, 2B-AKA-DVM ve H-2B-AKA-DVM sonucu elde edilen yüzde sınıflandırma başarımlarını, kappa katsayılarını (k) ve Z değerlerini göstermektedir. Deneysel sonuçlar, her bir sınıf için toplam verinin %10, %35 ve %65'i eğitim verisi alınarak elde edilmiştir. Deneysel sonuçlar önerilen 2B-AKA-DVM yönteminde en iyi sonucun 2 İKF durumunda elde edildiğini ve 2B-AKA-DVM'nin en iyi sonucunun

H-2B-AKA-DVM'dan daha etkili olduğunu göstermektedir. Bunun nedeni Hızlı 2-B AKA'da 2-B eğri aradeğerlemesi yerine istatistiksel süzgeçlerin kullanılması ve bu yaklaşımın 2-B eğri aradeğerlemeye göre başarısız olmasıdır. Z test sonuçlarına göre önerilen 2B-AKA-DVM ve H-2B-AKA-DVM her zaman doğrudan DVM'e göre istatistiksel olarak başarılıdır. Önerilen yöntemlerin en iyi sonuçları doğrudan DVM'e göre en az %6, en çok %13 artmıştır. 2-B AKA kullanılması durumunda P değerinin sabitlenerek z değerinin değiştirilmesi sonucu elde edilen sınıflandırma başarımları birbirinden istatistiksel olarak farklı değildir ve farklı P değerleri için sınıflandırma başarımları özellikle düşük eğitim verisi kullanılması durumunda birbirinden istatistiksel olarak farklıdır. Hızlı 2-B AKA kullanılması durumunda ise farklı P değerleri için elde edilen sınıflandırma başarımları birbirinden istatistiksel olarak farklı değildir. Bu nedenle P değerinin seçilmesi sadece 2-B AKA durumunda ve eğer eğitim verisi sayısı az ise önemlidir ve bu durumda farklı P değerlerinde sonuçların elde edilerek başarımların değerlendirilmesi yapılması gerekmektedir. Diğer yöntemler ile karşılaştırmalar önerilen yöntemin en iyi başarımları esas alınarak yapılacaktır. Buna göre 2B-AKA-DVM ve H-2B-AKA-DVM, D-DVM, KS-DVM ve AGS-DVM'e göre yüksek sınıflandırma başarımları sağlamaktadır. Şekil 3.6 örnek bir hiperspektral bant için ilk iki İKF'nin toplamı sonucu oluşan veri ile birlikte dalgalık uzayında gürültü giderimi, AGS ve KS uygulanmış bantı göstermektedir. BP sınıflandırma yöntemi Spek-BP ve ÖÇ-Spek-BP yöntemlerine göre daha yüksek sınıflandırma başarımları vermektedir. BP yöntemi 2B-AKA-DVM ve H-2B-AKA-DVM karşılaştırıldığında, BP ile elde edilen sınıflandırma başarımlarının 2B-AKA-DVM ile elde edilen sınıflandırma başarımlarından düşük, H-2B-AKA-DVM'den ise yüksek olduğu görülmektedir. Tablo 3.6'da önerilen yöntem, BP ve doğrudan DVM ile elde edilen ortalama sınıf başarımları verilmektedir. Sonuçlar birçok sınıf için önerilen yöntemin başarımlarının BP'den daha iyi olduğunu göstermektedir.

DC Mall verisinin yüksek piksel boyutundan dolayı bu veri kümesi için deneysel sonuçlar 2B-AKA-DVM kullanılarak elde edilememiştir, bu nedenle sadece H-2B-AKA-DVM kullanılmıştır. Bu durumda 182 bant üç İKF, 9 bant ise dört İKF içermektedir. P pencere boyutu 3×3 olarak sabitlenmiştir. Tablo 3.7 DVM, D-DVM, AGS-DVM, BP ve H-2B-AKA-DVM sonucu elde edilen yüzde sınıflandırma başarımlarını, kapa katsayılarını (k) ve Z değerlerini göstermektedir. Deneysel

sonular, her bir sınıf iin toplam verinin %5, %10 ve %35'i eēitim verisi alınarak elde edilmiřtir. Deneysel sonular nerilen H-2B-AKA-DVM ynteminde en iyi sonucun 2 İKF durumunda elde edildiēini gstermektedir ve elde edilen sınıflandırma sonuları doērudan DVM'e gre istatikselsel olarak bařarılıdır. Diēer yntemler ile karřılařtırmalar nerilen yntemin en iyi bařarımı esas alınarak yapılmaktadır; i) H-2B-AKA-DVM, D-DVM, KS-DVM ve AGS-DVM'e gre yksek sınıflandırma bařarımı saēlamaktadır, ii) BP ve H-2B-AKA-DVM yntemleri benzer sonular vermektedir.

Tablo 3.8'de Salinas verisi iin elde edilen DVM, D-DVM, AGS-DVM, BP ve 2B-AKA-DVM sonuları gsterilmektedir. Deneysel sonular, her bir sınıf iin toplam verinin %10 ve %50'si eēitim verisi alınarak elde edilmiřtir. Deneysel sonular nerilen 2B-AKA-DVM ynteminde en iyi sonucun 2 İKF durumunda elde edildiēini gstermektedir ve elde edilen sınıflandırma sonuları doērudan DVM'e gre istatikselsel olarak bařarılıdır. Diēer yntemler ile karřılařtırmalar nerilen yntemin en iyi bařarımı esas alınarak yapılmaktadır; i) 2B-AKA-DVM, D-DVM, KS-DVM ve AGS-DVM'e gre yksek sınıflandırma bařarımı saēlamaktadır, ii) BP ve 2B-AKA-DVM yntemleri benzer sonular vermektedir.



řekil 3.6: Indian Pine verisi 28. bant (a) ilk iki İKF'nin toplamı, (b) dalgacık uzayında grlt giderimi sonucu, (c) alak geiren szge (AGS) sonucu ve (d) keskinleřtirici szge (KS) sonucu

Tablo 3.4: Indian Pine verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (AGS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), orijinal verinin ve biçimbilimsel profillerin ardı ardına eklenerek DVM ile sınıflandırılması (Spek-BP), öznelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere uygulandıktan sonra elde edilen spektral verilerin ardı ardına eklenerek DVM ile sınıflandırılması (ÖÇ-Spek-BP), 2-B AKA ile DVM sınıflandırma (2B-AKA-DVM), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kapa katsayıları (k), Z değerleri

Yöntem	%10 EVO			%35 EVO			
	SB	k	Z	SB	k	Z	
DVM	82.24	0.70	-	91.47	0.83	-	
D-DVM	89.04	0.73	17.45	96.62	0.94	14.79	
KS-DVM	81.18	0.69	-4.21	90.35	0.81	-7.34	
AGS-DVM	87.47	0.72	13.68	94.38	0.89	7.92	
BP	94.56	0.73	29.13	99.27	0.99	21.47	
Spek-BP	92.47	0.71	24.95	98.53	0.98	19.71	
ÖÇ-Spek-BP	93.19	0.78	27.65	98.33	0.97	19.46	
2B-AKA-DVM ($\tau = 0.004$) ($P = 3 \times 3$)	1 İKF	71.59	0.53	18.40	91.31	0.87	-0.34
	2 İKF	94.31	0.72	27.90	99.30	0.97	21.35
	3 İKF	93.04	0.66	26.65	98.36	0.93	18.94
	4 İKF	89.30	0.84	16.44	94.55	0.87	7.93
2B-AKA-DVM ($\tau = 0.008$) ($P = 3 \times 3$)	1 İKF	78.86	0.59	-13.42	93.09	0.88	3.69
	2 İKF	94.16	0.72	27.92	99.27	0.97	21.40
	3 İKF	92.66	0.66	25.92	97.55	0.93	16.93
	4 İKF	92.57	0.64	25.65	97.73	0.92	17.33
2B-AKA-DVM ($\tau = 0.006$) ($P = 3 \times 3$)	1 İKF	73.96	0.54	-14.75	92.13	0.87	1.45
	2 İKF	94.00	0.73	27.56	99.13	0.97	21.01
	3 İKF	92.56	0.64	25.79	97.59	0.94	16.98
	4 İKF	92.23	0.65	25.30	97.43	0.93	16.64
2B-AKA-DVM ($\tau = 0.006$) ($P = 5 \times 5$)	1 İKF	79.73	0.63	-4.77	95.71	0.91	10.51
	2 İKF	95.52	0.81	30.36	99.67	0.99	22.30
	3 İKF	94.43	0.70	28.93	99.11	0.97	20.95
	4 İKF	87.71	0.77	12.32	93.77	0.89	5.62
2B-AKA-DVM ($\tau = 0.006$) ($P = 7 \times 7$)	1 İKF	87.87	0.61	12.71	98.33	0.96	18.53
	2 İKF	93.14	0.67	26.41	99.40	0.98	21.87
	3 İKF	93.41	0.69	27.14	98.33	0.93	19.11
	4 İKF	90.98	0.80	21.55	95.60	0.92	11.25
H-2B-AKA-DVM ($P = 3 \times 3$)	1 İKF	81.86	0.72	-0.78	92.22	0.87	1.75
	2 İKF	91.97	0.75	23.73	97.99	0.97	18.72
	3 İKF	91.78	0.74	23.62	98.00	0.97	18.87
H-2B-AKA-DVM ($P = 5 \times 5$)	1 İKF	85.69	0.70	7.66	95.24	0.92	9.49
	2 İKF	91.59	0.72	22.76	97.57	0.96	17.64
	3 İKF	83.20	0.71	3.78	92.37	0.86	3.29
	4 İKF	81.69	0.68	-3.86	90.01	0.79	8.20
H-2B-AKA-DVM ($P = 7 \times 7$)	1 İKF	89.94	0.71	18	97.23	0.94	15.63
	2 İKF	91.29	0.75	22.35	97.24	0.95	16.72
	3 İKF	81.59	0.68	-3.89	89.91	0.79	-7.74
	4 İKF	82.24	0.69	0	91.47	0.83	0

Tablo 3.5: Indian Pine verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (AGS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), orijinal verinin ve biçimbilimsel profillerin ardı ardına ekleyerek DVM ile sınıflandırma (Spek-BP), öznitelik çıkarımı yöntemi orijinal veriye ve biçimbilimsel profillere uygulandıktan sonra elde edilen spektral verilerin ardı ardına eklenerek DVM ile sınıflandırılması (ÖÇ-Spek-BP), 2-B AKA ile DVM sınıflandırma (2B-AKA-DVM), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA-DVM) yöntemlerinin %65 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kapa katsayıları (k), Z değerleri

Yöntem		%65 EVO		
		SB	k	Z
DVM		92.80	0.86	-
D-DVM		97.52	0.95	10.43
KS-DVM		91.92	0.85	-3.83
AGS-DVM		96.02	0.93	6.68
BP		99.54	0.99	14.25
Spek-BP		99.02	0.98	13.40
ÖÇ-Spek-BP		98.30	0.97	12.16
2B-AKA-DVM ($\tau = 0.004$) ($P = 3 \times 3$)	1 İKF	94.43	0.91	2.95
	2 İKF	99.57	0.99	14.08
	3 İKF	98.85	0.98	13.15
	4 İKF	95.34	0.91	4.95
2B-AKA-DVM ($\tau = 0.008$) ($P = 3 \times 3$)	1 İKF	95.40	0.92	4.78
	2 İKF	99.47	0.99	14.04
	3 İKF	97.94	0.92	11.22
	4 İKF	97.91	0.92	11.12
2B-AKA-DVM ($\tau = 0.006$) ($P = 3 \times 3$)	1 İKF	95.01	0.92	4.06
	2 İKF	99.41	0.99	13.90
	3 İKF	97.98	0.91	11.05
	4 İKF	97.75	0.92	10.74
2B-AKA-DVM ($\tau = 0.006$) ($P = 5 \times 5$)	1 İKF	97.75	0.95	9.97
	2 İKF	99.70	0.99	14.42
	3 İKF	99.21	0.97	13.69
	4 İKF	95.24	0.92	4.66
2B-AKA-DVM ($\tau = 0.006$) ($P = 7 \times 7$)	1 İKF	99.08	0.98	13.16
	2 İKF	99.73	0.98	14.52
	3 İKF	99.12	0.97	13.78
	4 İKF	96.67	0.91	8.35
H-2B-AKA-DVM ($W = 3 \times 3$)	1 İKF	94.00	0.91	2.91
	2 İKF	98.63	0.98	12.88
	3 İKF	98.76	0.98	13.10
H-2B-AKA-DVM ($P = 5 \times 5$)	1 İKF	96.28	0.93	6.86
	2 İKF	98.11	0.97	11.91
	3 İKF	94.39	0.92	4.69
	4 İKF	92.08	0.86	-3.56
H-2B-AKA-DVM ($P = 7 \times 7$)	1 İKF	97.85	0.96	10.82
	2 İKF	98.14	0.97	11.83
	3 İKF	92.34	0.86	-1.90
	4 İKF	92.80	0.86	0

Tablo 3.6: Indian Pine verisinde bulunan her bir sınıfın ortalama sınıf başarımları

Yöntem	Sınıf Etiketleri								
	1	2	3	4	5	6	7	8	9
DVM	86.61	80.75	96.67	99.79	99.07	82.63	91.91	92.17	99.53
2B-AKA-DVM	99.26	99.64	99.69	100	99.69	99.53	99.81	99.26	100
BP	98.95	99.64	100	100	100	97.36	99.33	99.26	99.76

Tablo 3.7: DC Mall verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırılması (KS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA-DVM) yöntemlerinin %5, %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kapa katsayıları (k), Z değerleri

Method	%5 EVO			%10 EVO			%35 EVO			
	SB	k	Z	SB	k	Z	SB	k	Z	
DVM	99.17	0.96	-	99.54	0.98	-	99.66	0.98	-	
D-DVM	99.17	0.96	0	99.64	0.98	2.11	99.75	0.98	1.66	
KS-DVM	96.21	0.92	-10.92	98.17	0.92	-6.99	99.48	0.97	-1.65	
AGS-DVM	97.86	0.93	-8.98	98.74	0.93	-6.48	99.52	0.97	-1.33	
BP	99.66	0.98	4.14	100	1	5.74	100	1	4.24	
H-2B-AKA-DVM	1 İKF	95.02	0.91	-16.17	97.85	0.95	-9.12	99.66	0.99	0
	2 İKF	99.53	0.98	3.34	99.88	0.99	3.90	99.94	0.99	3.87
	3 İKF	99.48	0.98	4.24	99.74	0.99	1.94	99.91	0.99	2.71
	4 İKF	99.48	0.98	4.24	99.73	0.99	1.94	99.96	0.99	3.57

Tablo 3.8: Salinas verisi için DVM ile sınıflandırma, dalgacık uzayında gürültü giderimi sonrası DVM ile sınıflandırma (D-DVM), keskinleştirici süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırma (KS-DVM), alçak geçiren süzgeç ile süzgeçlendikten sonra DVM ile sınıflandırılması (KS-DVM), biçimbilimsel profilleri DVM ile sınıflandırma (BP), hızlı 2-B AKA ile DVM sınıflandırma (H-2B-AKA-DVM) yöntemlerinin %5, %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB), kapa katsayıları (k), Z değerleri

Method	%10 EVO			%50 EVO			
	SB	k	Z	SB	k	Z	
DVM	89.28	0.87	-	90.92	0.89	-	
D-DVM	97.35	0.95	10.22	99.12	0.98	13.29	
KS-DVM	89.18	0.87	-2.01	90.56	0.88	-3.14	
AGS-DVM	94.21	0.94	6.27	97.90	0.96	7.12	
BP	99.08	0.98	15.15	99.87	0.99	19.47	
2B-AKA-DVM	1 İKF	91.79	0.90	2.83	95.39	0.94	8.31
	2 İKF	99.85	0.98	17.08	99.97	0.99	20.13
	3 İKF	99.11	0.98	15.19	99.96	0.99	20.09
	4 İKF	99.10	0.98	15.05	99.98	0.99	20.09

3.5. İçkin Kip Fonksiyonlarına Dalgacık Uzayında Gürültü Giderimi Uygulanması

3.5.1. Güdülenme ve önerilen yöntem

Bölüm 3.4'de önerilen düşük dereceli İKF'lerin toplamı yaklaşımı ile DVM sınıflandırma başarımı önemli oranda artmıştır. Bu yöntemde toplama işlemine dahil edilen birinci İKF'ler yerel en yüksek frekans bileşenlerini içermektedir ve bu nedenle gürültülü verilerdir. Hiperspektral görüntülerde analog/sayısal dönüşüm işlemleri sırasındaki nicemleme hatalarından dolayı meydana gelen nicemleme gürültüsü (quantization noise), elektronların hareketinden dolayı meydana gelen ısı gürültü (termal noise), algılayıcıdan dolayı meydana gelen atış gürültüsü (shot noise) bulunmaktadır. Atış gürültüsü sıfır ortalamalı ve standart sapması doğrudan işarete bağlı olan Gauss gürültüsüdür. Isı gürültü, sıfır ortalamalı Gauss gürültüsüdür ve değişintisi yükselteç girişindeki direnç ve yükseltecin bant genişliği ile ilişkilidir. Nicemleme gürültüsü ise her bir nicemleme aralığı için düzgün dağılımlıdır (uniformly distributed) [1].

Bu alt bölümde ele alınan çalışmada, her bir bant için elde edilen birinci İKF'lere ($\hat{IKF}_{l,1}$, $l = 1, 2, \dots, d$) dalgacık uzayında gürültü giderimi uygulanmaktadır. Birinci İKF'lerin yerel en yüksek frekans bileşenlerini içermesi nedeniyle gürültü giderimi sadece birinci İKF'lere uygulanmaktadır. Sonrasında düşük dereceli İKF'ler toplanarak elde edilen yeni veri üzerinden DVM sınıflandırma gerçekleştirilmektedir. Yüksek dereceli İKF'ler doğrudan atılarak ihmal edilmektedir. Birinci İKF'lere gürültü giderimi uygulanması sonucu yüksek frekanslardaki gürültü giderilmekte ve düşük dereceli İKF'lerin toplamı ile ise düşük frekans bileşenleri elenmektedir. Bu nedenle bu iki yaklaşımın birleşmesi bant geçiren süzgeç özelliği göstermektedir, fakat standart bir bant geçiren süzgeç ile aynı sonuçları elde etmek mümkün değildir. Önerilen yöntemin algoritması l . hiperspektral bant için aşağıda özetlenmektedir.

1- Hiperspektral görüntünün l . bandına 2-B AKA uygulanmaktadır ve İKF'ler $\hat{IKF}_{l,m}$, $m = 1, 2, \dots, M$ elde edilmektedir.

2- Dalgacık uzayında gürültü giderimi birinci İKF'ye ($\dot{IKF}_{l,1}$) uygulanarak gürültüsü giderilmiş $\dot{IKF}_{l,1}$ ($GG - \dot{IKF}_{l,1}$) elde edilmektedir.

3- Düşük dereceli İKF'ler toplanarak yeni veri elde edilmektedir (3.13).

$$B'_l(i, j) = GG - \dot{IKF}_{l,1}(i, j) + \sum_{m=2}^L \dot{IKF}_{l,m}(i, j) \quad (3.13)$$

4- Yeni veri kümesi B'_l , $l = 1, 2, \dots, d$ DVM ile sınıflandırılmaktadır.

Birinci İKF'lerde gürültü giderimi işlemi her bant diğer bantlardan bağımsız olarak dalgacık uzayında uzamsal uyarlanabilir Bayes küçültme yöntemi [67] kullanılarak uygulanmaktadır. Bu yöntem Bölüm 3.5.2'de detaylı olarak anlatılmaktadır.

3.5.2. Dalgacık uzayında gürültü giderimi

Bu bölümde dalgacık uzayında gürültü giderimi yöntemi olarak [67]'de önerilen uzamsal uyarlanabilir gürültü azaltımı yöntemi kullanılmıştır. Uzamsal uyarlanabilir gürültü azaltım yöntemi dalgacık katsayılarının gürültüsüz bileşenlerinin olasılığını hesaplamaktadır [67]. Bu yöntemde aynı alt banttaki iki gürültü katsayısı aynı genlik değerine sahip olsa da küçültme işlemi uzamsal konuma ve yerel çevreye göre yapılmaktadır. Uzamsal uyarlanabilir gürültü azaltımı yönteminin avantajları kenar algılamaya bağlı olmaması, gerçekleştirilmesinin basit olması ve iyi sonuçlar veren diğer yöntemlere göre hızlı gerçekleştirilebilmesidir.

Her bir dalgacık alt bandındaki gürültüsüz dalgacık katsayısı β 'nin olasılık yoğunluk fonksiyonu olarak genelleştirilmiş Laplacian önsel dağılımı kullanılmaktadır [67]. Genelleştirilmiş Laplacian önsel dağılımının olasılık yoğunluk fonksiyonu denklem (3.14) ile gösterilmiştir.

$$f(\beta) = \frac{\lambda v}{2\Gamma\left(\frac{1}{v}\right)} \exp(-\lambda\beta^v) \quad (3.14)$$

Burada $\Gamma\left(\frac{1}{v}\right) = \int_0^\infty t^{\frac{1}{v}-1} e^{-t} dt$ gamma fonksiyonu, λ ölçekleme parametresi ve v biçimlendirme parametresidir [67]. Eşik değerinden büyük katsayı bileşenlerinin gürültü içermediği kabul edilmektedir. Bu durumda iki varsayım yapılmaktadır. Bunlar ; H_0 : gürültülü bileşen var ($H_0: |\beta| \leq \text{eşik}$) ve H_1 : gürültü içermeyen bileşen var ($H_1: |\beta| > \text{eşik}$) varsayımlarıdır. β 'nin kestirim denklemi (3.15) ile verilmektedir [67].

$$\hat{\beta} = P(H_1|y, z)y = \frac{\eta\varepsilon\mu}{1 + \eta\varepsilon\mu} y \quad (3.15)$$

Burada z yerel uzamsal etkinlik göstergesini ve $\eta\varepsilon\mu$ genelleştirilmiş olabilirlik oranını (generalized likelihood ratio) göstermektedir. Her dalgacık katsayısı β , η değerine, yerel çevreden elde edilen ölçümlere (ε) ve verilen alt-banttaki katsayıların istatistiksel özelliklerine (μ) göre küçültülmektedir [67].

$$\eta = \frac{f(y|H_1)}{f(y|H_0)}, \quad \varepsilon = \frac{f(z|H_1)}{f(z|H_0)} \quad \text{ve} \quad \mu = \frac{P(H_1)}{P(H_0)} \quad (3.16)$$

Yerel uzamsal etkinlik göstergesi z , küçük boyuttaki kare pencere P içerisindeki N adet katsayının mutlak ortalamasıdır:

$$z = \frac{1}{N} \sum_{l \in P} w_l \quad (3.17)$$

Burada w_l dalgacık katsayılarının mutlak değerlerini göstermektedir ($w_l = |y_l|$). Nz_l N tane katsayının toplamını göstermek üzere, $f(Nz_l|H_{0,1})$ $f(w_l|H_{0,1})$ 'nin kendisi ile

N kere evrişimine eşittir. Ayrıca $w_l > 0$ ise $f(w_l|H_{0,1}) = 2f(y_l|H_{0,1})$ 'dir ve $w_l < 0$ ise $f(w_l|H_{0,1}) = 0$ 'dir. $f(y|H_0)$ ve $f(y|H_1)$ denklem (3.18) ile tanımlanmaktadır.

$$\begin{aligned} f(y|H_0) &= \int_{-\infty}^{\infty} \phi(y - \beta; \sigma) f(\beta|H_0) d\beta \\ f(y|H_1) &= \int_{-\infty}^{\infty} \phi(y - \beta; \sigma) f(\beta|H_1) d\beta \end{aligned} \quad (3.18)$$

Burada $\phi(y; \sigma)$ sıfır ortalaması ve σ standart sapmasına sahip Gauss yoğunluğunu göstermektedir. $f(\beta|H_0)$ ve $f(\beta|H_1)$ denklem (3.19) ile elde edilmektedir.

$$\begin{aligned} f(\beta|H_0) &= \begin{cases} \beta_0 \exp(-\lambda |\beta|^v), & \text{eğer } |\beta| \leq T \\ 0, & \text{eğer } |\beta| > T \end{cases} \\ f(\beta|H_1) &= \begin{cases} 0, & \text{eğer } |\beta| \leq T \\ \beta_1 \exp(-\lambda |\beta|^v), & \text{eğer } |\beta| > T \end{cases} \end{aligned} \quad (3.19)$$

Normalizasyon katsayıları β_0 ve β_1 denklem (3.20) ile elde edilmektedir [67].


$$\begin{aligned} \beta_0 &= \frac{\lambda v}{2\Gamma(\frac{1}{v})\Gamma_{inc}((\lambda T)^v, \frac{1}{v})} \\ \beta_1 &= \frac{\lambda v}{2\Gamma(\frac{1}{v})\Gamma_{inc}((\lambda T)^v, \frac{1}{v})} \end{aligned} \quad (3.20)$$

Burada $\Gamma_{inc}(x; a) = \frac{1}{\Gamma(a)} \int_0^x t^{a-1} e^{-t} dt$ tamamlanmamış gamma fonksiyonudur ve λ ölçekleme parametresidir [67]. $P(H_1)$ denklem (3.21) ile elde edilmiştir ve μ 'nin ifadesi denklem (3.22) ile gösterilmektedir [67].


$$\begin{aligned} P(H_1) &= \int_{-\infty}^{\infty} f(\beta|H_1) d\beta = 1 - \int_{-T}^T f(\beta) d\beta \\ P(H_1) &= 1 - \Gamma_{inc}((\lambda T)^v, \frac{1}{v}) \end{aligned} \quad (3.21)$$

$$\mu = \frac{P(H_1)}{P(H_0)} = \frac{1 - \Gamma_{inc}((\lambda T)^v, \frac{1}{v})}{\Gamma_{inc}((\lambda T)^v, \frac{1}{v})} \quad (3.22)$$

Uzamsal uyarlanabilir gürültü azaltımı yöntemi ile ilgili detaylı bilgi için [67]'de önerilen çalışma incelenebilir. Önerilen yöntemde dalgacık uzayında uzamsal uyarlanabilir gürültü azaltım yöntemi [67] birinci İKF'lere uygulanmaktadır ve Şekil 3.7 ile Şekil 3.8'de sırasıyla Indian Pine ve Pavia görüntüleri için birinci İKF ve gürültü giderimi uygulanmış birinci İKF sonuçları örnek bir bant için gösterilerek 1.İKF ve gürültü giderimi uygulanmış 1.İKF arasındaki fark imgeleri verilmektedir. Fark imgeleri 1.İKF ve gürültü giderimi uygulanmış 1. İKF verilerinin fark verisinin 10 katı alınıp her bir piksele 128 değeri eklenerek elde edilmiştir.



Şekil 3.7: Indian Pine verisi 6. bant (a) orijinal bant, (b) 1.İKF (c) gürültü giderimi uygulanmış 1.İKF, (d) 1. İKF ve gürültü giderimi uygulanmış 1.İKF arasındaki fark imgesi



Şekil 3.8: Pavia verisi 3. bant (a) orijinal bant, (b) 1.İKF (c) gürültü giderimi uygulanmış 1.İKF, (d) 1. İKF ve gürültü giderimi uygulanmış 1. İKF arasındaki fark imgesi

3.5.3. Deneysel sonuçlar

Deneysel sonuçlar Indian Pine, Pavia ve Salinas verileri kullanılarak elde edilmiştir. Önerilen yaklaşımın sınıflandırma başarımını göstermek amacı ile RTF çekirdeği ile DVM sınıflandırma algoritması kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma yöntemi kullanılmıştır. Deneysel sonuçlarda, DVM ceza parametresi C [10-1000] arasında ve RTF gamma parametresi [0.1-2] arasında değerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir. 2-B AKA için maksimum ve minimum noktalar her bir piksel değeri için en yakın 8 komşusuna bakılarak belirlenmiştir ve 2-B AKA'da aradeğerleme işlemleri [57, 58]'de tavsiye edilen ince metal plaka eğrileri (thin plate spline interpolation) kullanılarak elde edilmiştir. 2-B AKA'da maksimum ve

minimum noktaları bulmak için pencere boyutu $P=3\times 3$ olarak belirlenmiş ve $\tau = 0.006$ olarak sabitlenmiştir. Dalgacık uzayında gürültü giderimi yöntemi her bant için diğer bantlardan bağımsız olarak hiperspektral görüntüye uygulanmıştır. Sekiz sönen moment (vanishing moment) ile Symmlets dalgacıkları kullanılmış, bütün bantlar için [67]'de önerildiği üzere dört yeniden oluşturma seviyesi kullanılmış ve karesel pencere boyu 7×7 olarak alınmıştır.

Bölüm 3.1'de önerilen çalışmada her bant için AKA uygulandıktan sonra elde edilen düşük dereceli belirli sayıda İKF toplanarak her bir hiperspektral bant sınırlı sayıdaki İKF'den geri çatılmaktadır. Daha sonra bu geri çatılan bantlar üzerinden DVM ile sınıflandırma gerçekleştirilmektedir (2B-AKA-DVM). Bu bölümde önerilen çalışmada ise farklı olarak her bir bant için elde edilen birinci İKF'lere dalgacık uzayında gürültü giderimi uygulandıktan sonra düşük dereceli İKF'ler toplanarak elde edilen yeni veri üzerinden DVM sınıflandırma gerçekleştirilmektedir (önerilen yöntem D-2B-AKA-DVM olarak isimlendirilmiştir). D-2B-AKA-DVM'in başarımı birinci İKF'lere gürültü giderimi yöntemi olarak standart AGS uygulanması ve sonrasında düşük dereceli İKF'lerin toplanması ile elde edilen verinin DVM ile sınıflandırılması sonuçları (AGS-2B-AKA-DVM) ile karşılaştırılmıştır. AGS ile süzgeçleme için ise 5×5 boyutlarında ortalama alan çekirdek kullanılmıştır.

Deneysel sonuçlar ayrıca hiperspektral görüntünün her bir bandının dalgacık uzayında gürültü giderimi [67] uygulandıktan sonra DVM ile sınıflandırılması sonuçları (D-DVM) ve AGS ile süzgeçlendikten sonra DVM ile sınıflandırılması sonuçları (AGS-DVM) ile karşılaştırılmıştır. Dalgacık uzayında gürültü giderimi yöntemi için sekiz sönen moment ile Symmlets dalgacıkları kullanılmış, bütün bantlar için [67]'de önerildiği üzere dört yeniden oluşturma seviyesi kullanılarak karesel pencere boyu 7×7 olarak alınmıştır. AGS ile süzgeçleme için ise 5×5 boyutlarında ortalama alan çekirdek kullanılmıştır.

Tablo 3.9, Tablo 3.10 ve Tablo 3.11'de sırasıyla Indian Pine, Pavia ve Salinas verileri için doğrudan DVM, 2B-AKA-DVM, AGS-2B-AKA-DVM, D-2B-AKA-DVM, D-DVM ve AGS-DVM sonuçları gösterilmektedir. Deneysel sonuçlar, her bir sınıf için toplam verinin %10 ve %50'si eğitim verisi alınarak elde edilmiştir. Sonuçlarda

AKA sonucu her bant için elde edilen İKF'ler kullanılarak bantların geri çatılması yapılırken, sadece ilk İKF'nin kullanılması (1 İKF), ilk iki İKF'nin toplamının kullanılması (2 İKF), ve benzer şekilde ilk üç İKF'nin toplamının kullanılması (3 İKF) ve ilk dört İKF'nin toplamının kullanılması (4 İKF) durumunda elde edilen sınıflandırma başarımları gösterilmektedir. Deneysel sonuçlar D-2B-AKA-DVM, AGS-2B-AKA-DVM ve 2B-AKA-DVM yöntemlerinde en iyi sonucun 2 İKF durumunda elde edildiğini ve D-2B-AKA-DVM'nin en iyi sonucunun 2B-AKA-DVM, D-DVM, AGS-DVM ve AGS-2B-AKA-DVM'den daha başarılı olduğunu göstermektedir. Ayrıca 2B-AKA-DVM, 1 İKF durumunda elde edilen sınıflandırma başarımının D-2B-AKA-DVM kullanılarak önemli oranda artırılacağı gözlemlenmektedir. Tablo 3.12, Tablo 3.13 ve Tablo 3.14'de sırasıyla Indian Pine , Pavia ve Salinas görüntülerindeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı (3.12) [108] verilmektedir ve sınıflar arası uzaklığın önerilen yöntem ile arttığı gözlemlenmektedir. Şekil 3.9'da Indian Pine verisinde ayrılması zor üç sınıfın orijinal piksel değerleri kullanılarak elde edilen ortalama spektral imzaları, bu sınıfların birinci İKF ile ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları ve bu sınıfların birinci İKF'lere gürültü giderimi uygulanması sonrası birinci İKF ile ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları gösterilmektedir. Gürültü giderimi uygulandıktan sonra ilk iki İKF'nin toplamı sonucu sınıfların ortalama spektral imzalarının oldukça ayrılabilir olduğu görülmektedir.

Deneysel sonuçlar diğer İKF'lere gürültü giderimi uygulanması durumu için de elde edilmiştir ve elde edilen sonuçlar sadece birinci İKF'lere gürültü giderimi uygulanması durumuna göre neredeyse benzer hatta bazen çok az bir farkla daha düşüktür.

Tablo 3.9: Indian Pine görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB)

Yöntem		%10	%50
		EVO	EVO
		SB	SB
DVM		82.24	92.57
D-DVM		89.04	97.90
AGS-DVM		87.47	95.65
2B-AKA-DVM	1 İKF	73.96	94.75
	2 İKF	94.00	99.37
	3 İKF	92.56	97.70
	4 İKF	92.23	97.43
AGS-2B-AKA-DVM	1 İKF	89.88	99.61
	2 İKF	95.75	99.97
	3 İKF	92.08	97.55
	4 İKF	91.70	97.40
D-2B-AKA-DVM	1 İKF	93.66	99.95
	2 İKF	95.88	100
	3 İKF	92.17	98.37
	4 İKF	91.70	97.81

Tablo 3.10: Pavia görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB)

Yöntem		%10	%50
		EVO	EVO
		SB	SB
DVM		86.54	92.75
D-DVM		97.35	99.12
AGS-DVM		94.21	97.90
2B-AKA-DVM	1 İKF	91.51	98.57
	2 İKF	96.25	98.97
	3 İKF	96.14	98.72
	4 İKF	90.97	94.99
AGS-2B-AKA-DVM	1 İKF	96.48	99.64
	2 İKF	98.77	99.59
	3 İKF	98.41	99.54
	4 İKF	91.62	95.86
D-2B-AKA-DVM	1 İKF	98.04	100
	2 İKF	98.92	100
	3 İKF	98.46	100
	4 İKF	78.85	89.07

Tablo 3.11: Salinas görüntüsünün DVM, dalgacık uzayında gürültü giderimi sonrası DVM (D-DVM), alçak geçiren süzgeç ile süzgeçleme sonrası DVM (AGS-DVM) ile sınıflandırılması, 2-B AKA sonrası DVM ile sınıflandırılması (2B-AKA-DVM), 1. İKF'nin alçak geçiren süzgeç ile süzgeçlendikten sonra 2B-AKA-DVM ile sınıflandırılması (AGS-2B-AKA-DVM), 1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması (D-2B-AKA-DVM) yöntemlerinin %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB)

Yöntem		%10	%50
		EVO	EVO
		SB	SB
DVM		89.28	90.92
D-DVM		95.64	99.93
AGS-DVM		93.47	95.75
2B-AKA-DVM	1 İKF	91.79	95.39
	2 İKF	99.85	99.97
	3 İKF	99.11	99.96
	4 İKF	99.10	99.98
AGS-2B-AKA-DVM	1 İKF	94.94	100
	2 İKF	99.90	100
	3 İKF	99.88	100
	4 İKF	99.76	99.95
D-2B-AKA-DVM	1 İKF	96.82	100
	2 İKF	99.92	100
	3 İKF	99.90	100
	4 İKF	99.90	99.97

Tablo 3.12: Indian Pine görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı

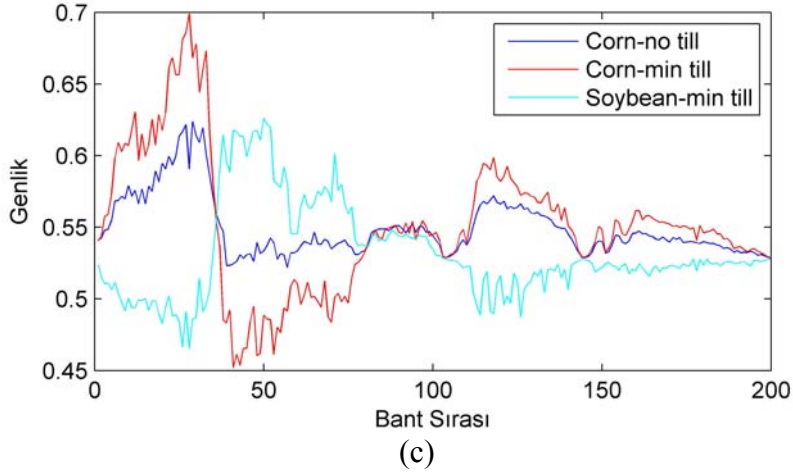
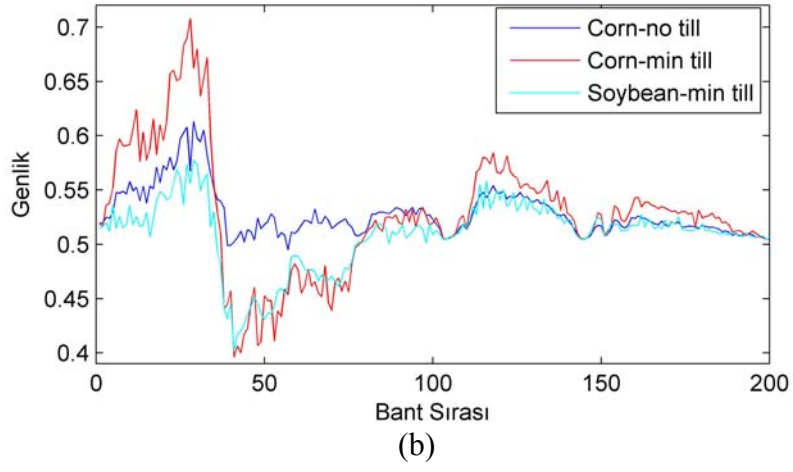
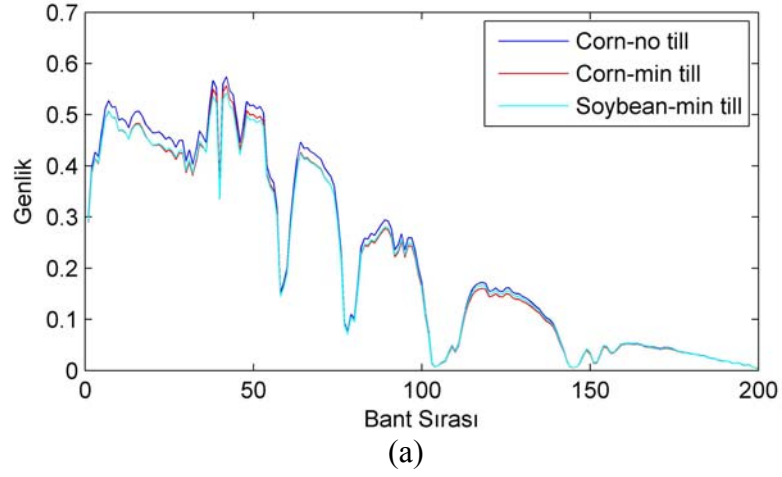
Sınıf Etiketleri	Farklı veri tanımlamaları		
	Orijinal veri	2 İKF (2B-AKA-DVM ile elde edilen)	2 İKF (D-2B-AKA-DVM ile elde edilen)
S-1	7.45	28.66	150.28
S-2	10.05	38.24	207.77
S-3	18.42	49.23	285.96
S-4	14.28	42.19	238.57
S-5	29.83	79.23	381.84
S-6	8.90	33.98	207.55
S-7	5.59	29.71	126.59
S-8	13.40	46.26	263.44
S-9	16.09	46.04	213.77

Tablo 3.13: Pavia görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı

Sınıf Etiketleri	Farklı veri tanımlamaları		
	Orijinal veri	2 İKF (2B-AKA-DVM ile elde edilen)	2 İKF (D-2B-AKA-DVM ile elde edilen)
S-1	5.72	42.12	153.83
S-2	5.76	43.44	168.89
S-3	7.31	49.37	208.59
S-4	7.27	36.98	121.19
S-5	17.35	71.86	238.47
S-6	6.03	55.17	311.08
S-7	9.71	56.29	250.69
S-8	5.55	42.24	154.22
S-9	14.32	50.08	177.17

Tablo 3.14: Salinas görüntüsündeki her bir sınıfın diğer sınıflara olan Bhattacharyya uzaklığı

Sınıf Etiketleri	Farklı veri tanımlamaları		
	Orijinal veri	2 İKF (2B-AKA-DVM ile elde edilen)	2 İKF (D-2B-AKA-DVM ile elde edilen)
S-1	5.92	74.44	120.35
S-2	5.53	71.21	107.13
S-3	139.30	145.66	229.13
S-4	18.97	162.89	320.21
S-5	17.94	91.59	172.13
S-6	23.99	106.69	221.46
S-7	36.15	96.57	181.22



Şekil 3.9: Indian Pine verisinde ayrılması zor üç sınıfın (a) orijinal piksel değerleri kullanılarak elde edilen ortalama spektral imzaları , (b) bu sınıfların birinci İKF ve ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları ve (c) bu sınıfların birinci İKF'lere gürültü giderimi uygulanması sonrası birinci İKF ve ikinci İKF'nin toplamı sonucunda oluşan verideki ortalama spektral imzaları

3.6. Ampirik Kip Ayırımı ve Birleşik Çekirdek Temelli Yüksek Doğruluklu Hiperspektral Görüntü Sınıflandırması

3.6.1. GÜDÜLENME VE ÖNERİLEN YÖNTEM

Birinci İKF'ler yerel en yüksek frekans bileşenlerini içermektedir ve sınıfları birbirinden ayıran sınırlar bu veride oldukça belirgindir. İkinci İKF'ler ise yerel bir sonraki en yüksek frekans bileşenlerini içermektedir fakat orijinal verinin birinci İKF'den çıkarılması sonucu elde edildiği için aslında düşük frekans bileşenlerini içermektedir. Bu nedenle ikinci İKF verisinde sınıf içi değişim düşüktür. Bu alt bölümde ele alınan çalışma ile birinci İKF ve ikinci İKF'nin içerdiği bu bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi önerilmektedir. Önerilen yaklaşımda öncelikle, hiperspektral görüntülerin her bir bandına AKA uygulanmaktadır ve her bir bant ile ilişkili İKF'ler elde edilmektedir. Sonrasında, her bir bant için elde edilen birinci İKF ($İK F_{l,1}, l=1,2,\dots,d$) ve ikinci İKF'nin ($İK F_{l,2}, l=1,2,\dots,d$) içerdiği bilgiler birleşik çekirdekler kullanılarak birleştirilmektedir.

Uzamsal ve spektral bilgileri birleştiren birleşik çekirdek ile DVM sınıflandırma yaklaşımı [24]'de önerilmiştir. [24]'de başlangıç olarak uzamsal ve spektral öznitelik vektörleri ($\mathbf{x}_u^s, \mathbf{x}_u^p$) oluşturulmaktadır ve çekirdek matrisleri uzamsal ve spektral öznitelik vektörleri için ayrı ayrı hesaplanarak birleştirilmektedir. Her bir uzamsal öznitelik vektörü komşu piksellerin ortalama değerleri ya da komşu piksellerin ortalama ve standart sapma değerleri olarak elde edilmektedir [24]. [24]'de çekirdeklerin doğrudan toplanması (3.23) veya çekirdeklerin ağırlıklandırılarak toplanması (3.24) gibi farklı çekirdek birleştirme yaklaşımları kullanılarak sınıflandırma başarımının artırılabilceği gösterilmiştir.

$$K(\mathbf{x}_u, \mathbf{x}_v) = K(\mathbf{x}_u^s, \mathbf{x}_v^s) + K(\mathbf{x}_u^p, \mathbf{x}_v^p) \quad (3.23)$$

$$K(\mathbf{x}_u, \mathbf{x}_v) = \mu K(\mathbf{x}_u^s, \mathbf{x}_v^s) + (1 - \mu) K(\mathbf{x}_u^p, \mathbf{x}_v^p) \quad (3.24)$$

Burada μ uzamsal ve spektral bilgiler arasında ödünleşim sağlamaktadır ve [0-1] arası değerler almaktadır [24]. $K()$ çekirdek fonksiyonunu ve \mathbf{x}_u u . öznelik vektörünü göstermektedir.

Önerilen çalışmada, birinci İKF ve ikinci İKF'lerin içerdiği bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi gerçekleştirilmektedir. Bu nedenle her bir hiperspektral piksel için iki farklı öznelik vektörü oluşturulmaktadır. Bu öznelik vektörleri, her bir bandın birinci İKF'si ($\dot{IKF}_{l,1}, l=1,2,\dots,d$) ile ilişki olan spektral bilgi ve her bir bandın ikinci İKF'si ($\dot{IKF}_{l,2}, l=1,2,\dots,d$) ile ilişkili olan spektral bilgidir. Bu durumda birinci İKF ve ikinci İKF ile ilişkili olan öznelik vektörleri (3.19) kullanılarak elde edilmektedir.

$$\begin{aligned}\mathbf{x}_u^{IKF1} &= \dot{IKF}_{l,1}(ui,uj) \quad l=1,2,\dots,d \\ \mathbf{x}_u^{IKF2} &= \dot{IKF}_{l,2}(ui,uj) \quad l=1,2,\dots,d\end{aligned}\quad (3.25)$$

\mathbf{x}_u^{IKF1} ve \mathbf{x}_u^{IKF2} elde edildikten sonra çekirdek matrisleri hesaplanmaktadır. Önerilen birleşik çekirdek yaklaşımında çekirdeklerin, doğrudan toplanarak birleştirilmesi (3.26) veya ağırlıklandırıldıktan sonra toplanarak birleştirilmesi (3.27) yöntemleri kullanılmaktadır.

$$K(\mathbf{x}_u, \mathbf{x}_v) = K(\mathbf{x}_u^{IKF1}, \mathbf{x}_v^{IKF1}) + K(\mathbf{x}_u^{IKF2}, \mathbf{x}_v^{IKF2}) \quad (3.26)$$

$$K(\mathbf{x}_u, \mathbf{x}_v) = \mu K(\mathbf{x}_u^{IKF1}, \mathbf{x}_v^{IKF1}) + (1-\mu)K(\mathbf{x}_u^{IKF2}, \mathbf{x}_v^{IKF2}) \quad (3.27)$$

3.6.2. Deneysel sonuçlar

Deneysel sonuçlar Indian Pine, DC Mall ve Pavia hiperspektral verilerini kullanarak elde edilmiştir. Önerilen yaklaşımın sınıflandırma başarımını göstermek amacı ile RTF çekirdeği ile DVM sınıflandırma algoritması kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma yöntemi kullanılmıştır. Deneyselerde, DVM ceza parametresi C [10-1000] arasında ve RTF gamma parametresi [0.1-2] arasında değerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir.

Gerçekleştirilen yöntemin sonuçları Indian Pine verisi için 2-B AKA ve hızlı 2-B AKA kullanılarak elde edilmiştir. Her bir sınıf için toplam verinin %10 ve %35'i eğitim verisi olarak alınmıştır. 2-B AKA'da maksimum ve minimum noktaları bulmak için pencere boyutu $P=3 \times 3$ olarak belirlenmiş ve $\tau=0.006$ ve $\tau=0.004$ değerleri için sonuçlar elde edilmiştir. DC Mall verisi için ise piksel boyutunun büyük olmasından dolayı sadece hızlı 2-B AKA kullanılarak sonuçlar elde edilmiştir. Her bir sınıf için toplam verinin %10 ve %35'i eğitim verisi olarak alınmıştır. Salinas verisi için sonuçlar 2-B AKA kullanılarak elde edilmiştir. Her bir sınıf için toplam verinin %10 ve %35'i eğitim verisi olarak alınmıştır. AKA ve hızlı 2-B AKA için maksimum ve minimum noktaları bulmak için pencere boyutu $P = 3 \times 3$ olarak belirlenmiştir. Hızlı 2-B AKA'da kullanılan pencere boyutları $s_{enbüyük}$ ve $s_{enküçük}$ sli değerlerinin belirlenmesi için denklem (3.6) ve (3.7)'deki tüm durumlar denenmiştir ve iki veri kümesi için de denklem (3.7)'de belirtilen enbüyük ölçütünün $s_{enbüyük}$ ve $s_{enküçük}$ değerlerini belirlemede en uygun ölçüt olduğu deneysel olarak belirlenmiştir. 2-B AKA'da aradeğerleme işlemleri ince metal plaka eğrileri (thin plate spline interpolation) kullanılarak elde edilmiştir. Indian Pine verisine hızlı 2-B AKA uygulanarak, 177 bant için 2 İKF ve 23 bant için 3 İKF elde edilmiştir ve 2-B AKA uygulanarak ise 143 bant için 3 İKF ve 57 bant için 4 İKF elde edilmiştir. DC Mall verisine hızlı 2-B AKA uygulanması sonucunda ise 182 bant 3 İKF ve 9 bant 4 İKF içermektedir.

Hızlı 2-B AKA sonucu elde edilen birinci İKF ve ikinci İKF'lerin içerdikleri bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi ve DVM ile sınıflandırılması (H-AKA-BK-DVM), 2-B AKA sonucu elde edilen birinci İKF ve ikinci İKF'lerin içerdikleri bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi ve DVM sınıflandırılması (AKA-BK-DVM), spektral ve uzamsal bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi ve DVM ile sınıflandırılması (SU-BK-DVM) ve doğrudan DVM sınıflandırma sonuçları Indian Pine verisi için Tablo 3.15'de gösterilmektedir. DC Mall verisi için ise H-AKA-BK-DVM, SU-BK-DVM ve doğrudan DVM sonuçları Tablo 3.16'de gösterilmektedir. Salinas verisi için AKA-BK-DVM, SU-BK-DVM ve doğrudan DVM sonuçları Tablo 3.17'de gösterilmektedir. SU-BK-DVM yönteminde her bir uzamsal öznitelik vektörü en

yakın 25 komşu pikselin ortalama değeri alınarak elde edilmiştir. İki çekirdeğin birleştirilmesi için çekirdeklerin doğrudan toplanması ve çekirdeklerin ağırlıklandırılarak toplanması yaklaşımları kullanılmıştır. Çekirdeklerin ağırlıklandırılarak toplanması durumunda μ 'nün [0-1] arası değerleri için sonuçlar elde edilmiştir. Deneysel sonuçlar önerilen H-AKA-BK-DVM ve AKA-BK-DVM yaklaşımlarının, doğrudan DVM ve BK-SU-DVM yöntemlerine göre sınıflandırma başarımını önemli oranda arttırdığını göstermektedir. Deneysel sonuçlar önerilen yaklaşım ile sınıflandırma başarımını doğrudan DVM'ye göre Indian Pine verisi için %11, DC Mall verisi için %0.4 ve Salinas verisi için %10 arttığını göstermektedir. Sınıflandırma başarımındaki artışın sebebi şu şekilde yorumlanabilir: Birinci İKF'ler yerel en yüksek frekans bileşenlerini içermektedir ve sınıfları birbirinden ayıran sınırlar bu veride belirgindir. İkinci İKF'ler ise yerel bir sonraki yüksek frekans bileşenlerini içermektedir fakat orijinal verinin birinci İKF'den çıkarılması sonucu elde edildiği için aslında düşük frekans bileşenlerini içermektedir. Bu nedenle ikinci İKF verisinde sınıf içi değişim düşüktür. Birinci İKF ve ikinci İKF'nin içerdiği bu bilgilerin birleşik çekirdekler kullanılarak birleştirilmesi sonucu DVM sınıflandırma başarımı artmıştır.

Tablo 3.15: Indian Pine görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), 2-B AKA temelli birleşik çekirdek (AKA-BÇ-DVM), hızlı 2-B temelli birleşik çekirdek (H-AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kapa katsayıları (k)

Birleşik Çekirdek Yaklaşımı	Yöntem	%10 EVO		%35 EVO	
		SB	k	SB	k
-	DVM	82.24	0.70	91.47	0.83
Doğrudan	SU-BÇ-DVM	88.69	0.73	96.70	0.94
	AKA-BÇ-DVM, $\tau = 0.006$	94.98	0.77	99.75	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.28	0.77	99.73	0.99
	H-AKA-BÇ-DVM	93.21	0.65	99.74	0.99
Ağırlıklandırılmış, $\mu = 0.1$	SU-BÇ-DVM	87.52	0.69	95.48	0.90
	AKA-BÇ-DVM, $\tau = 0.006$	95.43	0.77	99.77	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.45	0.77	99.85	0.99
	H-AKA-BÇ-DVM	94.30	0.65	99.87	0.99
Ağırlıklandırılmış, $\mu = 0.2$	SU-BÇ-DVM	87.17	0.65	95.63	0.91
	AKA-BÇ-DVM, $\tau = 0.006$	95.24	0.76	99.80	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.45	0.77	99.83	0.99
	H-AKA-BÇ-DVM	94.13	0.65	99.83	0.99
Ağırlıklandırılmış, $\mu = 0.3$	SU-BÇ-DVM	86.97	0.65	95.55	0.91
	AKA-BÇ-DVM, $\tau = 0.006$	95.11	0.76	99.77	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.44	0.77	99.82	0.99
	H-AKA-BÇ-DVM	93.88	0.65	99.77	0.99
Ağırlıklandırılmış, $\mu = 0.4$	SU-BÇ-DVM	86.65	0.66	95.45	0.91
	AKA-BÇ-DVM, $\tau = 0.006$	95.11	0.76	99.79	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.32	0.77	99.82	0.99
	H-AKA-BÇ-DVM	93.57	0.65	99.69	0.99
Ağırlıklandırılmış, $\mu = 0.5$	SU-BÇ-DVM	86.34	0.67	95.16	0.90
	AKA-BÇ-DVM, $\tau = 0.006$	95.26	0.77	99.75	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.28	0.77	99.82	0.99
	H-AKA-BÇ-DVM	93.21	0.65	99.67	0.99
Ağırlıklandırılmış, $\mu = 0.6$	SU-BÇ-DVM	85.97	0.68	94.65	0.89
	AKA-BÇ-DVM, $\tau = 0.006$	94.77	0.75	99.71	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	93.30	0.73	99.77	0.99
	H-AKA-BÇ-DVM	92.75	0.67	99.64	0.99
Ağırlıklandırılmış, $\mu = 0.7$	SU-BÇ-DVM	85.54	0.69	94.26	0.88
	AKA-BÇ-DVM, $\tau = 0.006$	94.54	0.76	99.67	0.99
	AKA-BÇ-DVM, $\tau = 0.004$	95.09	0.77	99.71	0.99
	H-AKA-BÇ-DVM	92.45	0.67	99.53	0.99
Ağırlıklandırılmış, $\mu = 0.8$	SU-BÇ-DVM	85.06	0.70	93.91	0.86
	AKA-BÇ-DVM, $\tau = 0.006$	93.99	0.76	99.51	0.98
	AKA-BÇ-DVM, $\tau = 0.004$	94.74	0.76	99.61	0.99
	H-AKA-BÇ-DVM	92.05	0.68	99.35	0.99
Ağırlıklandırılmış, $\mu = 0.9$	SU-BÇ-DVM	84.22	0.72	93.14	0.85
	AKA-BÇ-DVM, $\tau = 0.006$	92.62	0.75	99.13	0.98
	AKA-BÇ-DVM, $\tau = 0.004$	93.83	0.75	99.43	0.99
	H-AKA-BÇ-DVM	91.17	0.71	99.13	0.98

Tablo 3.16: DC Mall görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), hızlı 2-B AKA temelli birleşik çekirdek (H-AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kapa katsayıları (k)

Birleşik Çekirdek Yaklaşımı	Yöntem	%10 EVO		%35 EVO	
		SB	k	SB	k
-	DVM	99.54	0.98	99.66	0.98
Doğrudan	SU-BÇ-DVM	99.58	0.98	99.83	0.99
	H-AKA-BÇ-DVM	99.90	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.1$	SU-BÇ-DVM	99.64	0.98	99.64	0.98
	H-AKA-BÇ-DVM	99.97	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.2$	SU-BÇ-DVM	99.64	0.98	99.68	0.98
	H-AKA-BÇ-DVM	100	1	100	1
Ağırlıklandırılmış, $\mu = 0.3$	SU-BÇ-DVM	99.62	0.98	99.68	0.98
	H-AKA-BÇ-DVM	99.97	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.4$	SU-BÇ-DVM	99.58	0.98	99.77	0.98
	H-AKA-BÇ-DVM	99.91	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.5$	SU-BÇ-DVM	99.58	0.98	99.83	0.98
	H-AKA-BÇ-DVM	99.90	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.6$	SU-BÇ-DVM	99.60	0.97	99.81	0.98
	H-AKA-BÇ-DVM	99.77	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.7$	SU-BÇ-DVM	99.60	0.97	99.81	0.98
	H-AKA-BÇ-DVM	99.71	0.98	100	1
Ağırlıklandırılmış, $\mu = 0.8$	SU-BÇ-DVM	99.60	0.97	99.81	0.98
	H-AKA-BÇ-DVM	99.68	0.98	100	1
Ağırlıklandırılmış, $\mu = 0.9$	SU-BÇ-DVM	99.60	0.97	99.79	0.98
	H-AKA-BÇ-DVM	99.51	0.98	100	1

Tablo 3.17: Salinas görüntüsünün sınıflandırılmasında DVM, spektral ve uzamsal bilgileri birleştiren birleşik çekirdek (SU-BÇ-DVM), 2-B AKA temelli birleşik çekirdek (AKA-BÇ-DVM) yöntemlerinin %10 ve %35 eğitim verisi oranı (EVO) kullanılarak elde edilen yüzde sınıflandırma başarımları (SB) ve kapa katsayıları (k)

Birleşik Çekirdek Yaklaşımı	Yöntem	%10 EVO		%35 EVO	
		SB	k	SB	k
-	DVM	89.28	0.87	90.27	0.89
Doğrudan	SU-BÇ-DVM	99.42	0.98	99.73	0.98
	AKA-BÇ-DVM	99.90	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.1$	SU-BÇ-DVM	99.52	0.98	99.73	0.98
	AKA-BÇ-DVM	99.92	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.2$	SU-BÇ-DVM	99.54	0.98	99.77	0.98
	AKA-BÇ-DVM	99.91	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.3$	SU-BÇ-DVM	99.51	0.98	99.77	0.98
	AKA-BÇ-DVM	99.86	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.4$	SU-BÇ-DVM	99.59	0.98	99.77	0.98
	AKA-BÇ-DVM	99.89	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.5$	SU-BÇ-DVM	99.60	0.98	99.85	0.99
	AKA-BÇ-DVM	99.80	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.6$	SU-BÇ-DVM	99.62	0.97	99.82	0.98
	AKA-BÇ-DVM	99.77	0.99	100	1
Ağırlıklandırılmış, $\mu = 0.7$	SU-BÇ-DVM	99.62	0.97	99.82	0.98
	AKA-BÇ-DVM	99.71	0.98	100	1
Ağırlıklandırılmış, $\mu = 0.8$	SU-BÇ-DVM	99.60	0.97	99.82	0.98
	AKA-BÇ-DVM	99.68	0.97	100	1
Ağırlıklandırılmış, $\mu = 0.9$	SU-BÇ-DVM	99.60	0.97	99.80	0.98
	AKA-BÇ-DVM	99.61	0.97	100	1


3.7. Hiperspektral Görüntü Sınıflandırması için Ampirik Kip Ayrışımı Temelli Karar Tümeleşirme

3.7.1. GÜDÜLENME VE ÖNERİLEN YÖNTEM

Daha önceki alt bölümlerde bahsedildiği üzere düşük dereceli İKF'ler yerel uzamsal bilgileri içermekte, yüksek dereceli İKF'ler ile ise yerel uzamsal bilgiler neredeyse kaybolmaktadır (yani yüksek dereceli İKF'ler yavaş uzamsal salınım kiplerini içermektedir). Ayrıca Bölüm 3.4'de birinci ve ikinci İKF'nin toplamı sonucunda oluşan verinin yüksek DVM başarımı sağladığı gösterilmiştir. Bu alt bölümde önerilen çalışmada ise birinci İKF, ikinci İKF, birinci ve ikinci İKF'nin toplamı sonucunda oluşan veri ve ayrıca orijinal veri birbirinden bağımsız olarak DVM ile

sınıflandırılmaktadır ve elde edilen sonuçlar karar tümleştirme algoritmasıyla birleştirilmektedir.

Önerilen çalışmada hiperspektral görüntülerin farklı tanımlamalarının, i) birinci İKF'ler ile oluşan veri, ii) ikinci İKF'ler ile oluşan veri, iii) ilk iki İKF'nin toplamı sonucu oluşan veri ve iv) orijinal veri, birbirinden bağımsız olarak sınıflandırılması sonucu elde edilen sonuçların karar tümleştirme algoritması ile birleştirilerek sınıflandırma başarımının artırılması amaçlanmaktadır. İlk olarak 2-B AKA hiperspektral görüntülere uygulanmakta ve yukarıda bahsedilen farklı hiperspektral veri tanımlamaları elde edilmektedir. Sonrasında sınıflandırma sonuçları birleştirme işlemine dahil edilecek her bir veri DVM ile sınıflandırılmaktadır. Şekil 3.10'da örnek bir bant için birinci İKF, ikinci İKF, ilk iki İKF'nin toplamı ve orijinal veri gösterilmektedir.



Şekil 3.10: Indian Pine verisi 28. bant (a) orijinal bant, (b) 1. İKF, (c) 2. İKF ve (d) ilk iki İKF'nin toplamı

Çok sınıflı DVM sınıflandırma için bire-hepsi DVM kullanılmıştır. Bire-hepsi çok sınıflı DVM sınıflandırma yöntemi n sınıf sayısı olmak üzere n tane DVM modeli geliştirmektedir. Örneğin, i . DVM modelinde i . sınıfın bütün elemanları pozitif etiketli sınıfın, kalan diğer sınıfların bütün elemanları negatif etiketli sınıfın

elemanları olmak üzere eğitim işlemi gerçekleştirilmektedir. Sınıflandırma aşamasında ise test örnekleri bütün modeller kullanılarak test işlemine sokulmakta ve her bir test verisinin (\mathbf{x}) hiperdüzlemlere uzaklığı ($f_i(\mathbf{x})$, $i=1,2,\dots,n$) elde edilmektedir. Son olarak her bir test verisi hiperdüzlemlere en uzak olan sınıfa etiketlenmektedir.

Karar tümleştirme aşamasında üç farklı yaklaşım kullanılmaktadır. Birinci yaklaşımda her bir test verisi hiperdüzlemine uzaklığın en büyük olduğu sınıfa dahil edilmektedir ve bu yaklaşım denklem (3.28) ile ifade edilmektedir.

$$w = \underset{\substack{i=1,2,\dots,n \\ j=1,1,\dots,k}}{\operatorname{argmax}} \{f_{ij}(\mathbf{x})\} \quad (3.28)$$

Burada $f_{ij}(\mathbf{x})$, \mathbf{x} verisinin j . ($j=1,2,\dots,k$, k karar tümleştirme aşamasında sınıflandırma sonuçları dahil edilecek toplam veri tanımlaması sayısıdır) veri tanımlaması kullanılması durumunda i . hiperdüzleme uzaklığını (yani i . DVM durumunda elde edilen hiper düzleme uzaklığını) göstermektedir ve w kazanan sınıftır.

İkinci yaklaşım ise en yüksek olasılık yaklaşımıdır. Bu yaklaşımda her bir test verisi olasılığın en yüksek olduğu sınıfa dahil edilmektedir:

$$w = \underset{\substack{i=1,2,\dots,n \\ j=1,1,\dots,k}}{\operatorname{argmax}} \{P_j(w_i|\mathbf{x})\} \quad (3.29)$$

Burada $P_j(w_i|\mathbf{x})$ j . veri tanımlaması kullanılması durumunda i . sınıfın sonsal olasılığını göstermektedir. Her bir ikili DVM sonucu Platt tarafından önerilen yöntem [115] kullanılarak sonsal olasılıklara dönüştürülmektedir.

Üçüncü yaklaşım ise veri tanımlamalarının sınıflandırıcı açısından güvenilirliğini hesaba katmaktadır ve her bir test verisini aşağıdaki denklemi büyükleyen sınıfa atamaktadır [116].

$$w = \operatorname{argmax}_{i=1,2,\dots,n} \{F_i(\mathbf{x})\} \quad (3.30)$$

Burada F_i , w_i sınıfının üyelik fonksiyonudur ve denklem (3.31) ile tanımlanmaktadır.

$$F_i(\mathbf{x}) = \prod_{j=1}^k p(w_i) \{P_j(w_i|\mathbf{x}) / p(w_i)\}^{a_j} \quad (3.31)$$

Burada $p(w_i)$, w_i sınıfının önsel olasılığını göstermektedir. a_j güvenilirlik parametresidir ve [0-1] arası değerler almaktadır [116]. Bu çalışmada güvenilirlik parametreleri deneysel olarak belirlenmiştir.

3.7.2. Deneysel sonuçlar

Deneysel sonuçlar Indian Pine, Pavia ve Salinas görüntüleri kullanılarak elde edilmiştir. Gerçekleştirilen yöntemin sonuçları 2-B AKA kullanılarak elde edilmiştir. Her bir sınıf için toplam verinin %10'u eğitim verisi olarak alınmıştır. 2-B AKA'da maksimum ve minimum noktaları bulmak için pencere boyutu $P=3 \times 3$ olarak belirlenmiş ve $\tau=0.006$ olarak sabitlenmiştir. 2-B AKA'da aradeğerleme işlemleri ince metal plaka eğrileri (thin plate spline interpolation) kullanılarak elde edilmiştir.

Tablo 3.18, Tablo 3.19 ve Tablo 3.20'de sırasıyla Indian Pine, Pavia ve Salinas verileri için birinci İKF'ler ile oluşan verinin, ikinci İKF'ler ile oluşan verinin, ilk iki İKF'nin toplamı sonucu oluşan verinin ve orijinal verinin DVM sınıflandırma sonuçları gösterilmektedir. Deneysel sonuçlarda birinci İKF'ler ile oluşan tanımlama \dot{IKF}_1 olarak, ikinci İKF'ler ile oluşan tanımlama \dot{IKF}_1 olarak ve ilk iki İKF'nin toplamı sonucu elde edilen tanımlama ise $\dot{IKF}_1 + \dot{IKF}_2$ ile gösterilmektedir. En yüksek sınıflandırma başarımları ikinci İKF'ler ile oluşan verinin ve ilk iki İKF'nin toplamı sonucu oluşan verinin sınıflandırılması sonucu elde edilmiştir. İkinci İKF'lerin kullanılması durumunda sınıflandırma başarımının yüksek olmasının

sebebi, ikinci İKF'lerin yerel uzamsal yapıları koruması ve bununla beraber alçak frekans bileşenlerini de içermesidir. Bu nedenle sınıf içi değişinti azaltmakta ve sınıflandırma başarımı artmaktadır. İlk iki İKF'nin toplamı sonucu elde edilen sınıflandırma başarımının sadece ikinci İKF kullanılması ile elde edilen başarımdan düşük olmasının sebebi birinci İKF'nin gürültü içermesidir (birinci İKF yerel en yüksek frekans bileşenlerini içermektedir). Önerilen çalışmanın amacı ise elde edilen bu başarımları karar tümleştirme algoritması kullanarak daha da arttırmaktır.

Tablo 3.21, Tablo 3.22 ve Tablo 3.23'de sırasıyla Indian Pine, Pavia ve Salinas verileri için yukarıda bahsedilen veri tanımlamalarının sınıflandırma sonuçlarının tümleştirilmesi sonuçları verilmiştir. Tablolarda sınıflandırma sonucu birleştirme işlemine dahil edilecek veriler işaretlenilerek gösterilmiştir. Deneysel sonuçlar karar tümleştirmesi yaklaşımının sınıflandırma başarımını arttırdığını göstermektedir. En yüksek başarımlar ikinci İKF'ler ile oluşan verinin ve ilk iki İKF'nin toplamı sonucu oluşan verinin sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilmiştir ve üç karar kuralı ile ilişkili sonuçlar birbirine benzerdir. Tablo 3.24, Tablo 3.25 ve Tablo 3.26'da, sırasıyla Indian Pine ve Pavia verileri için, orijinal verinin sınıflandırmada kullanılması sonucu elde edilen sınıf başarımları ve ikinci İKF'ler ile oluşan verinin sınıflandırma sonuçlarının ilk iki İKF'nin toplamı sonucu oluşan verinin sınıflandırma sonuçları ile tümleştirilmesiyle elde edilen sınıf başarımları (bu sonuçlar en büyük uzaklık karar kuralı kullanılması durumunda elde edilmiştir) gösterilmektedir. Bu tablolardan tüm sınıfların sınıflandırma başarımlarının önerilen karar tümleştirme yöntemi kullanılarak arttığı gözlemlenmektedir.

Önerilen karar tümleştirme algoritmasının başarımı [31]'de önerilen yöntem ile karşılaştırılmıştır. [31]'de biçimbilimsel profiller ve orijinal veri ayrı ayrı DVM ile sınıflandırılmakta ve sınıflandırma sonuçları karar tümleştirme algoritmaları ile tümleştirilmektedir. Sonuçlar önerilen yaklaşımın başarısını onaylamaktadır. [31]'de önerilen çalışma ile sınıflandırma başarımı Indian Pine ve Pavia verileri için %10 artmışken, önerilen çalışma ile sınıflandırma başarımları Indian Pine ve Pavia verileri için %14 artmıştır. Deneysel sonuçlar tüm AKA temelli yöntemlerin karşılaştırıldığında karar tümleştirmesi yönteminin en iyi sonucu verdiğini göstermektedir.

Tablo 3.18: Indian Pine görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)

Veri Tanımlamaları	SB
Orijinal veri	82.80
$\dot{I}KF_1$	77.68
$\dot{I}KF_2$	95.75
$\dot{I}KF_1 + \dot{I}KF_2$	94.27

Tablo 3.19: Pavia görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)

Veri Tanımlamaları	SB
Orijinal Veri	85.27
$\dot{I}KF_1$	93.27
$\dot{I}KF_2$	98.52
$\dot{I}KF_1 + \dot{I}KF_2$	96.99

Tablo 3.20: Salinas görüntüsünün farklı tanımlamaları için elde edilen DVM sınıflandırma başarımları (SB)

Veri Tanımlamaları	SB
Orijinal Veri	89.28
$\dot{I}KF_1$	91.79
$\dot{I}KF_2$	99.87
$\dot{I}KF_1 + \dot{I}KF_2$	99.85

Tablo 3.21: Indian Pine görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)

Farklı Hiperspektral Veri Tanımlamaları				EnBüyük Uzaklık	EnBüyük Olasılık	Veri Güvenirliği
Orijinal veri	$\dot{I}KF_1$	$\dot{I}KF_2$	$\dot{I}KF_1 + \dot{I}KF_2$			
√	√			87.17	87.30	87.48
√		√		94.56	95.05	95.00
√			√	93.63	94.11	94.24
	√	√		93.77	94.77	94.28
	√		√	92.63	93.33	92.91
		√	√	96.22	96.23	96.18
	√	√	√	94.92	95.62	95.85
√	√	√	√	94.37	95.30	96.11

Tablo 3.22: Pavia görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)

Farklı Hiperspektral Veri Tanımlamaları				EnBüyük Uzaklık	EnBüyük Olasılık	Veri Güvenirliği
Orijinal veri	\dot{IKF}_1	\dot{IKF}_2	$\dot{IKF}_1 + \dot{IKF}_2$			
√	√			91.86	93.10	94.89
√		√		96.11	98.61	98.84
√			√	94.32	96.91	96.96
	√	√		98.61	98.98	98.91
	√		√	96.62	96.91	97.05
		√	√	99.38	99.38	98.89
	√	√	√	98.61	98.95	98.86
√	√	√	√	96.42	98.91	99.01

Tablo 3.23: Salinas görüntüsünün farklı tanımlamalarının DVM ile sınıflandırma sonuçlarının karar tümleştirilmesi ile birleştirilmesi sonucu elde edilen sınıflandırma başarımları (SB)

Farklı Hiperspektral Veri Tanımlamaları				EnBüyük Uzaklık	EnBüyük Olasılık	Veri Güvenirliği
Orijinal veri	\dot{IKF}_1	\dot{IKF}_2	$\dot{IKF}_1 + \dot{IKF}_2$			
√	√			95.72	95.24	94.96
√		√		98.31	98.27	98.37
√			√	97.58	97.05	97.63
	√	√		98.45	98.62	98.47
	√		√	96.27	96.71	96.95
		√	√	99.95	99.95	99.91
	√	√	√	98.91	98.93	98.89
√	√	√	√	97.27	97.89	98.01

Tablo 3.24: Indian Pine verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)

Yöntem	Sınıf Etiketleri								
	1	2	3	4	5	6	7	8	9
DVM_{orj}	0.6667	0.6280	0.9374	0.9866	0.9932	0.6762	0.8532	0.8569	0.9914
$DVM_{tüm}$	0.8031	0.9827	0.9799	0.9940	0.9977	0.9816	0.9964	0.9764	1.0000

Tablo 3.25: Pavia verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)

Yöntem	Sınıf Etiketleri								
	1	2	3	4	5	6	7	8	9
DVM_{orj}	0.7363	0.8951	0.7188	0.8896	0.9874	0.8389	0.9466	0.8160	0.9807
$DVM_{tüm}$	1.0000	1.0000	0.9972	0.9766	1.0000	1.0000	1.0000	0.9913	0.9903

Tablo 3.26: Salinas verisi için orijinal verinin DVM sınıflandırma sonuçları (DVM_{orj}) ve \dot{IKF}_2 ile $\dot{IKF}_1 + \dot{IKF}_2$ verilerinin DVM sınıflandırma sonuçlarının tümleştirilmesi sonucu elde edilen sınıf başarımları ($DVM_{tüm}$)

Yöntem	Sınıf Etiketleri						
	1	2	3	4	5	6	7
DVM_{orj}	0.8374	0.9315	0.9466	0.7524	0.7787	0.8789	0.9363
$DVM_{tüm}$	1.0000	1.0000	0.9917	0.9887	1.0000	1.0000	1.0000

3.8. Vargılar

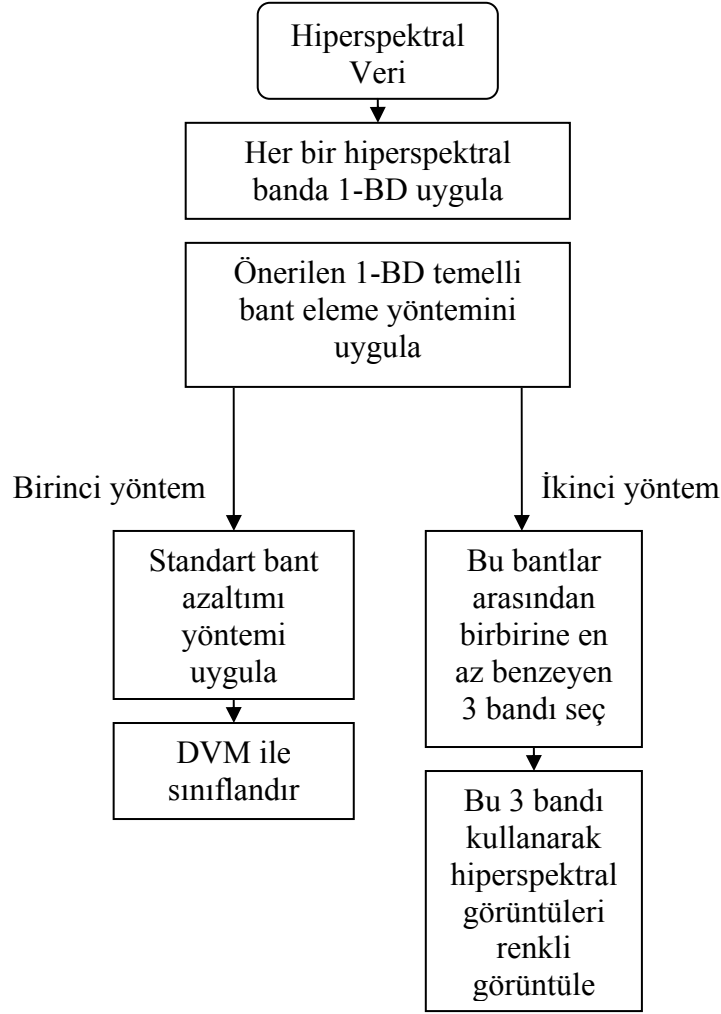
AKA temelli geliştirilen yöntemlerin DVM sınıflandırma başarımını başarılı bir şekilde arttırdığı deneysel sonuçlar ile gösterilmiştir. Sınıflandırma başarımlarındaki artışın nedeni geliştirilen AKA temelli yöntemler ile sınıflar arası uzaklıkların önemli bir oranda artırılması, hiperspektral görüntülerin uydudan veya uçaktan alınması sırasında arazinin satır satır taranma işlemlerinden dolayı oluşan yerel düşük frekansların veriden arındırılması ve sınıf içi değişimlerin AKA temelli yöntemler ile azalmasıdır. Geliştirilen AKA temelli özgün yöntemler ile hiperspektral görüntülerin sınıflandırılmasında literatürde var olan neredeyse en yüksek sınıflandırma başarımları elde edilmektedir. Geliştirilen AKA temelli yöntemler ile yeryüzü arazisinin satır satır taranması sırasında her bir bandeda oluşan yerel düşük frekans bileşenlerinin veriden arındırılarak spektral ve uzamsal bilgilerin birleştirilmesinin hiperspektral görüntülerin sınıflandırılmasında büyük başarımlar sağladığı gösterilmiştir. 2-B AKA'nın [57, 58] 2-B eğri aradeğerlemesi işlemlerinden dolayı hesapsal yükünün fazla olması nedeniyle piksel boyutu yüksek hiperspektral verilerde başarımları 2-B AKA'dan düşük olan hızlı 2-B AKA [59,60] kullanılması önerilmektedir.

4. BİR-BİT DÖNÜŞÜMÜ TEMELLİ YAKLAŞIMLAR

4.1. GÜDÜLENME

Bir-bit dönüşümü (1-BD) videoda basit ve hızlı hareket kestirimi için video çerçevesinin tek bit derinliğe indirilmesi ve bu sayede mantıksal D-VEYA tabanlı hızlı bir karşılaştırma yapılması için ilk defa [43]'de önerilmiştir. Bu bölümde ele alınan çalışmalarda 1-BD hiperspektral verilere uygulanarak az ayrılabilen iyi yapılandırılmamış bantların 1-BD temelli düşük hesapsal yüke sahip ve donanımsal olarak gerçekleştirilmesi uygun bir yaklaşım kullanılarak elenmesi önerilmektedir. Geliştirilen yöntemler düşük hesapsal yüke sahip olması ve donanımsal olarak gerçekleştirmeye uygun olması nedeniyle önemlidir. Geliştirilen 1-BD temelli bant eleme yöntemlerin donanıma uygunluğu [117]'de gösterilerek yöntemler FPGA ile gerçekleştirilmiştir.

Bu tez çalışması kapsamında 1-BD temelli iki yöntem önerilmektedir. Birinci yöntemde 1-BD hiperspektral verilere uygulanarak iyi yapılandırılmamış bantların standart bant azaltımı yöntemleri öncesi elenmesi amaçlanmaktadır. Bu sayede standart bant azaltımı yöntemlerinin hesapsal karmaşıklığı azaltılmaktadır. İkinci yöntemde ise 1-BD temelli özgün bir yöntem kullanılarak üç bant seçilmektedir ve bu bantlar hiperspektral görüntülerin renkli görüntülenmesi amacıyla kullanılmaktadır. Bu bölümde önerilen yöntemlerin blok şeması Şekil 4.1'de gösterilmektedir.

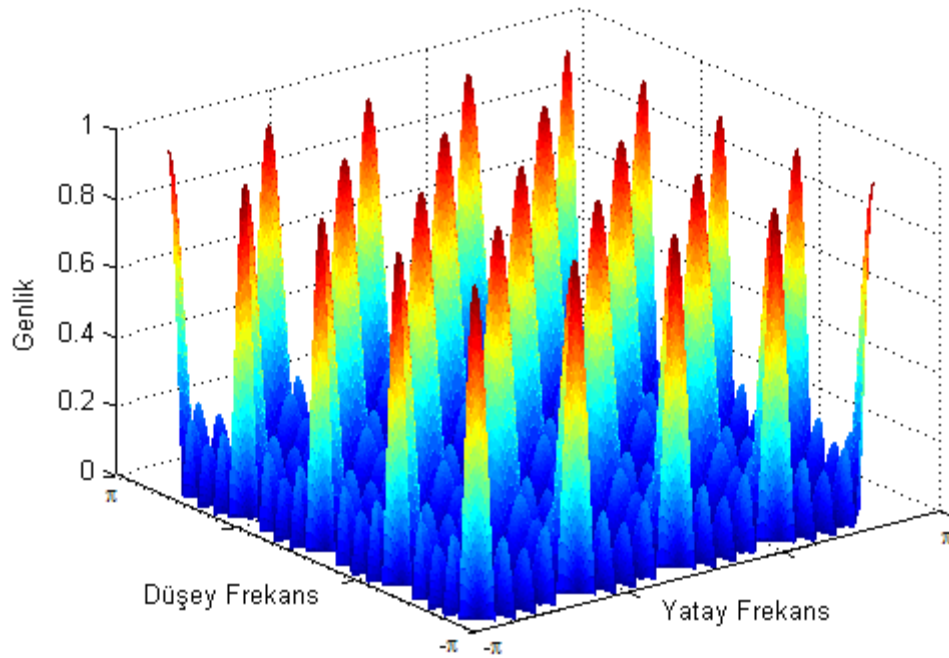


Şekil 4.1: Gerçekleştirilen 1-BD temelli algoritmaların blok şeması


4.2. Bir-Bit Dönüşümü

Bir-bit dönüşümünde imge çerçeveleri denklem (4.1)'de verilen çekirdek (kernel) ifadesi kullanılarak süzgeçlenmektedir. Bu çekirdek matrisi 17×17 piksel boyutlarındadır. [43]'de önerilen çekirdek çoklu bant geçiren bir süzgeç yapısına sahiptir ve denklem (4.1) ile ifade edilmektedir. Bu süzgecin frekans yanıtı Şekil 4.2'de gösterilmektedir. Örnek bir hiperspektral bant için orijinal bant ve bu bandın çoklu bant geçiren süzgeç ile süzgeçlendikten sonra oluşan veri Şekil 4.3'de gösterilmektedir. Çekirdeğin çoklu bant geçiren bir yapıya sahip olmasından dolayı bazı yüksek frekans ve bazı düşük frekans bantları geçirilmektedir.

$$K = \frac{1}{25} \begin{bmatrix} 10001000100010001 \\ 00000000000000000 \\ 00000000000000000 \\ 00000000000000000 \\ 10001000100010001 \\ 00000000000000000 \\ 00000000000000000 \\ 00000000000000000 \\ 10001000100010001 \\ 00000000000000000 \\ 00000000000000000 \\ 00000000000000000 \\ 10001000100010001 \\ 00000000000000000 \\ 00000000000000000 \\ 00000000000000000 \\ 10001000100010001 \end{bmatrix} \quad (4.1)$$



Şekil 4.2: 1-BD’de kullanılan çekirdek süzgecinin frekans yanıtı




Şekil 4.3: Indian Pine verisi 113. bant (a) orijinal bant ve (b) çoklu bant geçiren süzgeç ile süzgeçlendikten sonra oluşan bant

İmge çerçevesi denklem (4.1)'de verilen çekirdek ile süzgeçleme işleminden geçirildikten sonra denklem (4.2)'de verilen karşılaştırma ifadesi ile sadece “0” ve “1” değerlerinden oluşan ikili imgeye dönüştürülmektedir [43].

$$B(i, j) = \begin{cases} 1, & I(i, j) \geq I_F(i, j) \\ 0, & \text{aksi halde} \end{cases} \quad (4.2)$$

Burada I_F çerçevesi, I çerçevesinin çekirdek matrisi ile evrişimi sonucunda elde edilmektedir. Elde edilen ikili imgelerde detayların oldukça iyi korunduğu gözlemlenmektedir [68]. Bunun nedeni, çekirdek süzgecinin ikili imgenin elde edilmesi sırasında uyarlamalı eşik özelliği göstermesidir. Diğer bir ifadeyle, ikili imgeye dönüştürülecek olan orijinal imge üzerinde, sabit bir eşik değeri yerine değişken bir eşik değeri kullanılmaktadır. İkili imge, sabit eşik değeri kullanılarak elde edildiğinde ise detaylar kaybolmaktadır [68]. Indian Pine verisinin örnek bir bandına sabit eşik yöntemi ve [43]'de önerilen yöntem uygulanarak elde edilen 1-BD'leri Şekil 4.4'de gösterilmektedir.



Şekil 4.4: 113. bandın (a) [43]'de önerilen yöntem ve (b) sabit eşik kullanılarak elde edilen 1-BD'leri

Denklem (4.1)'de ifade edilen çekirdek ifadesinde normalizasyon işlemi 25'e bölünerek gerçekleştirildiği için kayan noktalı aritmetik işlemlerinin kullanılması gerekmektedir ve kayan noktalı aritmetik işlemleri donanımsal olarak gerçekleştirmek tamsayı aritmetik işlemlere göre daha zordur. Bununla birlikte hedeflenen başarımının yanı sıra güç tüketimi kayan noktalı aritmetik işlemler ile artmaktadır [68]. [44]'de önerilen çarpmasız 1-BD yönteminde bir-bit dönüşümünde yer alan çekirdek ifadesinde normalizasyon işlemi için kullanılan normalizasyon katsayısı 2'nin kuvveti şeklinde ayarlanmış, aynı zamanda çekirdek süzgecinin yapısı da değiştirilmiştir. Yeni oluşturulan süzgecin yapısı elmas şeklindedir. Çarpmasız 1-BD yönteminde kullanılan çekirdek süzgeci denklem (4.3)'de gösterilmektedir. Bu çekirdek süzgecinin frekans yanıtı ise Şekil 4.5'de gösterilmektedir.


4.3. Bir-Bit Dönüşümü Temelli Bant Azaltımı

Hiperspektral algılayıcılar ile birçok dar dalga boyunda görüntü alınmakta ve bu nedenle bantlar arası artıklık oluşmaktadır. Bilgi kaybına sebep olmadan bant sayısı azaltılabilmekte ve bunun sonucu olarak sınıflandırma yöntemlerinin hesapsal süresi sınıflandırma başarımından ödün vermeden azaltılabilmektedir. Ayrıca hiperspektral görüntülerin eğitim verisi miktarının çoğu zaman az olması ve yüksek bant sayısı içermesi de sınıflandırma başarımı düşürmektedir (yani Hughes olgusu gözlemlenmektedir) [109]. Bu problemi çözenin yollarından birisi bant azaltımı yöntemlerinin sınıflandırma öncesi kullanımınıdır. Bant seçme algoritmaları ile çeşitli arama stratejileri kullanarak d bantlı orijinal veriden veriyi en iyi temsil eden m adet bant ($m < d$) seçilmektedir. Literatürde bant azaltımı amacıyla birçok yöntem önerilmiştir [39-41]. Bu yöntemler kullanılan arama stratejilerinden dolayı yüksek hesapsal yük getirmektedir. Bu alt bölümde hiperspektral görüntülerde bant azaltımı yöntemlerinin hesapsal karmaşıklığını azaltmak amacı ile 1-BD kullanımı önerilmektedir.

4.3.1. Önerilen yöntem

Hiperspektral görüntülerde bant azaltımı yöntemlerinin hesapsal karmaşıklığını azaltmak amacı ile tez kapsamında özgün olarak 1-BD kullanılmıştır. 1-BD dönüşümü olarak [43]'de önerilen 1-BD ve [44]'de önerilen çarpmasız 1-BD kullanılmıştır. Gerçekleştirilen çalışma ile standart bant azaltımı yöntemlerinden önce 1-BD kullanılarak az ayrılabilen bantların elenmesi sağlanmaktadır. Bu doğrultuda öncelikle her bant için süzgeçleme ve karşılaştırma operatörleri kullanılarak 1-BD elde edilmektedir. Sonrasında 1-BD uygulanmış her banttaki satır ve sütundaki değişimlerin sayısı, ilgili bandın ayrışım ölçütü olarak alınmaktadır ve bu değişim sayısı yüksek ise o bandın daha çok gürültü özelliği taşıdığı, düşük ise ayıricılığının iyi olduğuna karar verilmektedir (yani bir bant için toplam değişim sayısı bir eşik değeri ile karşılaştırılarak ayırt ediciliği yüksek bantlara karar verilmektedir). Önerilen yöntemin performansını göstermek amacı ile önerilen yöntem standart en hızlı tırmanış (EHT) bant azaltımı [41] yöntemine ön işlem olarak kullanılmıştır. Önerilen yöntemin sınıflandırma başarımı üzerindeki etkisini

göstermek üzere de DVM temelli sınıflandırma kullanılmıştır. Deneysel sonuçlar önerilen yöntemin, bant azaltımı yöntemlerinin hesapsal yükünü azaltmakla birlikte, sınıflandırma başarımını da benzer seviyelerde tutabildiğini ve hatta bazen arttırabildiğini göstermiştir. Şekil 4.6 (a) ve (c) doğrudan EHT bant azaltım yöntemi ile önemsiz bulunmuş (sınıflandırma için seçilmeyen) örnek bir bandın sırasıyla [43]'de önerilen 1-BD ve [44]'de önerilen çarpmasız 1-BD'lerini göstermektedir. Şekil 4.6 (b) ve (d)'de gösterilen bantlar ise EHT bant azaltım yöntemi ile sınıflandırma açısından önemli olarak bulunmuş örnek bir bandın sırasıyla [43]'de önerilen 1-BD ve [44]'de önerilen çarpmasız 1-BD'lerini göstermektedir. Bu şekilden görüldüğü gibi, önemsiz bantlar çok fazla değişim göstermekte (bir nevi gürültü gibi), önemli bantlar is belirli bir yapıda bulunmaktadır. Bu nedenle, bir-bit dönüşümündeki uzamsal bit değişimi (0-1 değişimi ve tersi) hesaplanarak önemsiz bantların bant azaltımı öncesi atılması ve bant azaltımının hesapsal yükünün azaltılması sağlanmıştır. Bir bandın önemli olup olmadığının ölçütü her bant için yatay ve dikey doğrultudaki bit değişimi hesaplanarak elde edilmektedir. Toplam değişim sayısı belirli bir eşik değeri ile karşılaştırılarak önemli bantlara karar verilmektedir. Sonrasında ise önemli olarak bulunan bantlar üzerinden standart bir bant azaltım (burada EHT) yöntemi uygulanmaktadır.



Şekil 4.6: (a) 104. bandın 1-BD, önemsiz bant (değişim sayısı 16465) (b) 113. bandın 1-BD, önemli bant (değişim sayısı 5686) (c) 104. bandın çarpmasız 1-BD, önemsiz bant (değişim sayısı 17249) (d) 113. bandın çarpmasız 1-BD, önemli bant (değişim sayısı 6271)

Bant karakteristiklerinin ölçümü olarak, bantların 1-BD'lerindeki uzamsal bit değişimlerinin (1-0 ve 0-1 değişimleri) sayılmaktadır. 1-BD'leri [43]'de önerilen 1-BD veya [44]'de önerilen çarpmasız 1-BD kullanılarak elde edilebilmektedir. Her bant için yatay ve düşey doğrultudaki toplam değişim sayısı yapısallık ölçütü olarak kullanılmaktadır. Bu doğrultuda l indisli hiperspektral bandın 1-BD'deki toplam değişim sayısı $A(l)$ (4.4)'deki gibi hesaplanmaktadır.

$$A(l) = \sum_i \sum_j B_i^{1BD}(i, j) \oplus B_i^{1BD}(i-1, j) + \sum_i \sum_j B_i^{1BD}(i, j) \oplus B_i^{1BD}(i, j-1) \quad (4.4)$$

Burada B_i^{1BD} , l 'inci bandın bir-bit dönüşümünü, \oplus mantıksal D-VEYA işlemini ve (i, j) uzamsal koordinatları göstermektedir. Toplam değişim sayısı yerel bir eşik değeri ile karşılaştırılarak elenecek ve saklanacak bantlara karar verilmektedir. Bu nedenle her bir hiperspektral banttaki toplam değişim sayısı hesapladıktan sonra, yerel eşik değerlerinin hesaplanması gerekmektedir. Yerel eşik değeri her bant için, 6 komşu bandın ve kendisinin değişim sayılarının ortalamasına göre hesaplanmaktadır. Ortalamaya katılacak komşu bant sayısı deneysel olarak seçilmiştir. Yerel eşik değeri (4.5) kullanılarak elde edilmiştir.


$$t(l) = \frac{1}{7} \sum_{n=-3}^3 A(l+n) \quad (4.5)$$

Bir bandın $A(l)$ değeri, elde edilen yerel eşik değerinden küçük ise o bant iyi yapılandırılmış bir hiperspektral bant olarak kabul edilmektedir; diğer durumdaki bantlar ise elenmektedir. Bu yaklaşım (4.6)'da gösterilmektedir.

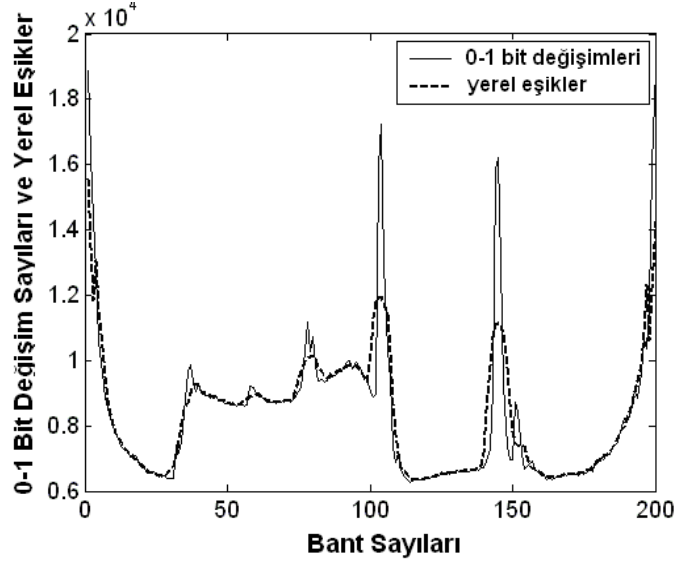
$$S(l) = \begin{cases} 1, & \text{eğer } A(l) < t'(l) \\ 0, & \text{aksi halde} \end{cases} \quad (4.6)$$

Burada $t'(l)$ karar için kullanılan eşik değerini ve $S(l)$ ise "1" değerini alıyorsa l hiperspektral bandın iyi yapılandırılmış olduğunu göstermektedir. İstenilen sayıda iyi yapılandırılmış bant seçebilmek amacıyla ψ eşik ağırlıklandırma faktörü kullanılmakta ve karar eşik değeri $t'(l) = \psi \times t(l)$ olarak belirlenmektedir. Bu

nedenle ψ 'nin yüksek değerde seçilmesi birçok bandın iyi yapılandırılmış olarak değerlendirilmesine sebep olmaktadır ve algoritmanın bir sonraki aşamasında daha yüksek hesapsal yük getirmektedir. ψ 'nin düşük değerde seçilmesi ise daha çok bandın atılmasını sağladığı için bir sonraki aşamada hesapsal yükü azaltmakta ama bir sonraki aşamaya daha az bilginin gösterilmesine yol açmaktadır. Karar eşik değerini belirlemek için kullanılan ψ parametresi deneysel olarak iki durum arasında bir denge sağlayacak şekilde seçilmiştir. Şekil 4.7 ve 4.8'de Indian Pine görüntüsüne sırasıyla 1-BD [43] ve çarpmasız 1-BD [44] dönüşümü uygulayarak elde edilen toplam 0-1 bit değişim sayıları ve yerel eşik değerleri bant sayısına bağlı olarak gösterilmektedir. Bu şekillerde 0-1 bit değişim sayısı yerel eşik değerinden yüksek olan hiperspektral bant indisleri iyi yapılandırılmamış yani elenecek bantların indislerini göstermektedir aksi durumda ise yani 0-1 bit değişim sayısının yerel eşik değerinden küçük olduğu bant indisleri ise iyi yapılandırılmış bantların indislerini göstermektedir.



Şekil 4.7: Indian Pine görüntüsüne 1-BD dönüşümü uygulayarak elde edilen toplam 0-1 bit değişim sayıları ve yerel eşik değerleri



Şekil 4.8: Indian Pine görüntüsüne çarpmasız 1-BD dönüşümü uygulayarak elde edilen toplam 0-1 bit değişim sayıları ve yerel eşik değerleri

4.3.2. En hızlı tırmanış (EHT) bant seçimi algoritması

EHT bant seçimi algoritması hiperspektral görüntülerde öznitelik seçimi amacı ile [41]'de önerilmiştir. EHT bant azaltımı yöntemi bir özyineli alt-küme seçme yöntemidir. EHT bant azaltımı yönteminin amacı, $V = \{v_1, v_2, \dots, v_d\}$ olmak üzere d bantlı V verisinden, belirli bir J en uygun şekle sokma ölçütünü kullanarak $S = \{s_1, s_2, \dots, s_m : s_i \in V; i = 1, \dots, m\}$ şeklinde m bantlı ($m < d$) S alt kümesi elde ederek bant sayısını azaltmaktır. Burada J , S alt kümesindeki özniteliklere bağlı bir değer hesaplamaktadır ($J = J(S)$) ve iki küme arasındaki farkı barındıran tamamlayıcı veri kümesi D , $d - m$ elemanlı olmaktadır ($D = \{s_i : s_i \in V, s_i \notin S, i = 1 : (d - m)\}$). EHT yönteminde başlangıç olarak V verisinden rasgele bir öznitelik alt kümesi S_0 seçilmektedir ve $J(S_0)$ değeri hesaplanmaktadır. Bu alt-kümeden başlanarak özyineli olarak en yüksek J değeri bulunmaya çalışılmaktadır. Algoritmanın i . özyinelemesinde, bir öznitelik (bant) S_{i-1} 'e ve diğer bir öznitelik D_{i-1} 'e ait olmak üzere tüm olası değiş tokuşlar yapılmakta ve bütün olası değişimler için ilişkili J değerleri hesaplanmaktadır. Yani S_{i-1} 'e ait olan bir öznitelik (bant) D_{i-1} 'e ait olacak ve D_{i-1} 'e ait olan bir öznitelik S_{i-1} 'e ait olacak şekilde değiş tokuş yapılmakta ve ilişkili J değeri hesaplanmaktadır.

Eğer en büyük değer, $J_{enbüyük}$ olarak elde edilmiş ve $J_{enbüyük} > J_{enbüyük}(S_{i-1})$ ise, $J_{enbüyük}(S_i)$ değerini elde ettiğimiz öznitelik değişimi kabul edilmektedir ve S_i ve ilişkili tamamlayıcısı D_i güncellenmektedir. Eğer $J_{enbüyük} \leq J_{enbüyük}(S_{i-1})$ ise, yerel minimuma ulaşılmıştır ve algoritma sonlandırılmaktadır. Bu durumda S_i öznitelik kümesi en son öznitelik kümesi olarak alınmaktadır ve işlem sonlandırılmaktadır.

[41]'de önerilen çalışmada J en uygun şekle sokma ölçütü olarak Jeffries-Matusita (JM) uzaklığı [69-71] kullanılmıştır. JM uzaklığı çok sınıflı problemlerde öznitelik seçimi için sınıflar arası uzaklığın hesaplanmasında uzaktan algılama alanında yaygın olarak kullanılmaktadır. Denklem (4.7) ile JM uzaklığı formüle edilmiştir [69-71].

$$JM = 2 \sum_{h=1}^n \sum_{k>h}^n P_h P_k JM_{hk}$$

$$JM_{hk} = \sqrt{2(1 - e^{-b_{hk}})}$$

$$b_{hk} = \frac{1}{8} (M_h - M_k)^T \left(\frac{C_h + C_k}{2} \right)^{-1} (M_h - M_k) + \frac{1}{2} \ln \left(\frac{1}{2} \frac{|C_h + C_k|}{\sqrt{|C_h| |C_k|}} \right)$$
(4.7)

Burada n toplam sınıf sayısını, P_i i . sınıfın önsel olasılığını, b_{hk} h ve k sınıfları arasındaki Bhattacharyya uzaklığını, M_i i . sınıfın ortalamasını ve C_i i . sınıfın $d \times d$ boyutlarında ortak değişinti (covariance) matrisini, T devrik (transpose) işlemini göstermektedir. Burada Bhattacharyya uzaklığının hesapsal yükünü azaltmak amacı ile her bir sınıfın Gauss dağılımına sahip olduğu varsayılmıştır. Sınıflar arası uzaklık hesaplanırken her bir sınıfın diğer tüm sınıflara olan uzaklığı hesaplanmıştır. Örneğin h . sınıfın diğer tüm sınıflara uzaklığı hesaplanırken diğer tüm sınıflar tek bir sınıfa aitmiş gibi düşünülmektedir.

EHT algoritmasında başlangıç alt kümesini seçmek önemlidir ve bu nedenle farklı başlangıç noktaları için algoritma birden fazla kere çalıştırılarak sonuçlar elde edilmelidir. EHT bant azaltımı yöntemi hesapsal maliyeti yüksek olan öz yineli arama ve her olası öznitelik vektörü için JM uzaklığı hesabı gerektirmektedir [41]. J

değerini hesaplamak için gerekli olan hesapsal yük denklem (4.8) ile gösterilmektedir.

$$\text{hesapsal yük} = p \times m \times (d - m) \quad (4.8)$$

Burada p toplam özyineleme sayısını göstermektedir. Bu nedenle EHT bant azaltımı yöntemine uygulanan başlangıç öznitelik (bant) sayısı d hesapsal yükü doğrudan etkilemektedir. Dolayısıyla önerilen 1-BD temelli yaklaşımla EHT uygulanacak başlangıç öznitelik vektör sayısını azaltmak toplam işlemleri hızlandıracaktır.

4.3.3. Deneysel sonuçlar

Deneysel sonuçlar Indian Pine ve DC Mall hiperspektral görüntüleri kullanılarak elde edilmiştir. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma yöntemi kullanılmıştır. Deneysel sonuçlarda, DVM ceza parametresi C [40-1000] arasında ve RTF gamma parametresi [0.1-3] arasında değerler alacak şekilde 5 katlı çarpaz geçerlilik kullanılarak belirlenmiştir ve en uygun ceza parametresi $C=1000$ ve en uygun RTF çekirdeği parametresi $\{\gamma = 2\}$ olarak bulunmuştur. Bu değerler deneysel olarak en yüksek sınıflandırma başarımı elde edilecek şekilde belirlemiştir. EHT bant azaltımı yöntemi için JM uzaklığı [69-71] kullanılmıştır.

Hiperspektral görüntülere orijinal EHT ve 1-BD temelli ön-işlem sonrası EHT uygulanarak bant azaltımı yapıldıktan sonra verilerin sınıflandırılması ile elde edilen sınıflandırma başarımları (SB) ve bant azaltımının hesapsal zamanı (T), Indian Pine görüntüsü için Tablo 4.1 ve Tablo 4.2’de, DC Mall görüntüsü için ise Tablo 4.3’de gösterilmektedir. Hesaplanma süreleri saniye cinsinden işlemcinin piksel başına harcadığı süre olarak verilmiştir. Indian Pine görüntüsü için 1-BD [43]’de ve [44]’de önerilen çekirdekler kullanılarak elde edilmiştir. DC Mall için ise sadece [44]’de önerilen çekirdek kullanılarak 1-BD elde edilmiştir. Tablolarda [43]’de önerilen 1-BD temelli ön-işlem sonrası EHT yöntemi 1-BD-EHT olarak, [44]’de önerilen çarpmasız 1-BD temelli ön-işlem sonrası EHT yöntemi ise ÇS1-BD-EHT olarak gösterilmektedir.

Tablo 4.1’de verilen sonuçlarda 1-BD dönüşümü ile 200 bant içeren Indian Pine görüntüsünün bant sayısı 125 banda düşürülmektedir ve 125 bant üzerinden EHT bant azaltımı yöntemi uygulanmaktadır. Deneysel sonuçlar, 1-BD-EHT ve ÇS1-BD-EHT yöntemlerinin çok benzer sonuçlar verdiğini göstermektedir. 1-BD-EHT ve ÇS1-BD-EHT sonuçları orijinal EHT ile karşılaştırıldığında ise düşük hesapsal yük ile birlikte yakın veya bazı durumlarda daha iyi sınıflandırma başarımı verdiğini göstermektedir. Tablo 4.2’de ise orijinal EHT ve ön-işlem ile 90 banda düşürüldükten sonra EHT uygulanan sonuçlar Indian Pine verisi için gösterilmektedir. Burada da 1-BD-EHT ve ÇS1-BD-EHT, orijinal EHT ile karşılaştırıldığında, düşük hesapsal yükün yanı sıra yakın veya daha iyi sınıflandırma başarımı vermektedir. Bunun nedeni önerilen 1-BD temelli yöntemle görenen iyi yapılandırılmamış bantların zaten standart EHT yöntemi ile de elenecek olmasıdır. Bu nedenle 1-BD temelli bant eleme yöntemi kullanılarak standart EHT yönteminin işlem süresi sınıflandırma başarımından ciddi bir ödün vermeden azaltılmaktadır.

Tablo 4.3’de verilen sonuçlarda çarpmasız 1-BD dönüşümü ile 191 bant içeren DC Mall görüntüsünün bant sayısı 125 banda düşürülmektedir ve 125 bant üzerinden EHT bant azaltımı yöntemi uygulanmaktadır. Burada da deneysel sonuçlar ÇS1-BD-EHT yönteminin, orijinal EHT ile karşılaştırıldığında, düşük hesapsal yükün yanı sıra yakın veya daha iyi sınıflandırma başarımı verdiğini göstermektedir.

Tablo 4.1: Indian Pine verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant), 1-BD temelli bant eleme yöntemi sonrası EHT (1-BD-EHT) (125 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (125 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)

BS	EHT		1-BD-EHT		ÇS1-BD-EHT	
	SB	T	SB	T	SB	T
40	91.32	6.73	91.32	2.92	91.28	3.58
35	91.84	5.22	90.62	2.38	91.28	2.78
30	90.30	3.32	90.14	1.23	90.60	2.21
25	89.60	1.38	89.55	1.15	89.71	1.03
20	89.69	0.81	88.86	0.60	88.68	0.47
15	86.41	0.33	88.07	0.13	87.99	0.24
10	86.39	0.12	87.90	0.06	86.70	0.10

Tablo 4.2: Indian Pine verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant), 1-BD temelli bant eleme yöntemi sonrası EHT (1-BD-EHT) (90 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (90 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)

BS	EHT		1-BD-EHT		ÇS1-BD-EHT	
	SB	T	SB	T	SB	T
40	91.32	6.73	91.30	0.83	91.25	1.60
35	91.84	5.22	90.75	1.25	90.80	1.10
30	90.30	3.33	90.40	1.13	90.64	0.81
25	89.60	1.41	89.64	0.60	89.95	0.53
20	89.69	0.81	89.16	0.38	89.01	0.32
15	86.41	0.33	87.90	0.18	88.07	0.19
10	86.39	0.12	86.48	0.04	86.61	0.07

Tablo 4.3: DC Mall verisi: En hızlı tırmanış bant azaltımı (EHT) (200 bant) ve çarpmasız 1-BD bant eleme yöntemi sonrası EHT (ÇS1-BD-EHT) (90 bant) uygulanması sonrası elde edilen DVM sınıflandırma başarımları (SB) ve hesaplama süreleri (T)

BS	EHT		ÇS1-BD-EHT	
	SB	T	SB	T
40	97.27	5.13	97.38	1.07
35	97.23	3.68	97.44	0.84
30	96.78	2.59	97.46	0.41
25	97.59	1.24	97.66	0.38
20	97.66	0.59	97.57	0.26
15	95.32	0.42	96.60	0.20
10	95.94	0.09	96.80	0.06

Ayrıca bu bölümde komşu bantlar arası D-VEYA temelli ayrışım ölçütünün bant eleme yaklaşımında kullanılarak sınıflandırma başarımına etkisi incelenmiştir. İlk olarak, her bant için 1-BD elde edilmektedir ve 1-BD uygulanmış her bandın kendisinden bir önceki ve bir sonraki bant ile D-VEYA işlemi sonucu hesaplanmaktadır. Bu şekilde elde edilen her iki veri için satır ve sütundaki değişimlerin sayılarının toplamı ilgili bandın ayrışım ölçütü olarak alınmaktadır. Bu yaklaşımın performansını 1-BD-EHT ile karşılaştırabilmek amacı ile gerçekleştirilen yöntem standart EHT bant azaltımı yöntemine ön-işlem olarak kullanılmıştır ve sonrasında son kalan bantlar kullanılarak hiperspektral görüntü DVM ile sınıflandırılmıştır. Deneysel sonuçlar Indian Pine verisi için Tablo 4.4'de verilmektedir ve gerçekleştirilen bu yöntem 1-BD-EHT-2 olarak gösterilmektedir. Deneysel sonuçlar 1-BD-EHT-2 yönteminin, 1-BD-EHT ile karşılaştırıldığında sınıflandırma başarımını düşürdüğünü ve bu nedenle her bir bandın yapısallık ölçütü

olarak sadece o bandın satır ve sütündeki 0-1 deęişimlerinin hesaplanmasının daha iyi bir ölçüt olduğunu göstermiştir. Bir bandın ayrışım ölçütünün sadece o banda göre belirlenmesi yerine bir önceki ve bir sonraki bantlarında hesaba katılması başarıyı düşürmektedir.

Tablo 4.4: Farklı bant sayılarında (BS), 1-BD sonrası en hızlı tırmanış bant azaltımı (1-BD-EHT) (125 bant) ve ayrışım ölçütü hesabında her bandın kendisinden bir önceki ve bir sonraki bant ile D-VEYA işlemi sonucu elde edilen her iki veri için satır ve sütündeki deęişimlerin sayılarının toplamını kullanan 1-BD-EHT yöntemi (1-BD-EHT-2) (125 bant) için elde edilen sınıflandırma başarımları (SB)

BS	1-BD-EHT	1-BD-EHT-2
	SB	SB
40	91.32	90.97
35	90.62	90.64
30	90.14	89.75
25	89.55	88.64
20	88.86	88.57
15	88.07	87.55
10	87.90	85.11

Özetle, bu bölümde 1-BD başarıyla hiperspektral görüntü bantlarına uygulanarak bant azaltımı için düşük hesapsal karmaşıklıęa sahip özgün bir ön-işlem gerçekleştirilmiştir. Bu ön-işlem sayesinde sınıflandırma başarımlarından ciddi bir ödün verilmeden bant azaltımı süresinin önemli oranlarda azaltılabileceęi gösterilmiştir.

4.4. Bir-Bit Dönüşümü Temelli Renkli Görüntüleme

Bu alt bölümde hiperspektral görüntülerin renkli görüntülenmesi amacı ile 1-BD temelli bir yöntem önerilmektedir. Hiperspektral görüntülerin renkli görüntülenmesi görüntünün yorumlanması için önemlidir. Hiperspektral görüntülerin renkli görüntülenmesi için temel olarak iki farklı yaklaşım kullanılmaktadır. İlk yaklaşımda çeşitli sınıflandırma ve topaklama yöntemleri kullanılarak her bir sınıf veya kümenin farklı renkle gösterilmesi amaçlanmaktadır. Etkili sınıflandırma ve topaklama işlemleri yüksek hesapsal karmaşıklıęa sahiptir ve ayrıca her bir sınıf veya kümenin farklı renkte görüntülenmesi sonucu sahne içerisindeki doğal görünüm kaybolmaktadır. İkinci yaklaşımda ise kırmızı-yeşil-mavi (KYM) bileşenleri olarak üç bant seçilerek renkli görüntülenme sağlanmaktadır. Bu üç bant hiperspektral

görüntüye öznitelik seçme ve öznitelik çıkarımı yöntemleri uygulanarak elde edilebilir. Bu yaklaşım ile d -boyutlu verinin üç bant ile temsil edilmesi nedeniyle bilgi kaybı olabilmektedir. Bilgi kaybını en aza indirecek üç uygun bandın seçimi üzerine çalışmalar devam etmektedir. Hiperspektral görüntülerin renkli görüntülenmesi üzerine [72-75, 104-106]'de çalışılmıştır. TBA temelli görüntüleme yaklaşımı [72]'de önerilmiştir. [72]'de önerilen çalışmada TBA sonucu oluşan ilk üç bant KYM bileşenler olarak alınmakta ve hiperspektral görüntünün renkli görüntülenmesinde kullanılmaktadır. Bağımsız bileşenler analizi temelli görüntüleme yöntemi [73]'de önerilmiştir. Topaklanmış bağımsız bileşenler analizinin hiperspektral görüntülerin renkli görüntülenmesinde kullanılması üzerine ise [74]'de çalışılmıştır. Bu çalışmada hangi bağımsız bileşenin renklendirme kullanılacağı karşılıklı bilgi miktarı (mutual information) ve ilinti katsayısı kullanılarak karar verilmiştir. [75]'de doğrusal spektral ağırlıklandırma zarfı kullanan görüntüleme yöntemi önerilmiştir. Başarım değerlendirmesi için nicel ölçüm yöntemleri olarak entropi ve ilinti katsayısının kullanılması [104]'de önerilmiştir. Spektral uzaklıkları koruyan dışbükey en iyileme (convex optimization) temelli görüntüleme yöntemi [105]'de önerilmiştir. [106]'da iki yanlı süzgeçleme (bilateral filtering) kullanılarak hiperspektral görüntülerin renkli görüntülenmesi sağlanmıştır. [106]'da önerilen yöntemin başarımı değişim (variance) ve entropi kullanılarak gösterilmiştir. Elde edilen tek bantlık renkli görüntüde en iyi karşıtlık için değişiminin yüksek olması ve yüksek bilgi miktarı içinde entropinin yüksek olması gerekmektedir. Literatürde önerilen renkli görüntüleme yöntemlerinin aksine bu tez çalışması kapsamında düşük hesapsal yüke sahip ve donanım gerçekleştirilmesi için uygun 1-BD temelli renkli görüntüleme yöntemi geliştirilmiştir.

4.4.1. Önerilen yöntem

Bu bölümde hiperspektral görüntülerin 1-BD temelli renkli görüntülenmesi üzerine çalışmalar yapılmıştır. Renkli görüntüleme için gerekli olan üç bandın seçimi iki aşama sonucu gerçekleştirilmektedir. İlk aşamada hiperspektral verilerin 1-BD'lerine göre bant eleme ve seçme işlemi yapılmaktadır (birinci aşama Bölüm 4.3'de anlatılan yaklaşım kullanılarak gerçekleştirilmektedir), ikinci aşamada ise kalan bantlar

arasından birbirine en az benzeyen 3 bant seçilmektedir. Gerçekleştirilen yaklaşım düşük hesapsal karmaşıklığa sahiptir ve donanım gerçekleştirilmesi için uygundur.

Hiperspektral verilerin KYM renkli gösterimi için gerekli olan nihai üç bant, bir önceki aşamada elde edilen (detaylı bilgi Bölüm 4.3'de anlatılmaktadır) iyi yapılandırılmış bantlar arasından seçilmektedir. İyi yapılandırılmış bantlar arasında birbirine en az benzeyen üç bant seçilerek kırmızı, yeşil ve mavi renk bileşenleri için kullanılacak bantlar elde edilmekte ve renkli görüntü oluşturulmaktadır. Birbirine en az benzeyen üç bandın seçimi için ikili ilinti ölçümü kullanılmaktadır. Bu amaçla iyi yapılandırılmış bantlar arasında D-VEYA sonuçlarının toplam değerleri hesaplanmaktadır. D-VEYA sonucunun en yüksek olduğu iki bant birbirine en az benzeyen iki banttır ve renkli görüntüleme için kullanılmaktadır. Üçüncü bant ise seçilmiş olan bu iki banda en az benzeyen bant olarak alınmakta ve kalan bantlardan seçilen iki bant ile D-VEYA sonuçlarının toplamı en büyük sonucunu veren bant olarak alınmaktadır.

4.4.2. Deneysel sonuçlar


Deneysel sonuçlar Cuprite ve Indian Pine görüntüleri kullanılarak elde edilmiştir. Gerçekleştirilen çalışmanın ilk aşamasından sonra Indian Pine verisi için 25 bant, Cuprite verisi için ise 15 bant kalmıştır (ψ eşik ağırlıklandırma sabiti 0.95 olarak kullanılmıştır). İkinci aşamada ise birinci aşamada seçilen bantlardan birbirine en az benzeyen üç bant seçilerek renkli görüntüleme için kullanılmıştır. İlk bant seçimi ve ikinci bant seçimi sonucu seçilen bant indisleri Indian Pine verisi ve Cuprite verisi için Tablo 4.5'de verilmiştir. Elde edilen üç bandı rasgele kırmızı, yeşil ve mavi bileşenleri temsil eden bantlar olarak atamak yerine standart sapma değeri en yüksek olan bant kırmızı bant, ikinci en yüksek standart sapmaya sahip olan bant yeşil bant ve standart sapma değeri en düşük olan bant ise mavi bant olarak alınmıştır. Şekil 4.9'da seçilen üç bant, bu üç bandın 1-BD sonuçları ve Indian Pine verinin bu üç bant kullanılarak elde edilen renkli görüntüsü gösterilmektedir. Indian Pine verisi için Şekil 4.9 (a) kırmızı, Şekil 4.9(b) yeşil, Şekil 4.9(c) mavi bileşenler olarak kullanılan bantları göstermektedir. Şekil 4.10'da ise Cuprite verisi için seçilen üç bant ve bu üç bant kullanılarak elde edilen renkli görüntüsü gösterilmektedir. Cuprite

verisi için Şekil 4.10(a) kırmızı, Şekil 4.10(b) yeşil, Şekil 4.11(c) mavi bileşenler olarak kullanılan bantları göstermektedir.


TBA [72] sonuçları karşılaştırma yapmak amacı ile verilmiştir. TBA ile elde edilen üç bant standart sapma değerlerine göre kırmızı, yeşil, mavi bantlara atanmaktadır ve renkli görüntü oluşturulmaktadır. Şekil 4.11’de gerçekleştirilen yöntem ve TBA ile elde edilen renkli görüntüleme sonuçları Indian Pine ve Cuprite verileri için gösterilmektedir. Cuprite verisinin yüksek piksel boyutundan dolayı TBA sonuçları tüm veri için elde edilmemiş olup, karşılaştırma sonuçları Cuprite verisinin küçük bir bölümü için elde edilmiştir. Önerilen yaklaşım ile daha düşük hesapsal karmaşıklık sağlanmakta ve neredeyse aynı ayrıntılar gösterilmektedir. [73]’de KYM bileşenleri arasındaki ilinti değerinin hiperspektral renkli görüntüleme bir ölçüt olabileceği gösterilmiştir, çünkü doğal renkli görüntülerin KYM bileşenleri arasındaki ilinti değeri yüksek olmaktadır [73]. Tablo 4.7 ve Tablo 4.8 gerçekleştirilen çalışma ve TBA ile elde edilen KYM bileşenleri arasındaki ilinti sonuçlarını Indian Pine verisi için göstermektedir. Tablo 4.9 ve Tablo 4.10 ise gerçekleştirilen çalışma ve TBA ile elde edilen KYM bileşenleri arasındaki ilinti sonuçlarını Cuprite verisi için göstermektedir. Bu sonuçlar gerçekleştirilen çalışmanın KYM bileşenleri arasında daha yüksek ilinti sonuçları verdiğini ve bu nedenle önerilen yöntemin TBA temelli renkli görüntüleme yöntemine göre daha başarılı olduğunu göstermektedir.

Tablo 4.5: İlk bant seçimi (İBS) ve İkinci Bant Seçimi (KBS) sonucu seçilen bant indisleri


Veri Kümesi	İBS	KBS
Indian Pine	5, 6, 7, 31, 33, 34, 75, 76, 100, 101, 102, 111, 112, 113, 114, 145, 146, 147, 148, 166, 167, 168, 169, 173, 216	5,75,169
Cuprite	104, 105, 106, 116, 117, 150, 151, 152, 170, 171, 172, 176, 177, 213, 216	116,152, 216




Şekil 4.9: Indian Pine verisi: (a) 5. bant, (b) 75. bant, (c) 169. bant, (d) 5. bandın 1-BD, (e) 75. bandın 1-BD, (f) 169. bandın 1-BD, (g) renkli görüntüsü




(a)



(b)




(c)



(d)

Şekil 4.10: Cuprite verisi: (a) 216. bant, (b) 152. bant, (c) 116. bant,(d) renkli görüntüsü



Şekil 4.11: (a) Indian Pine verisi TBA renkli görüntüleme sonuçları (b) Indian Pine verisi 1-BD temelli renkli görüntüleme sonuçları, (c) Cuprite verisi TBA renkli görüntüleme sonuçları (d) Cuprite verisi 1-BD temelli renkli görüntüleme sonuçları

Tablo 4.6: Indian Pine verisinde 1-BD temelli yöntem ile elde edilen KYM bileşenleri arasında ilinti katsayıları

1-BD temelli yöntem	K	Y	M
K	1	-0.4877	0.9070
Y	-0.4877	1	0.5193
M	0.9070	0.5193	1

Tablo 4.7: Indian Pine verisinde TBA ile elde edilen KYM bileşenleri arasında ilinti katsayıları

TBA	K	Y	M
K	1	0.0820	0.0740
Y	0.0820	1	8.2694e-004
M	0.0740	8.2694e-004	1

Tablo 4.8: Cuprite verisinde 1-BD temelli yöntem ile elde edilen KYM bileşenleri arasında ilinti katsayıları

1-BD temelli yöntem	K	Y	M
K	1	0.8360	0.8211
Y	0.8360	1	0.9809
M	0.8211	0.9809	1

Tablo 4.9: Cuprite verisinde TBA ile elde edilen KYM bileşenleri arasında ilinti katsayıları

TBA	K	Y	M
K	1	0.0127	0.0230
Y	0.0127	1	0.0127
M	0.0230	0.0127	1

4.5. Vargılar

Bu bölümde ele alınan çalışmalarda 1-BD hiperspektral verilere uygulanarak az ayrılabilen iyi yapılandırılmamış bantların düşük maliyetli ve donanımsal olarak gerçekleştirilmesi uygun 1-BD temelli bir yaklaşım kullanılarak elenmesi sağlanmıştır. Bu tez kapsamında geliştirilen 1-BD temelli yöntemlerin FPGA ile gerçekleştirilmesi üzerine [114]'de çalışılmıştır. Önerilen 1-BD temelli bant eleme yöntemi ile hiperspektral verilerde standart bant azaltımı yöntemlerinin hesapsal karmaşıklığının azaltılması sağlanmıştır. Literatürde yaygın olarak kullanılan hesapsal yükü oldukça fazla olan, fakat çok iyi bir başarımla sağlayan en hızlı tırmanış (EHT) bant azaltımı yönteminin hesapsal süresinin DVM sınıflandırma başarımlarından ciddi bir ödün verilmeden 1-BD temelli bir ön-işlem sayesinde önemli oranlarda azaltılabileceği gösterilmiştir. Ayrıca hiperspektral görüntülerin renkli görüntülenmesi üzerine özgün, düşük hesapsal maliyetli ve donanımsal olarak gerçekleştirilebilir 1-BD temelli özgün bir yöntem geliştirilmiştir. Geliştirilen 1-BD temelli yöntemlerin FPGA ile gerçekleştirilmesi ile ilgili detaylı bilgi [114]'de bulunmaktadır.

5. YÜKSEK DOĞRULUKTA DVM SINIFLANDIRMA İÇİN SINIR EĞİTİM ÖRNEKLERİNİN TOPAKLAMA TEMELLİ ÇIKARIMI

5.1. GÜDÜLENME

Eğitim verisinin kalitesi DVM sınıflandırma başarımını doğrudan etkilemektedir. Literatürde bulunan çalışmalarda eğitim verisi olarak tüm eğitim verisi kullanılması yerine sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın sınır eğitim örneklerinin kullanılarak yüksek sınıflandırma başarımları elde edilebileceği gösterilmiştir [76-78]. [76]'da sınıfları birbirinden ayıran ayırtaç düzlemine yakın karma (mixed) spektral verilerin (yani sınıfların sınırlarında bulunan verilerin) DVM eğitim aşamasında kullanılması önerilmiştir ve elde edilen sınıflandırma sonuçları tüm eğitim verisi kullanılması sonucunda elde edilen başarıma çok benzerdir [76]. Sınır eğitim örneklerinin yapay sınır ağları ile sınıflandırmadaki başarısı [77] ve [78]'de incelenerek ayırtaç düzlemine yakın olan sınır eğitim örnekleri kullanılarak sınıflandırma başarımının tüm eğitim verisini kullanma durumuna göre arttırılabileceği gösterilmiştir. [76-78]'de önerilen çalışmalarda sınır eğitim örnekleri görüntü yorumlama tekniği ile bulunmuştur ve sınır eğitim örneklerin otomatik yöntemlerle nasıl bulunacağı devam eden bir araştırma konusudur.

Bu tez kapsamında önerilen çalışmada DVM sınıflandırma için toplama yaklaşımı temelli sınır eğitim örnekleri tespiti önerilmektedir. Sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın olan sınır eğitim örnekleri toplama yaklaşımıyla bulunmaktadır. Sınır eğitim örnekleri iki aşamada elde edilmektedir. İlk aşamada, eğitim verisindeki her bir sınıfa toplama işlemi uygulanarak küme ortalamaları elde edilmektedir ve bu küme ortalamaları DVM eğitim işlemi için başlangıç eğitim verisi olarak alınmaktadır. Bu sayede, veri miktarı azaltılmış hiperspektral eğitim kümesi elde edilmektedir. İkinci aşamada ise küme ortalamalarını içeren bu veri DVM ile eğitilmektedir. Destek vektörü olarak bulunan küme ortalamaları ayırtaç düzlemine yakın olmaktadır ve bu nedenle önerilen yaklaşımda destek vektörü olan

küme ortalamalarının ait olduğu kümelere dahil olan orijinal eğitim verileri, ilgili küme ortalamaları ile birlikte sınır eğitim örnekleri olarak alınmaktadır. Elde edilen sınır eğitim örnekleri en son DVM eğitim aşamasında kullanılmaktadır ve bu aşamada elde edilen destek vektörleri asıl sınıflandırıcıyı tanımlamaktadır.

5.2. Sınır Eğitim Örneklerinin Seçimi

Sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın olan sınır eğitim örneklerinin toplama aşaması ve destek vektörlerinin belirlenmesi aşaması olmak üzere iki aşamada elde edilmektedir.

5.2.1. K -ortalama toplama yöntemi

Bu aşamada, her bir sınıfa K -ortalama toplama yöntemi uygulanmaktadır ve toplama işlemi gerçekleştirildikten sonra her topağın ortalama spektral verisi ilgili sınıfı temsil eden öznitelik vektörü olarak belirlenmektedir. Her bir sınıf için oluşturulan topak sayısı bu sınıftaki eğitim verisi sayısı ile ilişkilidir. Düşük sayıda eğitim verisine sahip olan bir sınıf düşük topak sayısına sahip olmaktadır. K -ortalama algoritması veri kümesini, giriş parametresi olarak verilen K adet topağa toplanmaktadır [79]. K -ortalama algoritmasının işlem basamakları şöyledir:

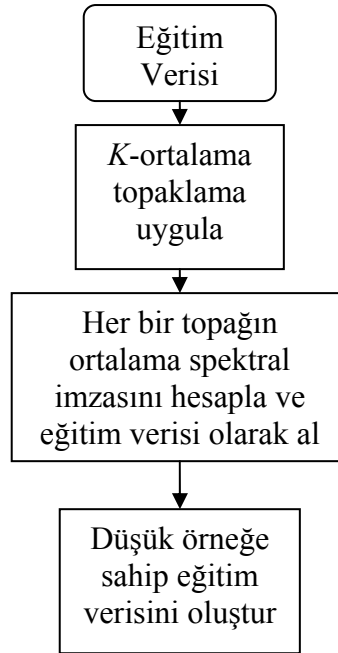
1. İlk topak merkezleri belirlenmektedir.
2. Her verinin seçilen merkez noktalara olan uzaklığı hesaplanmaktadır. Elde edilen sonuçlara göre tüm veriler K adet topaktan kendilerine en yakın olan topağa yerleştirilmektedir.
3. Oluşan topakların yeni merkez noktaları o topaktaki tüm verilerin ortalama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

Bu aşama sayesinde hiperspektral verinin tamamını kullanmak yerine, oluşan topakların ortalamaları ikinci aşamada kullanılarak DVM ile ilk eğitim aşamasında hızlandırma sağlanmaktadır. Yani, tüm topak ortalamalarını içeren eğitim verisi

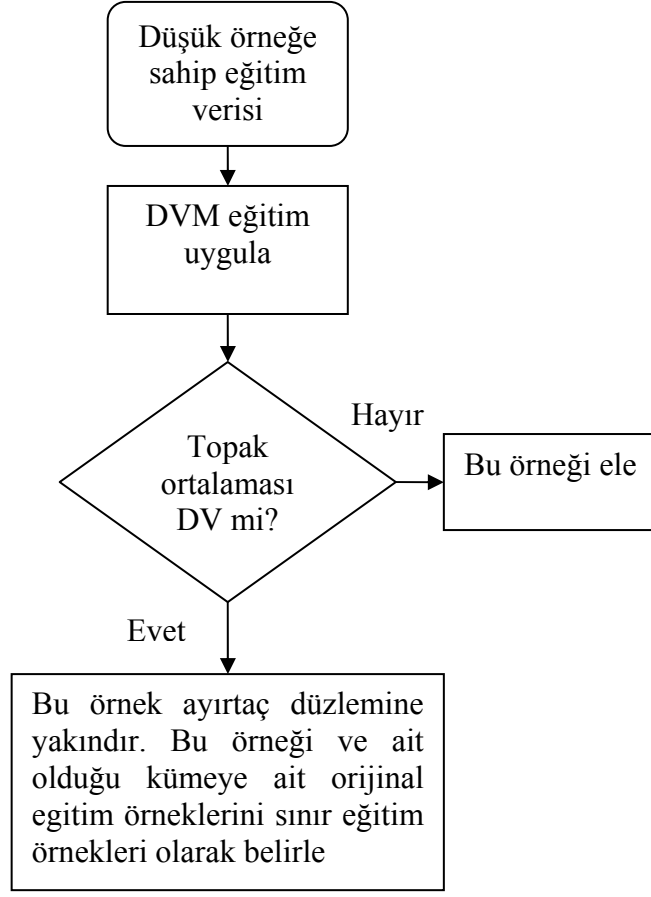
DVM ile eğitilmektedir. Gerçekleştirilen algoritmanın akış şeması Şekil 5.1’de gösterilmektedir.

5.2.2. Destek vektörlerinin belirlenmesi

Destek vektörlerini elde etmek amacı ile birinci aşamada bulunan topak ortalamalarını içeren eğitim verisi ile DVM eğitilmektedir. Bu sayede ayırtaç düzlemine yakın olan topak ortalamaları (yani destek vektörleri) bulunmaktadır. Ayırtaç düzlemine yakın olan topak ortalamaları aynı zamanda ayırtaç düzlemine yakın olan orijinal örnekler hakkında bilgi sağlamaktadır. Destek vektörü olarak bulunan topak ortalamalarının ait oldukları topağa dahil olan tüm orijinal eğitim verileri ve ilişkili topak ortalamaları sınır eğitim örnekleri olarak belirlenmekte ve nihai DVM eğitim aşamasında kullanılmaktadır. Şekil 5.2’de ikinci aşamada gerçekleştirilen algoritmanın akış şeması verilmektedir.



Şekil 5.1: Gerçekleştirilen algoritmanın birinci aşaması



Şekil 5.2: Gerçekleştirilen algoritmanın ikinci aşaması

5.3. Deneysel Sonuçlar

Deneysel sonuçlar Indian Pine ve Botswana hiperspektral görüntüleri kullanılarak elde edilmiştir. Önerilen yaklaşımın sınıflandırma başarımını göstermek amacı ile RTF çekirdeği ile DVM sınıflandırma yöntemi kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma kullanılmıştır. Deneyselerde, DVM ceza parametresi C [10-1000] arasında ve RTF gamma parametresi [0.1-2] arasında değerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir. Deneysel sonuçlar, her bir sınıf için toplam verinin %10, %20 ve %50'si eğitim verisi alınarak elde edilmiştir ve Indian Pine verisi için Tablo 5.1-Tablo 5.3'de, Botswana verisi için Tablo 5.4-Tablo 5.6'da gösterilmektedir.

Gerçekleştirilen yöntem ile sınır eğitim örneklerinin toplama temelli çıkarımı ve DVM eğitim işleminde eğitim verisi olarak kullanılması sağlanmıştır. Önerilen sınır

eđitim rneklerini bulma temelli DVM ile yntemi SE_DVM ile gsterilmektedir. SE_DVM ynteminin ilk ařamasında topak ortalamaları alınarak azaltılmıř eđitim verisi elde edilmektedir. Azaltılmıř eđitim verisi oranları %75 ve %50 olarak belirlenmiřtir. Bu durumda her bir sınıf iin, o sınıfın toplam veri miktarının %75 ve %50'si oranında topak elde edilmektedir ve topak ortalamaları yeni eđitim verisi olarak alınmaktadır. Tablolarda birinci ařama sonucunda elde edilen DVM sınıflandırma bařarımları, kullanılan eđitim verisi sayısının orijinal eđitim verisi sayısına oranı ile birlikte gsterilmektedir. İkinci ařama sonuçları ise sınır eđitim rneklerinin belirlenerek eđitim verisi olarak alınması sonucu oluřan DVM sınıflandırma sonuçlarını gstermektedir. Ayrıca tablolarda ikinci ařama sonucu kullanılan eđitim verisi sayısının orijinal eđitim verisi sayısına oranı da gsterilmektedir.

SE_DVM sonuçları, orijinal eđitim verisinin dođrudan kullanılması sonucu elde edilen DVM sınıflandırma sonuçları ve [80]'de nerilen aktif đrenme temelli DVM sınıflandırma yntemi (A-DVM) ile karřılařtırılmıřtır. A-DVM bařlangı olarak, eđitim verisinden rasgele seilen dřuk miktardaki eđitim verileri kullanılmaktadır. DVM eđitim iřlemi bu verileri kullanarak gerekleřtirilmektedir ve hiperdzlem oluřturulmaktadır. Sonrasında, geri kalan eđitim rneklerinden bu hiperdzleme en yakın eđitim verileri seilmekte, ve hiperdzleme en yakın olan eđitim rnekleri, eđitim verisine dahil edilmektedir. Bu iřlem ařamalı olarak, hiperdzlem ierisinde eđitim verisi kalmayana kadar devam etmektedir. A-DVM iin sonuçlar, eđitim verisine K -ortalama uygulanması sonucu oluřan topak ortalamalarının bařlangı eđitim verisi oluřturulması ve her bir zyinelemede ayırta dzlemine yakın olan 8 znelik vektrnn eđitim kmesine dahil edilmesi durumuna gre elde edilmiřtir. Tablolarda seilen K deđerleri de gsterilmektedir.

Tablolarda, deneysel sonuçlar yzde sınıflandırma bařarımı ve kapa katsayısı (k) kullanılarak verilmiřtir. Eđer $k = 1$ ise %100 sınıflandırma bařarımı elde edilmiřtir. Bu nedenle k deđerinin 1'e yakın olması iyi bir sınıflandırma bařarımı elde edildiđini gstermektedir. Farklı yntemlerin sınıflandırma bařarımları arasındaki farkın istatiksels nemi McNemar testi [66] kullanılarak llmřtir. McNemar testinde 0.05 bařarım seviyesi iin, $|Z| > 1.96$ ise sınıflandırma sonuçları arasındaki fark

istatistiksel olarak önemlidir [66]. Eğer Z 'nin işareti pozitif ise birinci sınıflandırıcı ikinci sınıflandırıcıya göre istatistiksel olarak başarılıdır. Eğer Z 'nin işareti negatif ise ikinci sınıflandırıcı birinci sınıflandırıcıya göre istatistiksel olarak başarılıdır. Burada Z değerleri, ikinci algoritma DVM ve birinci algoritma AÖ-DVM veya SEÖ-DVM kabul edilerek elde edilmiştir. AÖ-DVM ve SEÖ-DVM yöntemlerinde kullanılan K -ortalama algoritması başlangıç topak ortalamalarını rasgele seçmesi nedeni ile sonuçlar 5 kez elde edilmiştir ve tablolarda sınıflandırma başarımlarının, kapa katsayılarının (k) ve Z değerlerinin ortalama ve standart sapma değerleri verilmiştir. Tablo 5.1-Tablo 5.6'da elde edilen sonuçlar, Indian Pine ve Botswana verileri için, SEÖ_DVM yönteminin doğrudan DVM ve AÖ-DVM yöntemlerine göre daha başarılı olduğunu göstermektedir. SEÖ_DVM başarımı doğrudan DVM ile karşılaştırıldığında Indian Pine verisi için %10 ve %20 eğitim verisi oranı kullanılması durumunda %2, %50 eğitim verisi oranı kullanılması durumunda ise %1 artmıştır. Botswana verisi için ise %10 ve %20 eğitim verisi oranı kullanılması durumunda %1, %50 eğitim verisi oranı kullanılması durumunda ise %0.7 artmıştır. Şekil 5.3'de Indian Pine verisine doğrudan DVM, SEÖ-DVM ve AÖ-DVM uygulanması sonucu elde edilen sınıflandırma haritaları gösterilmektedir. Bu sonuçlar toplam verinin %50'nin eğitim verisi olarak alınmasına göre elde edilmiştir. Sınıflandırma haritalarından doğrudan DVM ve AÖ-DVM ile elde edilen bazı yanlış sınıflandırılan örneklerin önerilen SEÖ_DVM ile doğru sınıfa sınıflandırıldığı gözlemlenmektedir.

Tablo 5.1: Indian Pine verisinde toplam verinin %10'unun eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	82.67	-	0.69	-	-	-	
SEÖ-DVM	aşama 1	75	81.42	0.16	0.60	0.03	-	-
	aşama 2	107	84.73	0.33	0.70	0.08	9.34	0.45
SEÖ-DVM	aşama 1	50	80.11	0.31	0.58	0.02	-	-
	aşama 2	97	84.61	0.47	0.66	0.01	8.42	2.05
AÖ-DVM ($K=40$)	87	82.09	0.48	0.64	0.01	-3.89	2.21	

Tablo 5.2: Indian Pine verisinde toplam verinin %20'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	88.97	-	0.77	-	-	-	
SEÖ-DVM	aşama 1	75	87.14	1.37	0.66	0.01	-	-
	aşama 2	96	90.41	0.12	0.75	0.04	6.02	0.85
SEÖ-DVM	aşama 1	50	86.47	0.18	0.64	0.03	-	-
	aşama 2	89	90.55	0.13	0.79	0.01	6.37	0.91
AÖ-DVM ($K=80$)	89	88.41	0.35	0.69	0.01	-3.27	1.48	

Tablo 5.3: Indian Pine verisinde toplam verinin %50'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma(ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	92.59	-	-	-	-	-	
SEÖ-DVM	aşama 1	75	91.46	0.20	0.78	0.01	-	-
	aşama 2	79	93.50	0.09	0.84	0.005	3.83	0.18
SEÖ-DVM	aşama 1	50	90.29	0.11	0.76	0.01	-	-
	aşama 2	72	93.48	0.11	0.86	0.01	3.40	0.30
AÖ-DVM ($K=150$)	72	92.94	0.11	0.83	0.005	1.72	0.55	

Tablo 5.4: Botswana verisinde toplam verinin %10'unun eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, SEÖ-DVM ve AÖ-DVM sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

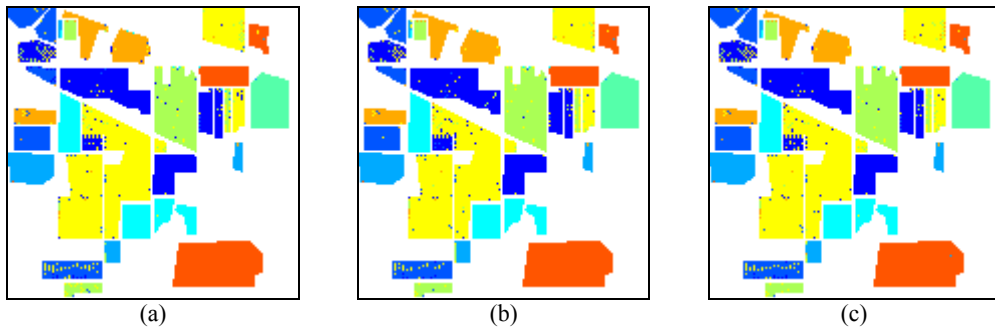
Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	91.37	-	0.86	-	-	-	
SEÖ-DVM	aşama 1	75	91.26	0.36	0.84	0.01	-	-
	aşama 2	100	92.94	0.09	0.86	0	4.59	0.31
SEÖ-SVM	aşama 1	50	90.48	0.70	0.82	0.02	-	-
	aşama 2	97	92.76	0.41	0.85	0.01	3.81	1.09
AÖ-DVM ($K=8$)	97	91.64	0.16	0.87	0.005	1.21	0.75	

Tablo 5.5: Botswana verisinde toplam verinin %20'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss) değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	94.80	-	0.92	-	-	-	
SEÖ-DVM	aşama 1	75	94.70	0.08	0.92	0.01	-	-
	aşama 2	84	95.71	0.27	0.93	0	3.13	1.12
SEÖ-DVM	aşama 1	50	94.15	0.19	0.90	0.01	-	-
	aşama 2	62	95.55	0.22	0.92	0.005	2.54	0.67
AÖ-DVM ($K=17$)	84	94.84	0.16	0.92	0.008	0.08	0.78	

Tablo 5.6: Botswana verisinde toplam verinin %50'sinin eğitim verisi olarak alınması sonucunda elde edilen doğrudan DVM, sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) ve aktif öğrenme temelli DVM (AÖ-DVM) sınıflandırma başarımlarının (SB), kapa katsayılarının (k) ve istatistiksel test sonuçlarının (Z) ortalama (ort) ve standart sapma (ss)değerleri ve kullanılan eğitim verisi sayısının orijinal eğitim verisi sayısına oranı (Oran)

Yöntem	Oran	SB		k		Z		
		ort	ss	ort	ss	ort	ss	
DVM	-	95.18	-	0.93	-	-	-	
SEÖ-DVM	aşama 1	75	95.11	0.12	0.92	0.001	-	-
	aşama 2	58	95.88	0.15	0.94	0.005	2.44	0.61
SEÖ-DVM	aşama 1	50	94.91	0.38	0.92	0.009	-	-
	aşama 2	56	95.84	0.06	0.93	0	1.97	0.21
AÖ-DVM ($K=30$)	58	95.25	0.14	0.93	0	0.45	0.59	



Şekil 5.3: (a) Doğrudan DVM, SB: 92.59 (b) sınır eğitim örneklerinin çıkarımı temelli DVM (SEÖ-DVM) (aşama 2'de oran=%72, SB: 93.48), ve (c) aktif öğrenme temelli DVM (AÖ-DVM) (aşama 2'de oran=%72, SB: 92.94), sonucu oluşan sınıflandırma haritaları

5.4. Vargular

Bu bölümde sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın olan sınır eğitim örneklerinin bulunması amacıyla özgün toplama temelli bir yöntem geliştirilmiştir. Sınır eğitim örneklerinin DVM aşamasında kullanılarak DVM sınıflandırma başarımının arttırılabileceği gösterilmiştir. Geliştirilen yöntem ile sınıflandırma başarımı artmakla beraber eğitim aşamasının iki kere yapılması nedeniyle DVM eğitim aşamasındaki hesaplanma süresi de artmıştır.

6. ÇOK-ÇÖZÜNÜRLÜKLÜ YAPILARLA TÜMLEŞTİRME

6.1. GÜDÜLENME

Hiperspektral görüntülerin sınıflandırma başarımının uzamsal ve spektral bilgiler birlikte kullanılarak artırılabilmesi [24-28]'de gösterilmiştir. Uzamsal ve spektral bilgiler [24]'de birleşik çekirdekler (composite kernels) kullanılarak birleştirilmiştir. [24]'de öncelikle uzamsal ve spektral öznelik vektörleri için çekirdek matrisleri ayrı ayrı hesaplanmaktadır ve sonrasında farklı çekirdek birleştirme yaklaşımları (örneğin çekirdeklerin doğrudan toplanması ve ağırlıklandırma parametresi kullanılarak toplanması) kullanılarak çekirdekler birleştirilmektedir. Biçimbilimsel profiller kullanılarak hiperspektral görüntülerin sınıflandırılması [25] ve [26]'da önerilmiştir. Biçimbilimsel profiller iki aşamada elde edilmektedir: i) TBA hiperspektral görüntülere uygulanarak temel bileşenler elde edilmektedir, ii) temel bileşenlere ardı ardına açma-kapama işlemleri uygulayarak biçimbilimsel profiller elde edilmektedir. [25]'de önerilen çalışmada biçimbilimsel profiller doğrudan yapay sinir ağı sınıflandırmasında kullanılmıştır. [26]'da ise orijinal spektral veriler ve biçimbilimsel profiller birleştirilerek (ardı ardına eklenerek) DVM ile sınıflandırılmıştır. Spektral ve uzamsal bilgilerin Markov Rassal Alanlar (Markov Random Field) temelli birleştirilmesi [27]'de ve havza (watershed) toplama yöntemi temelli birleştirilmesi [28]'de önerilmiştir. Hiperspektral görüntülerde komşu pikseller arasında uzamsal bir ilişki bulunmaktadır ve her bir piksel komşu piksellerinden en az bir tanesi ile aynı sınıftadır. Her bir pikselin komşu piksellerden en az bir tanesi ile aynı sınıfa ait olduğu (aynı sınıf komşuluk özelliği) [81]'de belirtilmiştir. [81]'de öncelikle veri DVM ile sınıflandırılarak her bir test pikseli için başlangıç sınıf etiketi elde edilmektedir ve her bir pikselin sekiz komşu pikseli tanımlanmaktadır. Sonrasında ise ikili karar ağacı temelli sıradüzensel sınıflandırıcı ile ilk aşamada elde edilen sınıflandırma sonuçları aynı sınıf komşuluk özelliği kullanılarak ince ayardan (fine-tuning) geçirilmektedir. Ayrıca her bir pikselin sınıflandırılırken komşu piksellerinin sınıf bilgilerinin de değerlendirilerek uzamsal ve spektral bilgilerin

birlikte kullanılmasını sağlayan olasılıksal gevşeme (probabilistic relaxation) yöntemleri literatürde bulunmaktadır [118]. Bu tez çalışmasında önerilen yöntem olasılıksal çıkışlar kullanmaması ve DVM uyumlu olması nedeniyle bir olasılıksal gevşeme yöntemi sayılmamaktadır.

Bu bölümde uzamsal ve spektral bilgilerin birlikte kullanılması amacıyla dalgacık dönüşümü temelli sıradüzensel bir yöntem önerilmektedir ve [81]'de belirtilen her bir pikselin en az bir komşu pikseli ile aynı sınıfa ait olduğunu ifade eden “aynı sınıf komşuluk özelliği” kullanılmaktadır. Aynı sınıf komşuluk özelliğine göre her bir piksel, komşu piksellerinden en az bir tanesi ile aynı sınıfa dahildir. Önerilen özgün sıradüzensel yöntem ile uzamsal ve spektral bilgilerin birlikte kullanılması değerlendirilmektedir ve ayrıca literatürde önerilen çalışmalardan farklı olarak sıradüzensel bir yapı kullanması nedeniyle sınıflandırma (test) süresinde azalması beklenmektedir. Önerilen yöntem detaylı olarak bir sonraki alt bölümde açıklanmaktadır.

6.2. Önerilen Yöntem

Bu bölümde DVM tabanlı sınıflandırma yönteminin [11] çok-çözünürlüklü yapılarla birleştirilerek hız ve başarımların artırımı elde edilmesi üzerine yapılan çalışmalar ele alınmıştır. Çok-çözünürlüklü yapıları elde etmek için dalgacık dönüşümü kullanılmıştır. Dalgacık dönüşümü sonrası her bir hiperspektral bant alçak frekans, yatay yüksek frekans, dikey yüksek frekans ve çapraz yüksek frekans bileşenlerine ayrılmaktadır [82]. Hiperspektral görüntünün her bir bandına r seviye dalgacık dönüşümü uygulanarak çok-çözünürlüklü bir yapı elde edilmiştir. Her seviyede önce alçak frekans bileşenleri sınıflandırmada kullanılmakta ve sonrasında bu sonuçlar üzerinden yüksek çözünürlüklü bilgiye geçilmekte ve bu sayede çok-çözünürlüklü bir yapı üzerinden sınıflandırma gerçekleştirilmektedir. Gerçekleştirilen algoritma aşağıda verilen adımlarla detaylı olarak açıklanmaktadır.

1. Eğitim aşamasında hiperspektral verinin eğitim verisine DVM eğitim işlemi uygulanmaktadır ve destek vektörleri elde edilmektedir. Dolayısıyla, eğitim aşaması çok-çözünürlüklü yapı kullanılmadan orijinal veri üzerinden gerçekleştirilmekte ve

bu sayede destek vektörlerinin orijinal veriler üzerinden oluşturulabilmesi sağlanmaktadır.

2. Test (sınıflandırma) aşamasında çok-çözünürlüklü yapının oluşturulabilmesi için her bir hiperspektral banda r seviye dalgacık dönüşümü uygulanmaktadır ve her seviyedeki alçak frekans bileşenleri elde edilmektedir. Dalgacık dönüşümü r seviye uygulanacağı için dalgacık dönüşümü uygulamadan önce hiperspektral verinin piksel boyutu, aynalama işlemi kullanılarak 2^r 'nin katına çıkarılmaktadır.

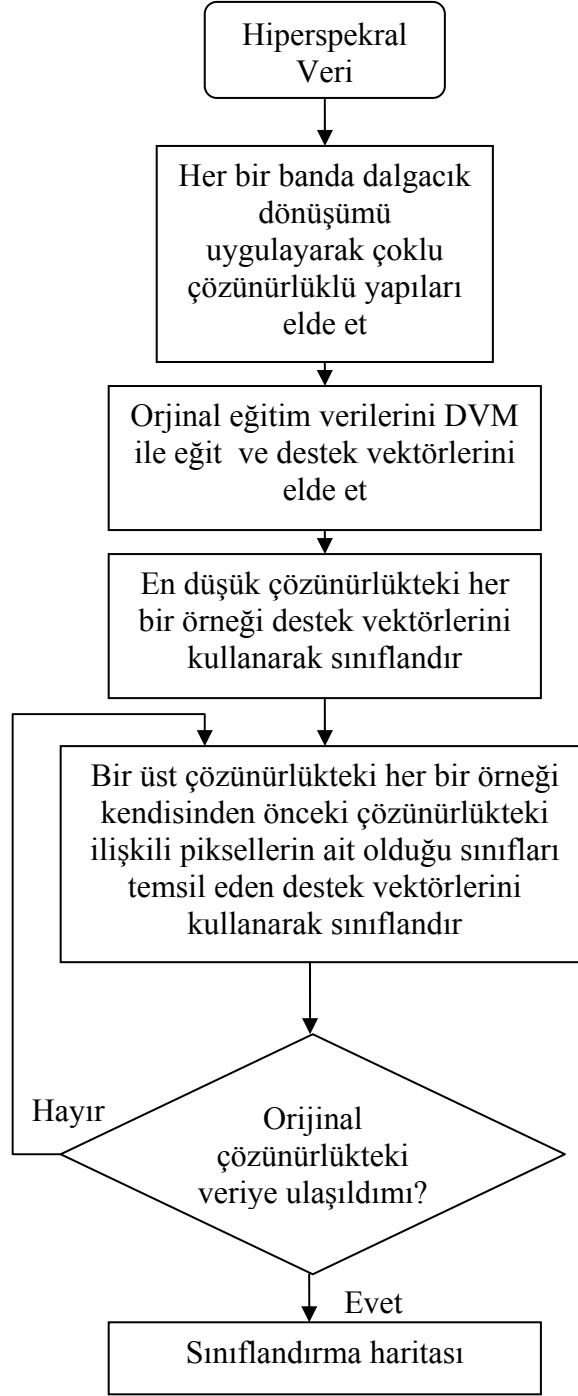
3. İlk önce en düşük çözünürlükteki (r . seviye) alçak frekans bileşenlerini içeren hiperspektral veri, eğitim aşamasında elde edilmiş olan destek vektörleri kullanılarak sınıflandırılmaktadır. Bu aşamada tüm sınıflar, bire-bir çok sınıflı sınıflandırma kullanılarak sınanmakta ve her piksel bire-bir sınıflandırma sonucunda en çok oyu alan sınıfa atanmaktadır. Bu aşamada dikkat edilmesi gereken bir nokta her piksel için sınıflandırmada tüm sınıfların sınanmasıdır. Böylece, en alt çözünürlükteki her piksel için bir sınıf bilgisi elde edilmektedir.

4. Bir sonraki aşamada, bir üst çözünürlükteki ($r-1$. seviye) alçak frekans bileşenlerini içeren hiperspektral verideki her bir piksel DVM ile sınıflandırılmaktadır. Fakat bu aşamada tüm sınıfların sınanması yerine sadece bir alt-çözünürlükte (bir üst seviyede) ilgili pikselin karşılık geldiği konumdaki komşu piksellerin sınıfları sınanmaktadır. Bu yaklaşım, [81]'de belirtilen her piksel için o pikselin ait olduğu sınıf ile en az bir komşusunun sınıfının aynı olduğunu ifade eden "aynı sınıf komşuluk özelliği" doğrultusunda kullanılmıştır. Bu nedenle, bu seviyede sadece bir üst seviyedeki komşu piksellerin sınıfları DVM ile sınanmaktadır. Başka bir deyişle, her bir piksel bir önceki çözünürlükte karşılık geldiği konumdaki pikselin sınıfını ve komşu piksellerin ait olduğu sınıfları temsil eden destek vektörleri kullanılarak DVM ile sınıflandırılmaktadır.

5. Aynı işlemler bir sonraki çözünürlük ($r-2$. seviye) için de gerçekleştirilmektedir ve $r-2$. seviyedeki her pikselin sınıf bilgisi, $r-1$. seviyedeki ilgili konumun komşu piksellerin sınıflarını temsil eden destek vektörleri kullanılarak DVM ile bulunmaktadır.

6. Bu işlemler, tam çözünürlükteki (orijinal çözünürlükteki) hiperspektral veri elde edilinceye kadar tekrarlanmakta ve her piksel için sınıf bilgisi bulunarak tüm hiperspektral verinin sınıf bilgisi (dolayısıyla sınıf haritası) elde edilmektedir.

Şekil 6.1’de önerilen yöntemin blok şeması gösterilmektedir. Gerçekleştirilen algoritma ile alt çözünürlükten başlanarak yüksek çözünürlüklere çıkılması sağlanmaktadır. Bu yaklaşım ile hiperspektral görüntüdeki pikseller sınıflandırılırken, eğitim aşamasında bulunan tüm destek vektörlerinin kullanılması yerine, her bir pikselin, kendisinden bir önceki alt-çözünürlükteki ilişkili konumdaki komşu öznitelik vektörlerinin sınıf bilgilerine göre sınıflandırılması gerçekleştirilmektedir. Bu nedenle tam çözünürlükteki veri için tüm sınıfların sınanması yerine sadece birkaç sınıfın sınanması sayesinde sınıflandırma işleminin hesapsal yükü azaltılmaktadır. Ayrıca komşuluk ilişkilerinden faydalandığı için hiperspektral görüntüdeki uzamsal ilişki de sınıflandırma aşamasında değerlendirilmektedir.



Şekil 6.1: Gerçekleştirilen algoritmanın akış şeması


6.3. Deneysel Sonuçlar

Deneysel sonuçlar Indian Pine hiperspektral görüntüsü kullanılarak sergilenmektedir. Her sınıf için toplam verinin %10 ve %50'si eğitim verisi olarak alınmıştır. Pikseller sınıflandırılırken, bir önceki alt bölümde açıklandığı gibi, bir önceki çözünürlükteki

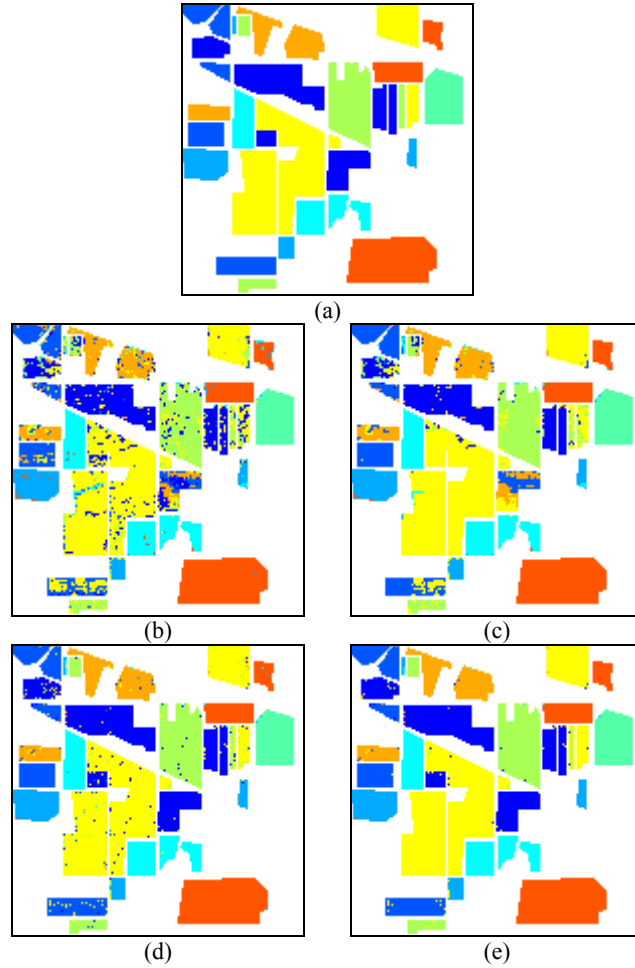
ilişkili konumdaki ve komşu piksellerin sınıflarını temsil eden destek vektörleri DVM sınıflandırmada kullanılmaktadır. Tablo 6.1’de doğrudan DVM ve gerçekleştirilen çok-çözünürlüklü DVM (ÇÇ-DVM) yönteminin sınıflandırma başarımları ve sınıflandırma süreleri gösterilmektedir. Hesaplanma süreleri saniye cinsinden işlemcinin piksel başına harcadığı süre olarak verilmiştir. Deneysel sonuçlar üst seviyedeki ilgili konuma ek olarak en yakın komşu öznitelik vektörü sayısı $s=8$, 24 ve $r=2,3,4$ seviye kullanılarak elde edilmiş olup her sınıf için toplam verinin %10’u ve %50’si eğitim verisi olarak kullanıldığı durumlar için verilmiştir. En yüksek sınıflandırma başarımları dalgacık dönüşümü sayısı $r=3$ ve $s=8$ en yakın komşu seçilerek elde edilmiştir. Örnek bir hiperspektral bant için $r=3$ seviyede elde edilen alçak frekans bileşenleri Şekil 6.3’de gösterilmektedir. Deneysel sonuçlar geliştirilen ÇÇ-DVM yönteminin sınıflandırma başarımlarını doğrudan DVM ile karşılaştırıldığında önemli oranda arttırdığını göstermektedir. Şekil 6.4, Indian Pine verisinin orijinal sınıf bilgileri haritası (yer doğrusu verisini) ile doğrudan DVM ve ÇÇ-DVM sonucu oluşan sınıflandırma haritalarını göstermektedir. Şekilden görüldüğü üzere önerilen yaklaşım özellikle sınıfların merkezlerinde meydana gelen yanlış sınıflandırma sonuçlarını spektral ve uzamsal bilgileri birlikte kullanması nedeniyle azaltmaktadır. Ayrıca gerçekleştirilen yöntem sınıflandırma süresini de azaltmaktadır. Burada verilen sınıflandırma süreleri, sadece destek vektörleri kullanılarak, tüm piksellerin sınıflandırılması için gereken toplam sürelerini kapsamakta olup destek vektörlerinin belirlenmesi işlemleri bu sürelere dahil edilmemiştir.

Tablo 6.1: Doğrudan DVM ve çok çözünürlüklü DVM (ÇÇ-DVM) sınıflandırma başarımları (SB) ve sınıflandırma süreleri (T)

Yöntem	%10 eğitim verisi		%50 eğitim verisi	
	SB	T (saniye)	SB	T (saniye)
DVM	83.02	0.0024	93.77	0.0172
ÇÇ-DVM ($r=2,s=8$)	88.15	0.0014	97.34	0.0056
ÇÇ-DVM ($r=2,s=24$)	85.65	0.0019	96.01	0.0067
ÇÇ-DVM ($r=3,s=8$)	89.11	0.0018	97.15	0.0066
ÇÇ-DVM ($r=3,s=24$)	85.95	0.0023	96.12	0.0083
ÇÇ-DVM ($r=4,s=8$)	84.22	0.0021	88.37	0.0086



Şekil 6.2: Indian Pine görüntüsü (a) 146. orijinal hiperspektral bant, (b) 1. seviyede alçak frekans bileşeni (c) 2. seviyede alçak frekans bileşeni (d) 3. seviyede alçak frekans bileşeni



Şekil 6.3 (a) Orijinal sınıf bilgileri haritası, (b) %10 eğitim verisi ve doğrudan DVM kullanılması sonucu oluşan sınıflandırma haritası, (c) %10 eğitim verisi ve çok çözünürlüklü DVM (ÇÇ-DVM) kullanılması sonucu oluşan sınıflandırma haritası, (d) %50 eğitim verisi ve doğrudan DVM kullanılması sonucu oluşan sınıflandırma haritası ve (e) %50 eğitim verisi ve ÇÇ-DVM kullanılması sonucu oluşan sınıflandırma haritası

6.4. Vargılar

Sıradüzensel özgün bir yöntem geliştirilerek uzamsal ve spektral bilgiler çoklu çözünürlüklü yapılar kullanılarak birleştirilmiştir ve bunun sonucunda DVM sınıflandırma başarımı artmıştır. Bununla beraber sınıflandırma (test) aşamasının çok çözünürlüklü bir yapı üzerinden gerçekleşmesi nedeniyle sınıflandırma (test) süresi azalmıştır. Önerilen yöntemde hiperspektral görüntüdeki pikseller sınıflandırılırken, eğitim aşamasında bulunan tüm destek vektörlerinin kullanılması yerine, her bir pikselin, kendisinden bir önceki alt-çözünürlükteki ilişkili konumdaki komşu öznelik vektörlerinin sınıf bilgilerine göre sınıflandırılması nedeniyle sınıflandırma (test) süresi azalmıştır.

7. FAZ İLİNTİSİ TEMELLİ YAKLAŞIMLAR

7.1. GÜDÜLENME

Faz ilintisi, iki işaret arasındaki benzerliğin ve işaretler arasındaki ötelemenin bulunmasında kullanılan bir frekans uzayı yöntemidir [45]. Uygulamada gürültü ve değişkenlik nedeniyle aynı nesneye ait spektral veriler değişkenlik gösterebilir bile, faz ilintisi standart çapraz ilintiye (cross correlation) oranla çok daha doğru algılanabilen bir tepe değeri vermektedir ve bu nedenle benzerlik algılamaları için daha uygun olabilmektedir [45].

Hiperspektral görüntülerde benzerlik ölçümleri için (spektral verilerin benzerliğinin ölçülmesi ve bantlar arası benzerliğin ölçülmesi) çoğunlukla standart çapraz ilinti kullanılmaktadır. Bu bölümde önerilen çalışmalarda hiperspektral görüntülerde spektral verilerin benzerliğinin ölçülmesi ve bantlar arası benzerliğin ölçülmesi amacıyla standart çapraz ilinti yerine faz ilintisi kullanımı faz ilintisi temelli özgün yöntemler geliştirilerek değerlendirilmektedir.

7.2. Faz İlintisi

$x_1[n]$ ile $x_2[n]$ iki hiperspektral veriyi gösteriyor ve $X_1[k]$ ile $X_2[k]$ bu verilere karşılık gelen ayrık Fourier dönüşümlerini (AFD, discrete Fourier transform) gösteriyorsa, faz ilintisi denklem (7.1) ile tanımlanmaktadır [83].

$$S[n] = F^{-1} \left[\frac{X_1[k] X_2^*[k]}{|X_1[k] X_2^*[k]|} \right] \quad (7.1)$$

Burada F^{-1} , ters AFD işlemini göstermektedir. İki spektral veri aynı ise, yani $x_1[n] = x_2[n]$ ise, faz ilintisi sonucu denklem (7.2) ile bulunmaktadır ve $n = 0$ noktasında birim dürtü elde edilmektedir.

$$\begin{aligned}
S[n] &= F^{-1} \left[\frac{X_1[k] X_2^*[k]}{|X_1[k] X_2^*[k]|} \right] = F^{-1} \left[\frac{X_1[k] X_1^*[k]}{|X_1[k] X_1^*[k]|} \right] \\
&= F^{-1} \left[\frac{|X_1[k]|^2}{|X_1[k]|^2} \right] = F^{-1} [1] = \delta[n]
\end{aligned} \tag{7.2}$$

Hiperspektral görüntülerin faz ilinti temelli topaklanması [83]'de önerilmiştir. [83]'de önerilen çalışmada, her bir pikselin spektral imzası seyreltilerek boyut azaltımı (bant sayısı azaltımı) yapılmakta ve bu sayede faz ilintisinin gürültü ve uzamsal değişkenliklerden daha az etkilenmesi sağlanmaktadır. Topaklar belirlenirken, piksellerin spektral imzaları arasındaki faz ilintisinin tepe değerine bakılarak karar verilmektedir. Eğer iki spektral imza arasındaki faz ilintisi belirli bir eşik değerinden yüksek ise bu iki spektral imza aynı topakta, aksi durumda farklı topaklar olarak ele alınmaktadır. Elde edilen topakların ortalama spektral imzaları üzerinden tekrar faz ilintisi temelli topaklama uygulanarak topaklar iyileştirilmekte ve fazladan elde edilen topaklar bu sayede ilişkinin yüksek olduğu topaklara dahil edilebilmektedir. Bu tez çalışmasında ise faz ilintisi temelli iki özgün yöntem önerilmiştir: i) faz ilintisi temelli eğitilmiş sınıflandırma yöntemi ve ii) faz ilintisi temelli bant seçme yöntemi.

7.3. Faz İlintisi Temelli Eğitilmiş Sınıflandırma Yöntemi

7.3.1. Önerilen yöntem

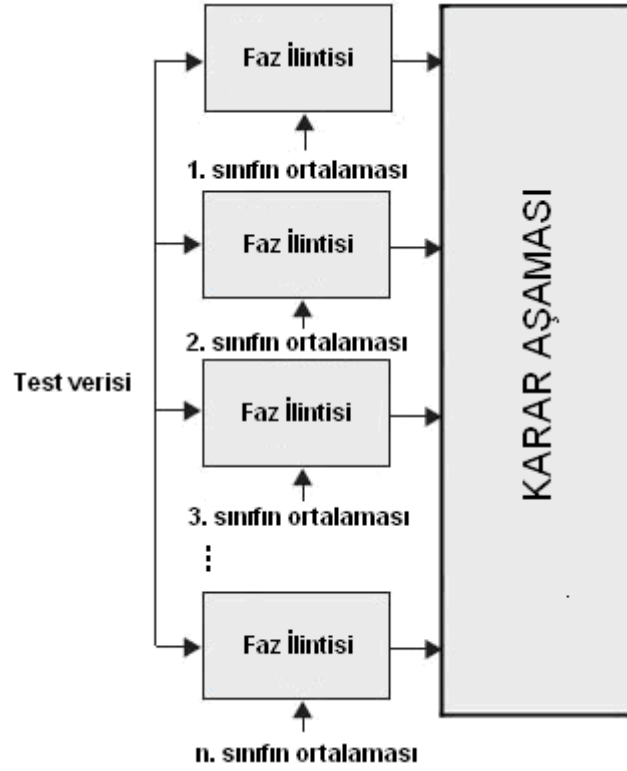
Faz ilintisi ile topaklama yöntemi [83] daha önce hiperspektral verilere uygulanmış olmasına rağmen eğitilmiş sınıflandırma yöntemi olarak ilk kez bu tez kapsamında incelenmiştir. Bu doğrultuda, sınıf temsilcilerinin eğitim aşamasında bulunması ve elde edilen sınıf temsilcilerinin sınıflandırma aşamasında kullanılması ile hiperspektral görüntülerin faz ilintisi temelli eğitilmiş (supervised) sınıflandırılması ele alınmıştır. Bu sınıflandırma yöntemi için üç farklı algoritma önerilmiştir.

İlk algoritmada, eğitim verisindeki her sınıfın ortalaması sınıf temsilcisi olarak alınmakta ve test verisindeki her bir spektral veri, elde edilen sınıf temsilci imzaları

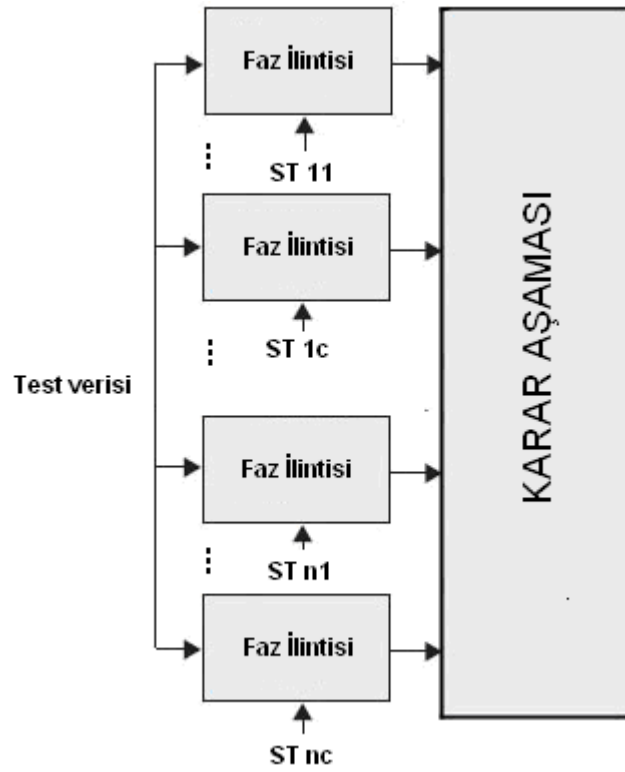
ile faz ilintisi işlemine sokulmaktadır. Her bir spektral veri, en yüksek faz ilintisinin elde edildiği sınıfa ait olacak şekilde sınıflandırılmaktadır. Şekil 7.1’de, önerilen 1. algoritmanın sınıflandırma (karar) aşaması gösterilmektedir.

İkinci algoritmada her sınıf için birden fazla sınıf temsilcisi alınmaktadır. Her sınıf için 5 sınıf temsilcisi, aynı sınıftaki spektral verilerin faz ilintisi sonuçlarına göre seçilmektedir. Burada aynı sınıfta olan fakat faz ilintisi değeri düşük olan örnek spektral veriler sınıf temsilcisi olarak atanmaktadır. Sınıflandırma aşaması ise ilk algoritma ile aynıdır, yani her bir spektral veri en yüksek faz ilintisinin elde edildiği sınıfa ait olacak şekilde sınıflandırılmaktadır. Şekil 7.2, ikinci algoritmanın sınıflandırma (karar) aşamasını göstermektedir. Bu şekilde c toplam temsilci sayısını ve ST sınıf temsilcisini göstermektedir. ST_{ij} ise i . sınıfın j . sınıf temsilcisini göstermektedir.

Üçüncü algoritmada ise eğitim aşamasında her sınıf için ikinci algoritmadaki gibi birden fazla sınıf temsilcisi bulunmaktadır. Sınıflandırma aşamasında ise sadece maksimum faz ilintisi değerine göre karar vermek yerine aynı sınıftaki tüm sınıf temsilcileri ile elde edilen faz ilintisi değerlerinin ortalamasına göre karar verilmektedir. En yüksek ortalama değere göre pikselin ait olduğu sınıfa karar verilmektedir.



Şekil 7.1: Birinci algoritmanın test verisini sınıflandırma aşaması



Şekil 7.2: İkinci algoritmanın test verisini sınıflandırma aşaması

7.3.2. Deneysel sonuçlar

Deneysel sonuçlar Indian Pine görüntüsü kullanılarak elde edilmiştir. Faz ilintisi temelli bir sınıflandırma yapılmak istendiğinde Indian Pine hiperspektral görüntüsünde birbirine oldukça yakın spektral imzalara sahip sınıfların bulunması nedeniyle, tüm sınıflar kullanıldığında sınıflandırma başarımının oldukça düşük olduğu gözlemlenmiştir. Bu nedenle önerilen üç farklı yaklaşımın başarımlarını karşılaştırmalı olarak tespit etmek için Indian Pine görüntüsündeki bazı sınıflar kullanılmış olup kullanılan sınıf bilgisi Tablo 7.1’de, bu sınıflar için elde edilen sınıflandırma başarımları ise Tablo 7.2’de gösterilmektedir. Bu sonuçlardan, ikinci algoritmanın daha yüksek sınıflandırma başarımı verdiği gözükmektedir.

Tablo 7.1: Eğitim ve test örneklerinin sayısı

Sınıf	Eğitim	Test
S1-Grass/Pasture	260	237
S2-Grass/Trees	389	358
S3-Hay-windrowed	236	253
S4-Soybean-clean till	305	309
S5-Woods	651	643
Toplam	1841	1800

Tablo 7.2: Üç farklı algoritma için elde edilen sınıflandırma başarımları (SB)

Kullanılan Sınıf Numaraları	SB1	SB2	SB3
S3,S4,S5	99.83	100	99.76
S2,S3,S4,S5	95.57	97.44	96.60
S1,S2, S3,S4,S5	82.77	87.27	78.80

7.4. Faz İlintisi Temelli Bant Azaltımı Yöntemi

Bu bölümde öznitelik ağırlıklandırma temelli bant seçimi için artıklık içeren bantların atılması aşamasında standart çapraz ilinti yerine faz ilintisi kullanılması değerlendirilmiş ve bu sayede daha iyi bant seçimi gerçekleştirilebileceği gösterilmiştir. Öznitelik ağırlıklandırma temelli bant seçimi algoritması, çift ayırma

yaklaşımı ve matris katsayıları analizi kullanarak orijinal bantlara ağırlıklar atamaktadır [38]. Her bir banda önemini ifade eden ağırlıklar verildikten sonra, seçilen bantlar arasında faz ilintisine bakılarak benzer bantların seçilmesi engellenmektedir. Gerçekleştirilen çalışmada [38]'den esinlenilmiştir. [38]'de her bir banda ağırlık ataması yapıldıktan sonra seçilecek bantlara standart çapraz ilinti yöntemi kullanılarak karar verilmektedir. Deneysel sonuçlar, faz ilintisi temelli bant seçimi algoritmasının, standart çapraz ilinti temelli bant seçimi algoritması ile karşılaştırıldığında daha yüksek sınıflandırma başarımı verdiğini göstermektedir. Gerçekleştirilen bant seçimi algoritmasının başarımı DVM sınıflandırma yöntemi kullanılarak gösterilmiştir.

7.4.1. Faz ilintisi ve öznelik ağırlıklandırma temelli bant seçimi yöntemi

Eğer n toplam sınıf sayısını, c ($c = 1, 2, \dots, n$) sınıf numarasını ve N_c c . sınıftaki örnek sayısını gösteriyorsa toplam örnek sayısı $N = N_1 + N_2 + \dots + N_n$ olmaktadır. Ayrıca $\mathbf{X}^{(c)} = [\mathbf{x}_1^{(c)}, \mathbf{x}_2^{(c)}, \dots, \mathbf{x}_{N_c}^{(c)}]$ c . sınıftaki veriyi gösteriyorsa, tüm giriş veri kümesi $\mathbf{X} = \bigcup_{c=1}^n \mathbf{X}^{(c)}$ olarak gösterilmektedir. Burada $\mathbf{x}_j^{(c)}$, $d \times 1$ boyutlarında bir vektördür ve d toplam spektral bant sayısını göstermektedir.

Çok sınıflı sınıflandırma problemlerinde öznelik ağırlıklandırma temelli bant seçimi yöntemi için [38]'de ortalama ıraksaklık D_{ort} (average divergence) ölçütü önerilmiştir. Gauss dağılımı varsayımı altında, ortalama ıraksaklık bütün bantların ıraksaklık değerlerinin toplamı olarak hesaplanmaktadır:

$$D_{ort} = \frac{1}{n(n-1)} \sum_{i=1}^{n-1} \sum_{j=i+1}^n \sum_{l=1}^d \left| \hat{\lambda}_l^{(i)} - \hat{\lambda}_l^{(j)} \right|^2 \left| \hat{\lambda}_l^{(i)} \hat{\lambda}_l^{(j)} \right|^{-1} \quad (7.3)$$

$$= \sum_{l=1}^d D_{ort}(l)$$

Burada $D_{ort}(l)$ l . bandın ıraksaklık değerini göstermektedir. (7.3)'e göre herhangi bir bant alt kümesinin sınıf ayrımsallığına bu alt kümedeki bireysel bantların

ayrimsallığı ile karar verilmektedir. $\hat{\lambda}_l^{(c)}$ c . sınıfın ilinti matrisinin standartlaştırılmış özdeğerlerini göstermektedir ve (7.4) ile ifade edilmektedir.

$$\hat{\lambda}_l^{(c)} = (\lambda_l^{(c)} - \bar{\lambda}_l) / \sigma_{\lambda_l} \quad (7.4)$$

Burada $\lambda_l^{(c)} (l=1,2,\dots,d)$ c . sınıfın ilinti matrisinin özdeğerleri, $\bar{\lambda}_l$ özdeğerlerin ortalamalarını ($\bar{\lambda}_l = \sum_{c=1}^n \lambda_l^{(c)} / n$) ve σ_{λ_l} standart sapma değerini

($\sigma_{\lambda_l} = \sqrt{\sum_{c=1}^n (\lambda_l^{(c)} - \bar{\lambda}_l)^2 / (n-1)}$) göstermektedir. Verideki çoğu bilginin ilk temel

bileşenlerde tutulması nedeni ile (7.3) düzenlenerek (7.5) elde edilmektedir.

$$D'_{ort} = \sum_{l=1}^d D_{ort}(l) (\bar{\lambda}_l / d)^r = \sum_{l=1}^d D'_{ort}(l) \quad (7.5)$$

Burada r 0'dan büyük ve kullanıcı girişli bir parametredir. l . bant için c . sınıf ile ilişkili olan önemlilik katsayısı $\bar{p}_l^{(c)}$ denklem (7.6) ile ifade edilmektedir.

$$\bar{p}_l^{(c)} = \frac{1}{d} \sum_{k=1}^d a_k (p_{lk}^{(c)})^2 \quad (7.6)$$

Burada $a_k = D'_{ort}(k) / \sum_{l=1}^d D'_{ort}(l)$ ve $p_{lk}^{(c)}$ l . bandın c . sınıfının ilinti matrisinin normalize edilmiş öz vektörlerinin k . bileşenini göstermektedir. Önemlilik katsayıları sıralanarak, c . sınıf için bantların önem sıralaması elde edilmektedir. Tüm sınıflar için bu sıralama elde edilmektedir ve sonrasında oylama yöntemi (7.7) kullanılarak orijinal bantlara ağırlıklar atanmaktadır.

$$w(l) = \frac{1}{d} \sum_{c=1}^n (d - d_l^{(c)} + 1) \quad (7.7)$$

Burada $d_l^{(c)}$ c . sınıfın l . bandının önem sırasını göstermektedir. Her bant için ağırlık değeri hesaplandıktan sonra, bantlar ağırlık değerlerine göre sıralanmakta ve yüksek ağırlığa sahip bantlar seçilmektedir.

Öznitelik ağırlıklandırma yöntemi bantlar arasındaki ilinti hesabını içermemektedir ve bu nedenle yüksek ağırlığa sahip benzer bantlar seçilebilmektedir. Önemli bilgi kaybına neden olmadan artıklık oluşturacak bantların elenmesi gerekmektedir. Bu nedenle faz ilintisi kullanılarak önceden seçilmiş olan bantlar ile yüksek ağırlıklı bantlar arasında faz ilintisi hesaplanmakta ve ilgili yüksek ağırlıklı bant ancak ilinti değeri eşik değerinden küçük ise seçilmektedir. Bu sayede [38]'de gerçekleştirilen çalışmada kullanılan standart ilinti yerine faz ilintisi kullanımının başarımları değerlendirilmektedir.

7.4.2. Deneysel sonuçlar

Indian Pine ve DC Mall verileri kullanılarak önerilen yaklaşımın başarımları değerlendirilmiştir. Bant azaltımı işlemi gerçekleştirildikten sonra farklı bant sayılarına sahip Indian Pine ve DC Mall verileri DVM ile sınıflandırılmıştır. Önerilen yaklaşımın sınıflandırma başarımlarını göstermek amacıyla ile DVM sınıflandırma algoritması RTF çekirdeği ile kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma yöntemi kullanılmıştır. Deneysel sonuçlarda, DVM ceza parametresi C [40-1200] arasında ve RTF gamma parametresi [0.1-3] arasında değerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir. Faz ilintisi ile öznitelik ağırlıklandırma temelli bant seçimi (ÖA-Fİ) ve standart çapraz ilinti ile öznitelik ağırlıklandırma temelli bant seçimi (ÖA-Sİ) ile elde edilen bantların DVM sınıflandırma sonuçları Indian Pine ve DC Mall görüntüleri için sırasıyla Tablo 7.3 ve Tablo 7.4'de gösterilmektedir. Deneysel sonuçlar artıklık eleme işleminde standart çapraz ilinti yerine faz ilintisi kullanılmasının sınıflandırma performansını özellikle düşük bant sayıları için arttırabileceğini göstermektedir.

Tablo 7.3: Indian Pine verisi için faz ilintisi temelli öznitelik azaltımı (ÖA-Fİ) ve standart çapraz ilinti temelli öznitelik azaltımı (ÖA-Sİ) sonrası farklı bant sayılarında (BS) elde edilen DVM sınıflandırma başarımları (SB)

BS	ÖA-Fİ	ÖA-Sİ
	SB	SB
10	78.55	77.55
15	81.40	78.98
20	82.21	80.16
25	84.06	81.88
30	85.06	83.43
35	87.03	86.00
40	87.79	87.66

Tablo 7.4: DC Mall verisi için faz ilintisi temelli öznitelik azaltımı (ÖA-Fİ) ve standart çapraz ilinti temelli öznitelik azaltımı (ÖA-Sİ) sonrası farklı bant sayılarında (BS) elde edilen DVM sınıflandırma başarımları (SB)

BS	ÖA-Fİ	ÖA-Sİ
	SB	SB
10	99.27	97.18
15	99.36	97.72
20	99.18	98.34
25	99.54	99.24
30	99.27	99.46
35	99.27	99.46
40	99.12	99.33

7.5. Vargılar

Önerilen faz ilintisi temelli sınıflandırma yaklaşımının başarımının DVM gibi gelişmiş sınıflandırma yöntemleri ile yarışabilecek düzeyde olmadığı görülmüştür. Bunun nedeni, DVM ile verileri sınıflandırırken çekirdek fonksiyonları kullanılması ve verinin yüksek boyutlu uzaya eşlemi yapılarak yüksek boyutlu uzayda doğrusal ayrılabilirliğe yakın hale getirilmesidir. Faz ilintisi temelli eğitimli sınıflandırma yönteminde ise orjinal giriş uzayında sınıflandırma yapılmaktadır. Öznitelik ağırlıklandırma temelli bant azaltımı yönteminde artıklık bantların elenmesi sırasında standart çapraz ilinti yerine faz ilintisi kullanılarak daha önemli ve birbirine daha az benzeyen bantlar seçilmektedir. Bu nedenle bantlar arası benzerliğin bulunmasında faz ilintisi benzerlik ölçütünün çapraz ilintiye göre daha başarılı olduğu gösterilmiştir.

8. SPEKTRAL GENLİK VE SPEKTRAL TÜREV BİLGİLERİNİN BİRLEŞTİRİLEREK HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA BAŞARIMININ ARTTIRILMASI

8.1. Gdlenme

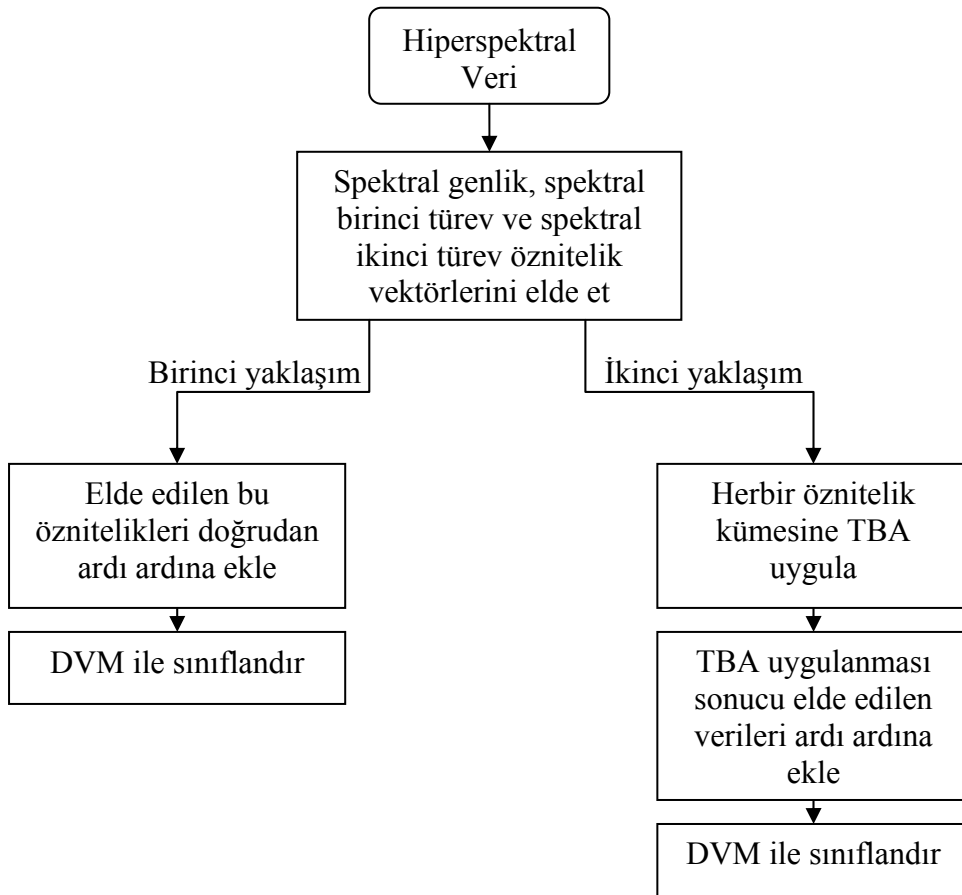
Spektral genlik znelik vektrleri hiperspektral grntlerin sınıflandırılması ve topaklanmasında yaygın olarak kullanılmaktadır. Spektral ayırım saęlayan dięer bir znelik vektrleri olan spektral trev znelik vektrleri atmosferik ve aydınlatma etkilerinden dolayı meydana gelen deęişiklerden etkilenmemesi nedeniyle nemlidir fakat spektral trev znelik vektrlerinin hiperspektral grntlerde kullanılması ile ilgili ok az alıřma bulunmaktadır. [84]'de spektral trev znelik vektrlerinin spektral ayırım ve tanımlamayı dzeltmek amacı ile kullanılması nerilmiřtir ve hiperspektral grntlerin komřu bantlarındaki eęim deęişiklikleri, spektral deęişimleri karakterize etmek iin kullanılarak spektral trev znelik vektrlerinin kodlanması zerine alıřılmıřtır. Trev bilgilerinin hiperspektral verilerde kullanılmasında trev spektroskopisinden [85]'de esinlenilmiřtir.

Bu blmde nerilen alıřma ile spektral genlik znelik vektrlerinin spektral trev znelik vektrleri ile birleřtirilmesinin DVM sınıflandırma bařarımına etkisi incelenmektedir. Spektral trev znelik vektrlerinin spektral genlik znelik vektrleriyle beraber hiperspektral grntlerin sınıflandırılmasında kullanılması ilk defa bu tez kapsamında incelenmektedir.

8.2. nerilen Yntem

Spektral genlik ve trev znelik vektrleri doęrudan ardı ardına eklenerek veya bant azaltımı yntemleri kullanılarak birleřtirilmektedir. Bant azaltımı yntemi olarak TBA seilmiřtir ve TBA genlik ve trev znelik vektrlerine ayrı ayrı uygulanarak her bir ayrı veri kmesi ile ilgili nemli bileřenlerin ıkarılması

sağlanmaktadır. İstenen bant sayısında veriler, genlik özniteliklerinin, birinci türev ve ikinci türev özniteliklerinin önemli bileşenlerinin farklı oranlarda birleşmesi (ardı ardına eklenmesi) sonucu elde edilmektedir. 3 farklı veri kümesine (spektral genlik öznitelikleri, spektral birinci türev ve spektral ikinci türev özniteliklerini içeren veriler) TBA öznitelik çıkarımı uygulanması sonucu elde edilen veriler ardı ardına eklenerek DVM ile sınıflandırılmaktadır. Deneysel sonuçlar önerilen yöntemin DVM sınıflandırma başarımını arttırdığını göstermektedir. Bu bölümde geliştirilen yöntemlerin blok şeması Şekil 8.1’de verilmektedir.



Şekil 8.1: Gerçekleştirilen algoritmaların akış şeması

Hiperspektral verilerin, genlik öznitelikleri farklı dalga boyu bantlarındaki yansıtırlık değerlerini içermektedir. Spektral genlik öznitelik vektörlerini $\{\mathbf{x}_i | \mathbf{x}_i \in \mathbb{R}^d\}_{i=1}^N$ olarak göstermek mümkündür ve burada d \mathbf{x}_i örneğinin toplam öznitelik (bant) sayısını göstermektedir. Şekil 8.2’de üç farklı sınıfa ait genlik öznitelik vektörleri (sınıfların

ortalama spektral imzalarının farklı dalga boylarındaki yansıtırlık değerleri) gösterilmektedir ve farklı sınıfların genlik verilerinin oldukça ayrılabilir olduğu görülmektedir. Spektral türev öznitelik vektörü ise, her bir $\{\mathbf{x}_i\}_{i=1}^N$ örneği için, spektral genlik öznitelik vektörünün ardışık örneklerinin farkı alınarak bulunmaktadır. Örneğin \mathbf{x}_i örneğinin j . bant için spektral birinci türev bilgisi (8.1) kullanılarak elde edilmektedir.

$$\mathbf{y}_i^j = \mathbf{x}_i^{j+1} - \mathbf{x}_i^j \quad j = 1, 2, \dots, d-1 \quad (8.1)$$

Burada \mathbf{x}_i^j i . pikselin j . bant için genlik örneğini ve \mathbf{y}_i^j , i . pikselin j . bant için birinci türev örneğini göstermektedir. Spektral birinci türev özniteliklerinin toplam sayısı $d-1$ 'dir. Şekil 8.3'de üç farklı sınıf için birinci türev öznitelik vektörleri (sınıfların ortalama spektral imzalarının farklı dalga boylarındaki birinci türev değerleri) gösterilmektedir. Spektral birinci türev öznitelikleri daha az kolay ayrılabilir olmasına rağmen, farklı sınıfların ayrılmasında önemli bilgi sağlamaktadır. Spektral ikinci türev öznitelik vektörü ise spektral birinci türev öznitelik vektörünün ardışık örneklerinin farkı alınarak elde edilmektedir. Örneğin \mathbf{x}_i örneğinin j . bant için spektral ikinci türev örneği denklem (8.2) kullanılarak elde edilmektedir.


$$\mathbf{z}_i^j = \mathbf{y}_i^{j+1} - \mathbf{y}_i^j \quad j = 1, 2, \dots, d-2 \quad (8.2)$$

(8.2)'de \mathbf{z}_i^j , i . pikselin j . bant için spektral ikinci türev örneğini göstermektedir ve toplam spektral ikinci türev öznitelikleri sayısı $d-2$ 'dir. Üç farklı sınıf için spektral ikinci türev öznitelik vektörleri (sınıfların ortalama spektral imzalarının farklı dalga boylarındaki spektral ikinci türev değerleri) Şekil 8.4'de gösterilmektedir.


Sınıflandırma başarımları, tüm spektral genlik öznitelikleri, tüm spektral birinci türev ve tüm spektral ikinci türev öznitelikleri için hesaplanmakla birlikte TBA öznitelik çıkarımı kullanılarak üç farklı veri kümesinin birleştirilmesinden elde edilen yeni veri için de elde edilmektedir. Genlik ve spektral türev özniteliklerinin yapısının farklı olması nedeni ile TBA üç veri kümesine (genlik öznitelikleri, spektral birinci türev öznitelikleri, spektral ikinci türev öznitelikleri) ayrı ayrı uygulanmaktadır.

İstenen toplam bant sayısı için, üç veri kümesinden farklı sayılarda öznitelikler çıkarılmakta ve ardı ardına eklenerek birleştirilmektedir.


TBA boyut azaltımı için yaygın olarak kullanılan doğrusal dönüşüm yöntemidir [1]. TBA, mümkün olduğunca ilişkili değişkenleri, temel bileşenler olarak adlandırılan düşük sayıda ilişkisiz değişkenlere dönüştüren matematiksel yöntemi içermektedir. Yaygın kullanılan öznitelik çıkarım yöntemi olması nedeniyle burada öznitelik (bant) çıkarımı için kullanılmaktadır ve bir sonraki alt bölümde detaylı olarak incelenmektedir.



Şekil 8.2: Üç farklı sınıf için spektral genlik öznitelik vektörleri



Şekil 8.3: Üç farklı sınıf için birinci spektral türev öznitelik vektörleri



Şekil 8.4: Üç farklı sınıf için spektral ikinci türev öznitelik vektörleri

8.3. Temel Bileşen Analizi (TBA)

Temel Bileşen Analizi (TBA), örüntü tanıma uygulamalarında boyut azaltımı amacıyla yaygın olarak kullanılan eğitimsiz (unsupervised) bir öznitelik çıkarımı (bant çıkarımı) yöntemidir ve bu yöntem ile yüksek boyutlu giriş verisinin düşük boyutlu ve birbirleriyle ilişkisiz öznitelikler içeren veriye doğrusal dönüşümü sağlanmaktadır [113].

İzdüşüm yöntemlerinde d boyutlu orijinal giriş uzayının, minimum bilgi kaybı ile yeni m boyutlu uzaya eşlemi yapılmaktadır. \mathbf{w} doğrultusunda X verisinin eşlemi aşağıdaki denklem ile elde edilmektedir.

$$Z = \mathbf{w}^T X \quad (8.3)$$

TBA yönteminde büyükleme ölçütü olarak değişinti kullanılmaktadır. Eğer \mathbf{w}_1 temel bileşeni gösterirse, X verisinin \mathbf{w}_1 'e eşlemi sonucu $Z = \mathbf{w}_1^T X$ 'dir ve Z 'in değişintisi σ_Z^2 denklem (8.4) ile tanımlanmaktadır.

$$\sigma_Z^2 = \mathbf{w}_1^T \Sigma \mathbf{w}_1 \quad (8.4)$$

Burada Σ , X verisinin ortak değişinti (covariance) matrisini göstermektedir. $\mathbf{w}_1^T \mathbf{w}_1 = 1$ sınırlaması altında σ_Z^2 en büyüklenmelidir ve ilişkili Lagrange problemi denklem (8.5) ile ifade edilmektedir.

$$\text{büyükle: } \mathbf{w}_1^T \Sigma \mathbf{w}_1 - \alpha (\mathbf{w}_1^T \mathbf{w}_1 - 1) \quad (8.5)$$

Denklem (8.5)'in \mathbf{w}_1 'e göre türevi alınarak 0'a eşitlenmektedir:

$$2 \Sigma \mathbf{w}_1 - 2\alpha \mathbf{w}_1 = 0 \rightarrow \Sigma \mathbf{w}_1 = \alpha \mathbf{w}_1 \quad (8.6)$$

Denklem (8.6)'dan görüldüğü üzere \mathbf{w}_1 ortak değişinti matrisinin bir özvektörü ve α 'da ortak değişinti matrisinin öz değeridir. Değişintinin en büyüklenebilmesi için en büyük özdeğere sahip özvektörün seçilmesi gerekmektedir. Bu nedenle birinci temel bileşen giriş verisinin ortak değişinti matrisinin en büyük özdeğere sahip özvektörüdür. İkinci temel bileşen ise ortak değişinti matrisinin en büyük ikinci özdeğere sahip özvektörüdür. d boyutlu bir veriden m ($m < d$) boyutlu yeni bir veri elde etmek için kullanılan TBA öznelik çıkarımı algoritması aşağıdaki şekilde özetlenmektedir.

1-Verinin ortalaması verinin kendisinden çıkarılmaktadır.

2-Ortak deęişinti matrisi hesaplanmaktadır ve d boyutlu bir veri için ortak deęişinti matrisi boyutu $d \times d$ 'dir.

3-Ortak deęişinti matrisinin özdeęer ve özvektörleri bulunmaktadır.

4-Özdeęerler büyükten küçüğe doğru sıralanmakta ve buna göre özvektörler de sıralanmaktadır.

5-En yüksek m özdeęere sahip özvektörün devrięi alınarak, ortalaması çıkarılmış veri (1. aşamada elde edilen) ile çarpılmakta ve m boyutlu veri elde edilmektedir.

Eđer ki bantlar arası ilinti yüksek ise, yüksek özdeęere sahip özvektörlerin sayısı düşük olmakta ve bunun sonucu olarak da büyük miktarda boyut azaltımı yapılabilmektedir. Bantlar arası ilintinin düşük olması durumunda ise TBA'nın etkisi az olmaktadır ve neredeyse orijinal bant sayısında bant elde edilmektedir.

8.4. Deneysel Sonuçlar

Deneysel sonuçlar Indian Pine görüntüsünü kullanarak elde edilmiştir. Tablo 8.1, spektral genlik özniteliklerinin (GÖ), spektral birinci türev özniteliklerinin (TÖ1), spektral ikinci türev özniteliklerinin (TÖ2) ayrı ayrı kullanılması, GÖ ve TÖ1 veri kümelerinin ardı ardına eklenmesi (GÖ-TÖ1), ve ayrıca üç veri kümesinin ardı ardına eklenmesi (GÖ-TÖ1-TÖ2) ile oluşan verilerin DVM ile sınıflandırılması sonuçlarını göstermektedir. Deneylerde, DVM ceza parametresi C [40-1000] arasında ve RTF gamma parametresi [0.1-3] arasında deęerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir ve en uygun ceza parametresi $C=1000$ ve en uygun RTF çekirdeęi gamma parametresi $\{\gamma = 2\}$ olarak bulunmuştur. Sadece spektral türev öznitelikleri kullanılarak elde edilen sınıflandırma başarımı sadece genlik öznitelikleri kullanılarak elde edilen sınıflandırma başarımından düşük olmaktadır. Fakat spektral birinci türev özniteliklerinin, genlik öznitelikleri ile birlikte kullanılması durumunda sınıflandırma başarımının arttığı görülmektedir. Üç veri kümesinin birleşmesi durumunda, sadece spektral genlik özniteliklerinin kullanılması durumu ile aynı sınıflandırma başarımları elde edilmektedir. Bu sonuçlar genlik özniteliklerinin, spektral birinci türev öznitelikleri ile birleşmesi durumunda, (öznitelik çıkarımı uygulanmadan) sınıflandırma başarımının artırıldığı göstermesi açısından önemlidir.

Tablo 8.1: Spektral genlik özniteliklerinin (GÖ), spektral birinci türev özniteliklerinin (TÖ1), spektral ikinci türev özniteliklerinin (TÖ2) ayrı ayrı kullanılması, GÖ ve TÖ1 veri kümelerinin ardı ardına eklenmesi (GÖ-TÖ1), ve ayrıca üç veri kümesinin ardı ardına eklenmesi (GÖ-TÖ1-TÖ2) ile oluşan verilerin DVM sınıflandırma başarımları (SB)

Veri Kümesi	SB
GÖ	92.56
TÖ1	87.72
TÖ2	78.92
GÖ-TÖ1	93.85
GÖ-TÖ1-TÖ2	92.56

Öznitelik çıkarımı uygulanması durumunda sınıflandırma başarımını hesaplayabilmek amacı ile, TBA üç farklı veri kümesine ayrı ayrı uygulanmaktadır ve istenilen toplam öznitelik (bant) sayısını elde etmek için üç farklı veri kümesinden TBA ile çıkarılan öznitelikler, farklı oranlarda birleştirilerek sınıflandırma performansı üzerindeki etkisi incelenmiştir. Her veri kümesine TBA uygulanarak, istenilen öznitelik (bant) sayısına göre her 3 veri kümesinden farklı oranlarda öznitelikler birlikte kullanılarak oluşan yeni veri kümesi DVM ile sınıflandırılmaktadır. Tablo 8.2’de TBA sonucu sadece genlik özniteliklerinden istenen sayıda bant seçilmesi sonuçları TBA-GÖ, spektral genlik ve spektral birinci türev özniteliklerinden istenen sayıda bant seçilmesi sonuçları TBA-GÖ+TÖ1, ve spektral genlik, spektral birinci türev ve spektral ikinci türev özniteliklerinden istenen sayıda bant seçilmesi sonuçları TBA-GÖ+TÖ1+TÖ2 olarak gösterilmektedir ve elde edilen veri kümeleri için elde edilen en iyi sınıflandırma başarımlarını, toplam öznitelik (bant) sayısına göre gösterilmektedir (örneğin üç veri kümesinin birlikte kullanılması durumunda, toplamda 10 bant elde edilmek istenir ise, her bir veri kümesinden farklı sayılarda öznitelikler TBA ile elde edilmekte ve ardı ardına eklenerek elde edilen yeni veri DVM ile sınıflandırılmaktadır). Deneysel sonuçlar spektral genlik özniteliklerinin, spektral birinci türev ve spektral ikinci türev özniteliklerinin öznitelik çıkarımı yöntemi ile birleşmesi sonucu sınıflandırma başarımının önemli ölçüde arttırılabileceğini ve TBA-GÖ+TÖ1+TÖ2’nin TBA-GÖ+TÖ1’ya göre yakın sonuçlar verdiğini göstermektedir.

Tablo 8.2: Farklı bant sayılarında (BS) TBA sonucu sadece spektral genlik özniteliklerinden bant seçilmesi (TBA-GÖ), spektral genlik ve spektral birinci türev özniteliklerinden bant seçilmesi (TBA-GÖ+TÖ1), ve spektral genlik, spektral birinci türev ve spektral ikinci türev özniteliklerinden bant seçilmesi (TBA-GÖ+TÖ1+TÖ2) sonucu DVM sınıflandırma başarımları

BS	TBA-GÖ	TBA-GÖ+ TÖ1	TBA-GÖ+TÖ1+TÖ2
40	83.06	85.22	85.52
35	83.79	86.70	86.70
30	85.54	87.68	87.68
25	87.61	89.38	89.66
20	89.03	89.36	89.36
15	88.77	88.77	88.84
10	86.79	87.61	87.61

Bu bölümde önerilen çalışmada hiperspektral görüntülerin sınıflandırma başarımının, spektral genlik öznitelikleri ve spektral türev özniteliklerinin TBA ile birleştirilmesi sonucu artırılması önerilmiştir. Deneysel sonuçlar, öznitelik çıkarımı (bant çıkarımı) yöntemi kullanılması veya kullanılmaması durumunda, spektral genlik ve spektral türev özniteliklerinin birlikte kullanılarak, daha iyi sınıflandırma başarımı elde edileceğini göstermektedir.

Farklı bant sayılarında, TBA-GÖ+TÖ1+TÖ2 yöntemi kullanılarak elde edilen sınıflandırma başarımları, Bölüm 7’de anlatılan faz ilintisi ile öznitelik ağırlıklandırma temelli bant seçimi (ÖA-Fİ) yöntemi ve Bölüm 4’de bahsedilen 1-BD temelli ön-işlem sonrası EY uygulanarak bant azaltımı yöntemi (1-BD-EY) sonuçları ile karşılaştırılmıştır ve sonuçlar Tablo 8.3’de gösterilmektedir. 1-BD, [43]’de önerilen çekirdek kullanılarak gerçekleştirilmiş ve ön-işlem sonrası toplam bant sayısı 125’e azaltılarak EY yöntemi uygulanmıştır. Sonuçlar düşük bant sayılarında GÖ+TÖ1+TÖ2 yönteminin daha iyi sonuç verdiğini, fakat yüksek bant sayılarında 1-BD-EY yönteminin daha iyi sonuç verdiğini göstermektedir. Bunun nedeni olarak bilindiği üzere TBA veriye ait en önemli bileşenleri ilk birkaç bantta tutmaktadır. TBA sonucu elde edilen bantlardan yüksek bant sayısında seçim yapmak başarımı düşürmektedir.

Tablo 8.3: TBA-GÖ+TÖ1+TÖ2, 1-BD-EHT, ÖA-Fİ yöntemlerinin farklı bant sayılarında (BS) sınıflandırma başarımları

BS	TBA-GÖ+TÖ1+TÖ2	1-BD-EHT	ÖA-Fİ
40	85.52	91.32	87.79
35	86.70	90.62	87.03
30	87.68	90.14	85.06
25	89.66	89.55	84.06
20	89.36	88.86	82.21
15	88.84	88.07	81.40
10	87.61	87.90	78.55

8.5. Vargılar

Spektral türev özniteliklerinin genlik öznitelikleriyle beraber hiperspektral görüntülerin sınıflandırılmasında kullanılarak DVM sınıflandırma başarımının arttırılabileceği gösterilmiştir. Elde edilen sonuçlar atmosferik ve aydınlatma etkilerinden dolayı meydana gelen değişikliklerden etkilenmeyen spektral türev özniteliklerinin spektral verileri tanımlamada önemli öznitelikler olduğunu göstermiştir. Ayrıca sadece spektral türev öznitelikleri kullanılarak elde edilen sınıflandırma başarımı sadece genlik öznitelikleri kullanılarak elde edilen sınıflandırma başarımından düşük olması nedeniyle spektral birinci türev özniteliklerinin genlik öznitelikleri ile birlikte kullanılması önerilmektedir.

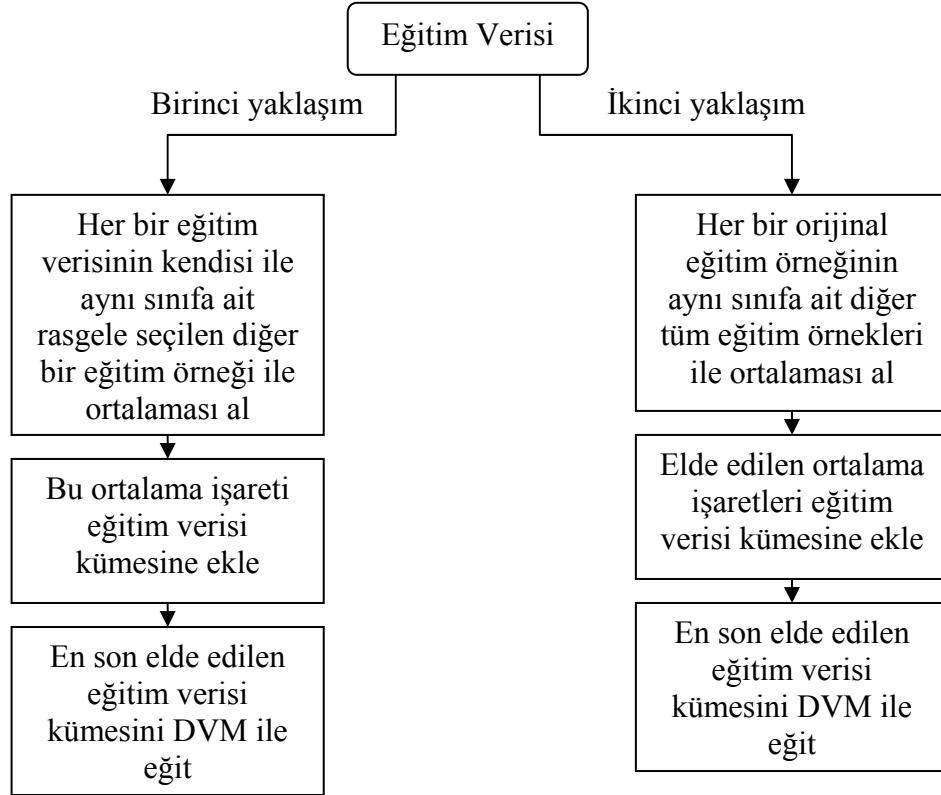
9. DÜŞÜK SAYIDA EĞİTİM VERİSİNE SAHİP HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRMA BAŞARIMININ ÖRNEK ARADEĞERLEME YAKLAŞIMI KULLANILARAK ARTTIRILMASI

9.1. Gdlenme

DVM ile sınıflandırma başarımı doğrudan eğitim verisinin kalitesine bağlıdır ve hiperspektral görüntülerde eğitimli veriyi elde etmek zaman alıcı ve masraflı işlemler gerektirmektedir [86]. Ayrıca yüksek miktardaki spektral bant sayısı ve düşük miktardaki eğitimli örnek sayısı sonucu oluşan yüksek boyut problemi (Hughes olgusu) nedeniyle sınıflandırma başarımları düşmektedir. Hughes olgusuna göre eğitimli veri sayısı sabit iken bant sayısı arttırıldığında sınıflandırma başarımı düşmektedir. Eğitim verisinin miktarı arttırılarak Hughes olgusu probleminin etkisi azaltılabilir. Örneğin [91 ,92]'de rasgele grlt vektrnn her bir eğitim örneğine eklenerek toplam eğitim verisinin arttırılması önerilmiştir. Bu bölümde önerilen çalışma ile ise [91, 91]'de önerilen çalışmalardan farklı olarak aynı sınıfa ait orijinal eğitim örneklerinin aradeğerlemesi ile oluşan yeni örneklerin eğitim verisine eklenerek toplam eğitim verisi miktarının yapay olarak arttırılması önerilmektedir.

9.2. Önerilen Yöntem

Bu bölümde önerilen yöntemler ile orijinal eğitim örneklerinin aradeğerlemesi ile oluşan yeni örneklerin eğitim verisine eklenerek toplam eğitim verisi miktarının yapay olarak arttırılması sağlanmaktadır. Hiperspektral görüntülerde eğitim verisinin arttırılması amacıyla iki yöntem önerilmektedir. Şekil 9.1'de bu bölümde gerçekleştirilen algoritmaların akış şeması verilmektedir.



Şekil 9.1: Gerçekleştirilen algoritmaların akış şeması

İlk yaklaşımda, ara değerlendirilmiş eğitim örnekleri her bir orijinal eğitim örneğinin aynı sınıfa ait ve rasgele seçilen diğer bir eğitim örneği ile ortalaması alınarak hesaplanmaktadır. Sonrasında aradeğerleme işlemi ile elde edilmiş yeni örnekler eğitim verisine eklenmekte ve eğitim verisi miktarı iki kuvvetine çıkarılmaktadır.

İkinci yaklaşımda ise her bir orijinal eğitim örneğinin aynı sınıfa ait diğer tüm eğitim örnekleri ile ortalaması alınarak eğitim verisine eklenmesi önerilmektedir. Bu yaklaşım ilk yaklaşımın limit durumudur ve tek bir sınıf için önerilen yaklaşım aşağıda özetlenmektedir. $\mathcal{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ örnek bir sınıf için N tane eğitim örneğini göstermektedir.

1-İlk örneğin diğer tüm örnekler ile ortalaması hesaplanmaktadır:

$$\{\mathbf{x}'_{1,1}, \mathbf{x}'_{1,2}, \dots, \mathbf{x}'_{1,N-1}\} = \frac{\mathbf{x}_1 + \{\mathbf{x}_2, \dots, \mathbf{x}_N\}}{2} \quad (9.1)$$

2-İkinci örneğin diğer kalan tüm örnekler ile ortalaması hesaplanmakta ve yeni örnekler elde edilmektedir (burada ilk örnek ortalama alma işlemine dahil edilmemektedir).

$$\{\mathbf{x}'_{2,1}, \mathbf{x}'_{2,2}, \dots, \mathbf{x}'_{2,N-2}\} = \frac{\mathbf{x}_2 + \{\mathbf{x}_3, \mathbf{x}_4, \dots, \mathbf{x}_N\}}{2} \quad (9.2)$$

Bu işlemler sınıfın son örneği ile karşılaşılan kadar tekrarlanmaktadır. Örneğin orijinal eğitim verisindeki t . örnek için eğitim verisine eklenecek yeni örnekler aşağıdaki denklem ile ifade edilmektedir.

$$\{\mathbf{x}'_{t,1}, \mathbf{x}'_{t,2}, \dots, \mathbf{x}'_{t,N-t}\} = \frac{\mathbf{x}_t + \{\mathbf{x}_{t+1}, \mathbf{x}_{t+2}, \dots, \mathbf{x}_N\}}{2} \quad (9.3)$$

3-Yeni elde edilen toplam örnek sayısı $\sum_{i=1}^{N-1} (N-i) = N(N-1)/2$ 'dir ve elde edilen yeni örnekler eğitim verisine eklenmektedir. Eğitim örneklerinin toplam sayısı $N + N(N-1)/2$ 'dir.

İlk yaklaşım veya ikinci yaklaşım kullanılarak yeni eğitim örnekleri elde edilmekte ve başlangıçta var olan eğitim örnekleri ile birlikte kullanılarak DVM eğitim aşaması gerçekleştirilmektedir.

9.3. Deneysel Sonuçlar

Deneysel sonuçlar Indian Pine hiperspektral görüntüsü kullanılarak elde edilmiştir. Önerilen yaklaşımın sınıflandırma başarımını göstermek amacı ile DVM sınıflandırma yöntemi RTF çekirdeği ile kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma için bire-bir çok sınıflı sınıflandırma yöntemi kullanılmıştır. Deneylede, DVM ceza parametresi C [10-1000] arasında ve RTF gamma parametresi [0.1-2] arasında değerler alacak şekilde 5 katlı çapraz geçerlilik kullanılarak belirlenmiştir. Deneysel sonuçlar, her bir sınıf için toplam verinin %5 ve %10'u eğitim verisi alınarak elde edilmiştir.

Önerilen birinci ve ikinci yaklaşımın sınıflandırma başarımları sadece orijinal eğitim verilerinin DVM sınıflandırmada kullanılması sonuçları ile karşılaştırılmıştır. Tablo

9.1 karşılaştırma sonuçlarını göstermektedir. Deneysel sonuçlar önerilen örnek aradeğerleme yaklaşımlarının sınıflandırma başarımını arttırdığını göstermektedir. Ayrıca sonuçlar, eğitim örneklerine rasgele Gauss gürültüsü eklenmesiyle eğitim örneklerinin arttırılması ve yeni verinin DVM sınıflandırılması sonuçları ile de karşılaştırılmıştır. Rasgele gürültü, farklı değişinti değerlerinde sıfır ortalamalı Gauss dağılımı kullanılarak elde edilmiştir. Bu yöntemin sınıflandırma başarımı orijinal eğitim verisinin DVM sınıflandırılması sonuçları ile neredeyse benzerdir. Bu nedenle, önerilen örnek aradeğerleme yöntemlerinin eğitim verisini arttırmada daha başarılı olduğu görülmektedir.

Önerilen çalışmalar ile DVM sınıflandırma başarımının düşük sayıda eğitim verisi durumunda örnek aradeğerleme temelli eğitim verisi arttırma yöntemi kullanılarak arttırılması gerçekleştirilmiştir. Deneysel sonuçlar önerilen yöntemin başarısını onaylamaktadır.

Tablo 9.1: Indian Pine görüntüsünde %5 ve %10 eğitim verisi oranı (EVO) kullanılarak elde edilen standart DVM, önerilen 1. aradeğerleme yaklaşımı ve 2. örnek aradeğerleme yaklaşımı sınıflandırma başarımları (SB)

Yöntem	%5 EVO	% 10 EVO
DVM	79.72	83.82
1. önerilen yaklaşım	80.90	84.15
2. önerilen yaklaşım	79.97	83.97

9.4. Vargılar

Eğitim verisinin miktarının özgün ve gerçekleştirilmesi basit bir örnek aradeğerleme yöntemi ile yapay olarak arttırılarak sınıflandırma başarımını olumsuz yönde etkileyen yüksek miktardaki boyut probleminin (yani Hughes olgusu) etkisinin azaltılabileceği gösterilmiştir. Bu nedenle sınıflandırma başarımında artma gözlemlenmiştir. Sınıflandırma başarımındaki artış çok yüksek olmamakla beraber özellikle çok düşük başlangıç eğitim verileri olması durumunda istatistiksel olarak başarılıdır. Ayrıca örnek aradeğerleme ile eğitim verisinin arttırılması yönteminin her bir eğitim verisi örneğine gürültü ekleyerek eğitim verisinin arttırılması yöntemine göre daha başarılı olduğu gözlemlenmiştir.

10. SPEKTRAL BÜKME İLE SINIFLANDIRMA BAŞARIMININ ARTTIRILMASI

10.1. GÜDÜLENME

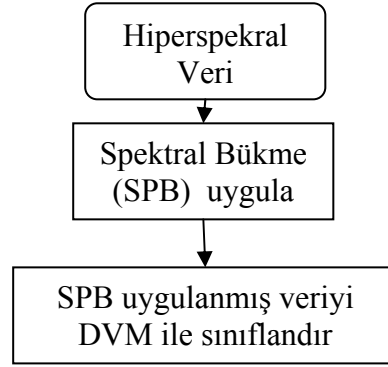
Frekans bükme olarak da bilinen spektral bükme (SPB) ile işaretin frekans bileşenleri eğrilmektedir ve ilk olarak [93, 94]'de Oppenheim ve ekibi tarafından önerilmiştir. SPB işaretin frekans bileşenlerinin frekans eksenini boyunca eğriltmesini sağlayan bir sinyal işleme yöntemidir. SPB ile işaretin frekans bileşenleri frekansta yayılırken, işaret zaman uzayında daralmaktadır. Bu nedenle spektral bükme sonucunda işaretlerdeki enerji ilk zaman örneklerinde toplanmaktadır. Bu bölümde her bir spektral verideki enerjinin ilk bantlarda toplanmasını sağlayan SPB yönteminin hiperspektral verilerdeki her bir spektral veriye uygulanması önerilmektedir. Bu sayede, yani enerjinin ilk bantlarda toplanması nedeniyle, sınıflandırma başarımını düşüren yüksek miktardaki boyut problemi (yani, Hughes olgusu) etkisinin azaltılması ve bunun sonucunda hiperspektral görüntülerin sınıflandırma başarımının artması hedeflenmektedir.

SPB birçok işaret işleme uygulamalarında kullanım alanı bulmuştur [93-104]. Konuşma işaretinin uyarlamalı olarak iyileştirilmesi amacı ile [95]'de ve konuşmacı düzgeleme (speaker normalization) amacı ile [96]'da önerilmiştir. [96]'da önerilen yöntem ile konuşma tanıma uygulamalarındaki başarımların düşüşü frekans bükme kullanılarak azaltılmıştır. İkinci dalgacıkların (dyadic wavelets) spektral eğriltmiş dalgacıkları içerecek şekilde genişletilmesi üzerine [97]'de çalışılmıştır. SPB yönteminin analog ve karma işaret testi uygulamalarında kullanımı [98]'de ve matris formülasyonu ile çözümü [99]'de önerilmiştir. Değişken frekans bükme süzgeçlerinin ayrık kosinüs dönüşümüne uygulanmasıyla konuşma işaretinin iyileştirilmesi [100]'de sağlanmıştır. [101]'de ise isteğe bağlı frekans eksenini biçimlendirme temelli frekans bükme yöntemi önerilmiştir. İmgelerin sıkıştırılması amacıyla eğriltmiş ayrık kosinüs dönüşümü [102]'de, eğriltmiş ayrık kosinüs

dönüşümü temelli blok kodlama yöntemi ise [103]'de önerilmiştir. SPB yöntemin hiperspektral görüntülerde kullanılması üzerine ise ilk defa bu tez kapsamında çalışılmıştır.

10.2. Spektral Bükme ve Önerilen Yöntem


Bu bölümde önerilen çalışmada ilk olarak SPB yöntemi hiperspektral görüntüdeki her bir spektral veriye uygulanmakta ve sonrasında SPB uygulanmış veri DVM ile sınıflandırılmaktadır. Şekil 10.1'de gerçekleştirilen algoritmanın akış şeması verilmektedir.



Şekil 10.1: Gerçekleştirilen algoritmanın akış şeması

Spektral bükme (SPB) işleminde, frekans bileşenleri, spektral ekseninde doğrusal olmayan şekilde değiştirilmektedir ve bu işlem, birinci dereceden seri süzgeçler kullanılarak elde edilmektedir. Şekil 10.2'de her bir spektral veriye uygulanan spektral bükme ağı gösterilmektedir. Burada a spektral bükme parametresidir ve süzgeçlerin kararlı olabilmesi için spektral bükme parametresi $-1 < a < 1$ olmalıdır. Spektral bükme ağına göre ilk olarak giriş işareti \mathbf{x} zamanda terslenerek ilk süzgece uygulanmaktadır ve çıkış verisinin son örneği, bükme işlemi uygulanan yeni verinin ilk örneğini ($\mathbf{x}^{yeni}[1]$) oluşturmaktadır. Sonrasında süzgeçlenmiş veri, ikinci süzgece uygulanmaktadır ve elde edilen verinin son örneği, çıkış verisinin bir sonraki örnek değeri ($\mathbf{x}^{yeni}[2]$) olarak alınmaktadır. Bu işlemler spektral bükme ağındaki her bir süzgeç için gerçekleştirilmektedir. İlk iki süzgeç hariç diğer süzgeçler tüm geçiren

süzgeçlerdir. Süzgeç sayısı spektral bükme uygulanacak verinin öznitelik sayısına eşittir.




Şekil 10.2: Spektral bükme ağı

Spektral bükme ağında birinci ve ikinci süzgeçler $a > 0$ iken alçak geçiren süzgeç ve $a < 0$ iken yüksek geçiren süzgeç özelliği göstermektedir ve diğer süzgeçler tüm geçiren süzgeçlerdir. Birinci süzgecin transfer fonksiyonu $H_1(z) = \frac{1}{1-az^{-1}}$ 'dir ve $z^{-1} = \cos \Omega n - j \sin \Omega n$ yazılır ise frekans yanıtı denklem (10.1) ile ifade edilmektedir.

$$H_1(e^{j\Omega}) = \frac{1 - a \cos \Omega n - ja \sin \Omega n}{1 - 2a \cos \Omega n + a^2} \quad (10.1)$$

SPB ağındaki birinci süzgecin genlik ve faz yanıtı ise denklem (10.2) ile ifade edilmekte ve Şekil 10.3'de gösterilmektedir (spektral bükme parametresi $a=0.3$ iken elde edilmiştir).

$$\begin{aligned} |H_1(e^{j\Omega})| &= \frac{1}{\sqrt{1 - 2a \cos \Omega n + a^2}} \\ \angle H_1(e^{j\Omega}) &= -\tan^{-1} \left[\frac{a \sin \Omega n}{1 - a \cos \Omega n} \right] \end{aligned} \quad (10.2)$$




Şekil 10.3: SPB ağındaki ilk süzgecin genlik ve faz yanıtı

İlk iki süzgeci içeren sistemin transfer fonksiyonu $H_{12}(z) = \frac{(1-a^2)z^{-1}}{(1-az^{-1})^2}$ 'dir ve sistemin frekans yanıtı, genlik ve faz spektrumları ile beraber denklem (10.3) ile ifade edilmektedir. Şekil 10.4'de ikinci süzgecin genlik ve faz yanıtları, Şekil 10.4'de ise ilk iki süzgeci içeren sistemin genlik ve faz yanıtları gösterilmektedir (spektral bükme parametresi $a=0.3$ iken elde edilmiştir).


$$H_{12}(e^{j\Omega}) = \frac{(1-a^2)((1-a^2)\cos\Omega n - 2a - j(1-a^2)\sin\Omega n)}{(1-2a\cos\Omega n + a^2)^2}$$

$$|H_{12}(e^{j\Omega})| = \frac{1-a^2}{1-2a\cos\Omega n + a^2} \quad (10.3)$$

$$\angle H_{12}(e^{j\Omega}) = -\tan^{-1} \left[\frac{(1-a^2)\sin\Omega n}{(1+a^2)\cos\Omega n - 2a} \right]$$



Şekil 10.4: SPB ağındaki ikinci süzgecin genlik ve faz yanıtı




Şekil 10.5: SPB ağındaki ilk iki süzgeç ile oluşan sistemin genlik ve faz yanıtı

SPB ağındaki ilk iki süzgeç $a > 0$ için alçak geçiren süzgeç, $a < 0$ için yüksek geçiren süzgeç özelliği göstermektedir ve bükme sonrasında frekans bileşenlerinin çakışmasını (frekansta örtüşmeyi) önlemek amacıyla kullanılmaktadır. Ağıdaki diğer süzgeçler ise transfer fonksiyonu $H_i(z) = \frac{z^{-1} - a}{1 - az^{-1}}, i = 3, \dots, d$ (burada d toplam süzgeç sayısını yani verinin toplam bant sayısını göstermektedir) olan tüm geçiren süzgeçlerdir ve bu süzgecin genlik ve faz yanıtları denklem (10.4) ile ifade edilmektedir. Şekil 10.6'de bu süzgeç için, spektral bükme parametresi $a = 0.3$ iken elde edilen genlik ve faz spektrumları gösterilmektedir.

$$|H_i(e^{j\Omega})| = 1$$

$$\angle H_i(e^{j\Omega}) = -\tan^{-1} \left[\frac{(1 - a^2) \sin \Omega n}{(1 + a^2) \cos \Omega n - 2a} \right] \quad (10.4)$$



Şekil 10.6: SPB ağındaki tüm geçiren süzgecin genlik ve faz yanıtı

Tüm geçiren süzgeçlerin genlik yanıtı bütün frekanslar için birim genlikte olduğundan tüm frekans bileşenleri genliklerinde bir değişim olmadan

geçirilmektedir. Tüm geçiren süzgeçlerde, sistem kutuplarının ve sıfırlarının uygun bir şekilde yerleştirilmesi sonucu istenen faz yanıtı elde edilmektedir. Doğrusal bir faz etkisi işarette zaman gecikmesi haricinde bir değişime sebep olmamaktadır. Sistemin faz yanıtı tam doğrusal olmasa dahi, doğrusala yeteri kadar yakın ise işarette meydana gelen bozulmalar ihmal edilebilecek düzeyde kalmaktadır. Denklem (10.4) ve denklem (10.3)'den görüldüğü üzere ilk iki süzgece ait sistemin faz yanıtı, tüm geçiren süzgecin faz yanıtına eşittir. Tüm SPB ağının genlik ve faz spektrumları denklem (10.5)'de gösterilmektedir.

$$\begin{aligned} |H_{SE}(e^{j\Omega})| &= \frac{1-a^2}{1-2a \cos \Omega n + a^2} \\ \angle \theta_{SE}(\Omega) &= -(d-1) \tan^{-1} \left[\frac{(1-a^2) \sin \Omega n}{(1+a^2) \cos \Omega n - 2a} \right] \end{aligned} \quad (10.5)$$


Bu tez çalışmasında SPB yönteminin hiperspektral görüntülerin her bir pikseli ile ilişkili spektral verilere (spektral imza) uygulanması önerilmiştir. Örnek bir spektral veri ve bu verinin farklı spektral bükme parametrelerinde eğriltmiş ifadeleri Şekil 10.7 ve Şekil 10.8'de gösterilmektedir. Şekillerden görüldüğü üzere spektral bükme parametresinin değerinin artırılması ile verinin önemli bir bölümü ilk bantlarda toplanmaktadır. Bunun nedeni sistemin kutuplarının konumları incelenerek açıklanabilir. Tüm geçiren süzgecin transfer yanıtından görüldüğü üzere sistemin $z = a$ konumunda bir adet kutbu bulunmaktadır. a 'nın 0'a yakın değerlerde seçilmesi sonucu faz yanıtı doğrusala yakın olmaktadır. a 'nın 1'e yaklaşması sonucu doğrusallıktan uzaklaşmaktadır ve bunun sonucu olarak işaretteki öteleme miktarı artmaktadır. Öteleme miktarının artması sonucu işaretin büyük bir bölümü ilk bantta toplanmakta ve son bantların değerleri 0'a çok yakın olarak elde edilmektedir.

Spektral bükme parametresi a 'nın 0'dan küçük değerlerinde, spektral bükme ağındaki ilk iki süzgeç yüksek geçiren süzgeç özelliği göstermekte ve spektral bükme işlemi sonucunda yüksek frekans bileşenleri düşük frekanslara doğru yayılmaktadır. Spektral bükme parametresi a 'nın 0'dan büyük değerlerinde, spektral bükme ağındaki ilk iki süzgeç alçak geçiren süzgeç özelliği göstermekte ve spektral bükme işlemi sonucunda alçak frekans bileşenleri yüksek frekanslara doğru yayılmaktadır.


Farklı bükme parametrelerinde eğriltilmiş bir spektral verinin ayrık Fourier dönüşümü (AFD) sonuçları Şekil 10.9 ve Şekil 10.10'da gösterilmektedir.

SPB uygulanmış işareti yeniden elde edebilmek amacıyla SPB sonucu oluşan işaretin $-a$ ile SPB işlemine sokulması gerekmektedir. Geri oluşan işaretin genel yapısı orijinal işarete benzemekle birlikte, ilk iki süzgecin alçak geçiren veya yüksek geçiren süzgeç özelliği göstermesi nedeniyle geri elde edilen işaretin genlik değerlerinde değişim gözlenmektedir. Şekil 10.11'de örnek bir spektral imzanın $a = 0.8$ parametresi ile eğriltildikten sonra geri çatılması sonucu gösterilmektedir.


Bu bölümde önerilen çalışmada ilk olarak SPB yöntemi her bir spektral veriye uygulanmakta ve sonrasında SPB uygulanmış veri DVM ile sınıflandırılmaktadır. Farklı bükme parametreleri için sonuçlar değerlendirilmektedir. Ayrıca işaretin büyük bir bölümünün ilk bantlarda toplanması ve son bantlardaki değerlerin 0'a çok yakın olması sonucu, bu bantların elenerek düşük bant sayısı üzerinden sınıflandırma yapılması sonuçları da incelenmektedir. Elenecek bant sayısı ve spektral bükme parametresi arasındaki ilişki deneysel sonuçlar ile gösterilmektedir.



(a)

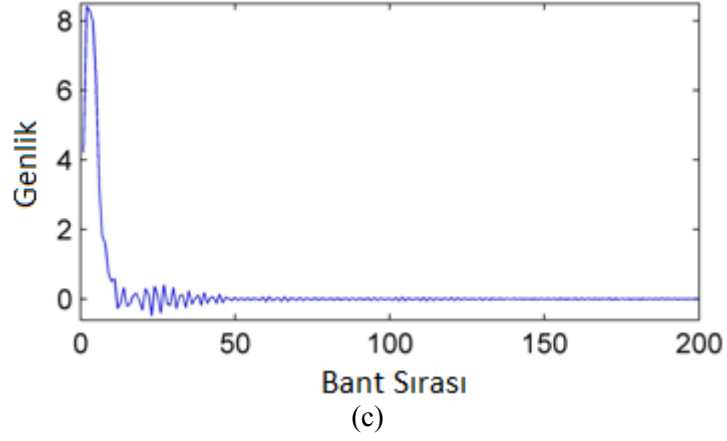




(b)




(c)


Şekil 10.7: (a) orijinal işaret, (b) $a=0.1$ iken bükülmüş işaret , (c) $a=0.3$ iken bükülmüş işaret




Şekil 10.8: Şekil 10.7’de gösterilen orijinal verinin (a) $a=0.5$ iken bükülmüş işaret , (b) $a=0.7$ iken eğriltilmiş işaret , (c) $a=0.9$ iken bükülmüş işaret



(a)




(b)




(c)


Şekil 10.9: (a) orijinal veri, (b) $a = 0.3$ ile bükülmüş veri ve (c) $a = -0.3$ ile bükülmüş veri için AFD sonuçları



(a)




(b)



(c)

Şekil 10.10: (a) orijinal veri, (b) $a = 0.8$ ile bükülmüş veri ve (c) $a = -0.8$ ile bükülmüş veri için AFD sonuçları



Şekil 10.11: Orijinal ve geri çatılmış spektral veri

10.3. Deneysel Sonuçlar

Sınıflandırma sonuçları farklı bükme parametreleri için, Indian Pine hiperspektral görüntüsü kullanılarak elde edilmiştir. Her bir sınıf için toplam verinin %50'si ve %10'u eğitim verisi olarak alınmıştır. DVM sınıflandırma için RTF çekirdeği kullanılmıştır. Hızlı eğitim süresi sağladığı için çok sınıflı DVM sınıflandırma bire-bir çok sınıflı sınıflandırma yöntemi kullanılarak gerçekleştirilmiştir. Farklı bükme parametreleri kullanılarak gerçekleştirilen SPB işlemi sonucunda elde edilen yeni hiperspektral verinin DVM sınıflandırma başarımları Indian Pine verisi için Tablo 10.1'de gösterilmektedir. Sonuçlar $a < 0$ iken sınıflandırma başarımının düşük olması nedeniyle sadece $a > 0$ için verilmiştir. $a < 0$ iken sınıflandırma sonuçlarının düşük olması şu şekilde yorumlanabilir: kullanılan spektral veriler düşük frekansları içermektedir ve $a < 0$ iken ilk iki süzgecin yüksek geçiren süzgeç özelliği göstermesi nedeniyle düşük frekanslar bastırılmaktadır. Bunun sonucu olarak spektral bükme işlemi ile yüksek frekanslar düşük frekanslara doğru yayılmakta ve bu da sınıflandırma başarımını düşürmektedir.

Deneysel sonuçlar uygun bükme parametreleri kullanılarak sınıflandırma başarımının önemli oranda artırılabilceğini göstermektedir. Sınıflandırma başarımının artırılması şu şekilde yorumlanabilir: Bilindiği üzere eğitim verisi ve toplam spektral bant sayısı arasındaki oran sınıflandırma başarımını etkilemektedir ve büyük miktardaki spektral bant sayısı ve düşük miktardaki etiketlenmiş eğitim kümesi,

yüksek miktardaki boyut problemine (yani, Hughes olgusu) sebep olmaktadır ve bunun sonucu olarak sınıflandırma başarımı düşmektedir. Bir önceki bölümde bahsedildiği üzere spektral imzalara SE uygulanması sonucu işaretler sola dayalı hale gelmekte ve son bazı bantların piksel değerleri 0 olmaktadır. Bu durumda düşük bant sayısında DVM sınıflandırma yapılarak Hughes olgusunun etkisi azalmakta ve sınıflandırma başarımı artmaktadır. Deneysel sonuçlar sınıflandırma başarımının %10 eğitim verisi oranı durumunda %3, %50 eğitim verisi oranında ise %1 arttırılabileceğini göstermektedir. %10 eğitim verisi için en iyi sonuç $a = 0.5$ iken, %50 eğitim verisi için ise $a = 0.6$ iken elde edilmiştir.

SPB sonucu birçok bant değerinin 0'a çok yakın değerler alması nedeniyle bu bantların elenerek oluşan düşük bantlı verinin DVM sonuçları elde edilmiştir. Sonuçlar Indian Pine verisi için elde edilmiştir ve %10 eğitim verisi durumunda $a = 0.5, 0.9$, %50 eğitim verisi durumunda $a = 0.6, 0.9$ seçilmiştir. Farklı bant sayılarındaki sınıflandırma başarımları Indian Pine verisi için Tablo 10.2'de verilmiştir. Sonuçlardan görüldüğü üzere %10 eğitim verisi durumunda, $a = 0.6$ iken, bant sayısı %50 azaltıldığında tüm bantların kullanıldığı duruma göre çok yakın sınıflandırma başarımı elde edilmiştir. Benzer şekilde %50 eğitim verisi durumunda, $a = 0.5$ iken, bant sayısı %50 azaltıldığında elde edilen sınıflandırma başarımı, tüm bantların kullanıldığında elde edilen başarımla çok yakındır. Ayrıca daha yüksek miktarda etkili bant azaltımı yapabilmek için bükme parametresinin değerinin arttırılması gerekmektedir. Örneğin tablodan görüldüğü üzere 30 bant kullanılmak istendiğinde, %10 eğitim verisi durumunda, $a = 0.6$ iken başarımlar 79.42, $a = 0.9$ iken başarımlar 91.22'dir. Ayrıca %50 eğitim verisi durumunda, $a = 0.5$ iken başarımlar 82.94, $a = 0.9$ iken başarımlar 92.29'dur. Deneysel sonuçlar SE yönteminin hiperspektral görüntülerdeki sınıflandırma başarımını arttırdığını göstermektedir.

Ayrıca SPB temelli bant azaltımı yöntemi, TBA bant çıkarımı yöntemi ve standart örnek seyreltme yaklaşımı ile karşılaştırılmıştır ve farklı bant sayılarında (BS) elde edilen sonuçlar Tablo 10.3'de verilmiştir. Sonuçlar %10 eğitim verisi oranı kullanılarak elde edilmiştir ve düşük bant sayılarında önerilen yöntem için $a = 0.9$ olarak seçilmiştir. Kullanılan a değerleri tablolarda belirtilmiştir. Örnek seyreltme için ise çift doğrusal örnek seyreltme (ÇDS) yaklaşımı kullanılmıştır. Tüm

sonuçlarda önerilen yöntemin ÇDA ve TBA temelli bant azaltımı yöntemlerinden daha iyi başarımlar sağladığı görülmektedir.

Tablo 10.1: Indian Pine verisi için farklı Spektral Bükme Parametrelerinde (SBP) %10 ve %50 eğitim verisi oranı (EVO) kullanılarak elde edilen DVM Sınıflandırma Başarımları (SB)

SBP	%10 EVO	%50 EVO
	SB	SB
0	82.24	92.57
0.1	83.02	93.14
0.2	84.20	93.25
0.3	84.83	93.62
0.4	85.15	93.79
0.5	85.23	93.79
0.6	85.16	93.96
0.7	85.01	93.81
0.8	84.22	93.62
0.9	83.16	92.76

Tablo 10.2: Indian Pine verisi için spektral bükme temelli bant eleme sonrası farklı Bant Sayılarında (BS) Sınıflandırma Başarımları (SB)

BS	SB			
	%10 EVO	%10 EVO	%50 EVO	%50 EVO
	$a=0.5$	$a=0.9$	$a=0.6$	$a=0.9$
200	85.23	83.16	93.96	92.76
150	85.23	83.16	93.94	92.67
100	85.21	83.12	93.89	92.65
50	83.29	83.01	93.70	92.57
40	81.72	83.00	93.51	92.46
35	80.61	83.02	92.57	92.42
30	79.42	82.94	91.22	92.29

Tablo 10.3: Indian Pine verisi için SPB temelli bant azaltımı sonrası DVM (SPB-BA-DVM), TBA sonrası DVM (TBA-DVM) ve ÇDS sonrası DVM (ÇDS-DVM) sonuçları

BS	SPB-BA-DVM	TBA-DVM	ÇDS-DVM
150	85.23($a=0.6$)	76.43	81.89
100	85.21($a=0.6$)	76.43	80.32
50	83.29($a=0.6$)	76.40	78.24
40	83.00($a=0.9$)	76.32	77.30
30	82.94($a=0.9$)	76.26	75.47
20	82.75($a=0.9$)	76.00	71.73
10	80.54($a=0.9$)	74.58	60.36
5	69.03($a=0.9$)	64.44	52.33

10.4. Vargılar

İşaretlerin frekans bileşenlerini frekansta yayan ve bu nedenle zaman uzayında işareti daraltan spektral bükme yönteminin hiperspektral görüntülerde yüksek boyut probleminin (Hughes olgusu) etkisini azalttığı ve bunun sonucunda DVM sınıflandırma başarımını arttırdığı gösterilmiştir. Hiperspektral görüntülerde her bir spektral veriye spektral bükme uygulanması sonucu işarettaki enerjinin ilk bantlarda toplanması nedeniyle yüksek boyut probleminin etkisi azalmıştır ve bu da sınıflandırma başarımının iyileşmesine neden olmaktadır. Ayrıca spektral bükme sonrası son bazı bant değerlerinin sıfıra yakın olması nedeniyle bu bantların elenebilir olduğu gösterilmiştir. Bu nedenle düşük bant sayısı üzerinden DVM sınıflandırma (test) yapıldığı için test süresi de hızlanmıştır.

11. VARGILAR

Bu tez çalışması sonucu elde edilen temel vargılar aşağıdaki gibi özetlenebilir.

1-Spektral ve uzamsal bilgileri birlikte kullanabilmek amacı ile özgün AKA temelli yöntemler geliştirilerek sınıflandırma başarımının önemli oranda arttırılabileceği gösterilmiştir. Ayrıca hiperspektral görüntülerdeki her bir bandın piksel değerlerinin satır satır tarama sonucu elde edilmesi sırasında oluşan yerel düşük frekans bileşenlerinin önerilen AKA temelli yöntemler ile veriden arındırılmasının sınıflandırma başarımını arttırdığı gösterilmiştir. Geliştirilen AKA temelli yöntemler ile sınıflar arası uzaklıkların önemli bir oranda arttırılması, satır satır tarama işlemlerinden dolayı oluşan yerel düşük frekansların sınıflandırmaya dahil edilmemesi, sınıf içi değişimlerin azalması nedenleriyle sınıfları zor ayrılabilen (örneğin Indian Pine verisi) hiperspektral verilerin sınıflandırılmasında yüksek başarımlar elde edilmiştir. Geliştirilen yöntemler ile sınıflandırma başarımı önemli oranda artmaktadır. Fakat 2-B AKA'daki 2-B eğri aradeğerlemesi işlemlerinden dolayı 2-B AKA'nın hesapsal yükü özellikle yüksek piksel boyutuna sahip hiperspektral görüntülerde oldukça fazladır [57,58]. Bu nedenle yüksek piksel boyutuna sahip hiperspektral görüntülerde 2-B AKA'ya göre daha az başarılı olan hızlı 2-B AKA [59,60] kullanılması önerilmektedir.

2- Hiperspektral görüntülerdeki iyi yapılandırılmamış bantların 1-BD temelli düşük hesapsal yüke sahip ve donanımsal olarak gerçekleştirilmesi uygun bir bant eleme yöntemi kullanılarak başarılı bir şekilde elenebilirliği gösterilmiştir. Önerilen 1-BD temelli bant eleme yöntemi ile literatürde yaygın olarak kullanılan ve yüksek hesaplama süresine sahip standart bant azaltımı yöntemlerinin hesapsal karmaşıklığı sınıflandırma başarımından ödün vermeden azaltılmıştır. Ayrıca hiperspektral görüntülerin renkli görüntülenmesi amacıyla özgün 1-BD temelli bir yöntem geliştirilmiştir. Bu tez çalışmasında geliştirilen 1-BD temelli yaklaşımlar bu yöntemlerin donanımsal olarak gerçekleştirilebilirliği açısından önemlidir ve bu tez

kapsamında geliştirilen 1-BD yöntemlerinin FPGA ile gerçekleştirilmesi üzerine [117]'de çalışılmıştır.

3- Sınıfları birbirinden ayıran ayırtaç düzlemlerine yakın olan eğitim verileri (sınır eğitim örnekleri) özgün toplama temelli bir yöntem kullanılarak elde edilmiştir. Sınır eğitim örneklerinin DVM eğitim aşamasında kullanılarak DVM sınıflandırma başarımının artırılacağı gösterilmiştir. Geliştirilen bu yöntem ile sınıflandırma başarımı artmakla beraber eğitim aşamasının iki kere yapılması nedeniyle DVM eğitim aşamasındaki hesaplanma süresi artmaktadır.

4- Hiperspektral görüntülerin sınıflandırılmasında uzamsal ve spektral bilgilerin birlikte kullanılması amacıyla çok-çözünürlüklü yapılar kullanan özgün bir yöntem geliştirilmiştir. Önerilen yöntem ile uzamsal ve spektral bilgiler sıradüzensel bir yaklaşım ile bir arada kullanılarak DVM sınıflandırma başarımı önemli oranda iyileştirilmiştir. Ayrıca DVM ile sınıflandırma (test) aşamasının sıradüzensel bir yapı kullanılarak gerçekleştirilmesi sonucu sınıflandırma süresi hızlanarak hızlı bir sınıflandırma yöntemi geliştirilmiştir.

5- Hiperspektral görüntülerde benzerlik uygulamaları için faz ilintisi yönteminin standart çapraz ilintiye göre daha uygun olduğu gösterilmiştir. Bu tez çalışmasında önerilen çalışmalarla spektral verilerde faz ilintisi ile benzerliğin ölçülmesi temelli bir eğitilmiş sınıflandırma yöntemi ve ayrıca bantlar arası benzerliğin faz ilintisi ile ölçülerek artık bantların elenmesi temelli bir bant azaltımı yöntemi geliştirilmiştir.

6- Spektral türev özniteliklerinin atmosferik ve aydınlatma etkilerinden dolayı meydana gelen değişikliklerden etkilenmediği literatürdeki çalışmalarda gösterilmiştir. Bu tez çalışmasında özgün olarak geliştirilen yöntemler ile spektral türev özniteliklerinin hiperspektral görüntülerin sınıflandırılmasında genlik öznitelikleriyle beraber kullanılarak DVM sınıflandırma başarımının artırılacağı gösterilmiştir.

7-Eğitim verisinin miktarı örnek aradeğerleme yöntemi ile yapay olarak artırılarak sınıflandırma başarımını olumsuz yönde etkileyen yüksek miktardaki boyut probleminin (yani Hughes olgusu) etkisinin azaltılabileceği ve bunun sonucunda


DVM sınıflandırma başarımının artırılabilceği gösterilmiştir. Sınıflandırma başarımındaki artış çok yüksek olmamakla beraber özellikle çok düşük başlangıç eğitim verileri olması durumunda istatistiksel olarak başarılıdır.

8-Yüksek miktardaki bant sayısı ve düşük miktardaki eğitimli örnek sayısının sebep olduğu yüksek miktardaki boyut probleminin (yani Hughes olgusu) etkisinin spektral bükme yöntemi kullanılarak azaltılabileceği gösterilmiştir. Geliştirilen spektral bükme temelli özgün yöntem sayesinde DVM sınıflandırma başarımı önemli oranda artmıştır .

11.1. Geliştirilen Yöntemlerin Hesaplanma Süreleri ve Sınıflandırma Başarımlarının Değerlendirilmesi


Bu alt bölümde tez kapsamında gerçekleştirilen tüm çalışmaların Indian Pine verisi için elde edilen sınıflandırma başarımları ve hesaplanma süreleri birbirleriyle karşılaştırılmaktadır. Karşılaştırma iki farklı kategoride yapılmaktadır. Öncelikle yöntemlerin hesaplanma süreleri eğitim ve test aşamaları için harcanan toplam zaman birlikte değerlendirilerek incelenmektedir. Bu amaçla Şekil 11.1’de tüm yöntemlerin sınıflandırma sonuçları, ve hesaplanma süreleri gösterilmektedir. Şekilleri yorumlamada kolaylık olması açısından Tablo 11.1’de her bir yöntemin kısa isimleri ve açıklamaları verilmektedir. Bu şekilde eğitim ve test işlemlerinde harcanan toplam hesaplanma süreleri işlemcinin her bir piksel için saniyede harcadığı süre olarak gösterilmektedir. Şekilden görüldüğü üzere önerilen yöntemler arasında en iyi sınıflandırma başarımları AKA temelli yöntemler ile elde edilmiştir ve tüm AKA temelli yöntemlerin diğer önerilen yöntemlerden çok daha iyi başarımlar sağladığı gösterilmiştir. En yüksek sınıflandırma başarımı AKA temelli karar tümleştirme yöntemi (AKA-Tüm) ile elde edilmiştir. AKA-Tüm yönteminin hesaplanma süresinin diğer AKA temelli yöntemlerden fazla olmasının sebebi farklı veri seti tanımlamalarının ayrı ayrı sınıflandırıldıktan sonra sınıflandırma sonuçlarının tümleştirilmesidir. 2-B AKA’nın hesaplanma süresi 2-B eğri aradeğerlemesi işlemlerinden dolayı fazladır. Hızlı 2-B AKA kullanılarak sınıflandırma başarımı 2-B AKA kullanılması durumuna göre düşsede, 2-B AKA temelli yöntemlerden sonra tez kapsamında geliştirilen en yüksek başarımlar sağlayan ikinci yöntemdir. Bu nedenle

yüksek çözünürlüklü hiperspektral veriler için daha düşük sınıflandırma başarımı sağlayan ve eğri aradeğerlemesi yerine istatistiksel süzgeçler kullandığı için daha hızlı çalışan hızlı 2-B AKA kullanılması önerilmektedir. Sınıflandırma başarımını arttırmak için geliştirilen diğer yöntemler (SBP-DVM, SEÖ-DVM, GÖ+TÖ1, ÖA-DVM, ÇÇ-DVM) ile doğrudan DVM'ye göre sınıflandırma başarımını artmıştır. ÇÇ-DVM en yüksek sınıflandırma başarımı sağlayan 3. yöntemdir ve hesaplanma süresi 2-B AKA temelli yöntemlerden oldukça düşük olmakla beraber hızlı 2-B AKA yönteminin hesaplanma süresine çok yakındır. Geliştirilen bant azaltımı yöntemleri (1-BD-EHT, ÖA-Fİ, SPB-BA, TBA-GÖ+TÖ1+TÖ2) ile artıklık bantların elenmesi sonucu sınıflandırma (test) süreleri azalsada elde edilen sınıflandırma başarımları büyük artış gösterememektedir. Geliştirilen bant azaltımı yöntemleri arasında hesaplanma süresi (eğitim+test) en az olan yöntem faz ilintisi temelli öznetelik azaltımı (ÖA-Fİ) yöntemidir, fakat bu yöntemin sınıflandırma başarımı diğer öznetelik azaltımı yöntemlerinden düşüktür. Bant seçme yöntemleri arasında en iyi başarımların 1-BD sonrası En Hızlı Tırmanış (1-BD-EHT) yöntemi ile elde edilmektedir. Fakat 1-BD-EHT yönteminin hesaplanma süresi ÖA-Fİ yönteminden yüksektir. Bant çıkarımı yöntemleri arasında ise en iyi başarımların spektral bükme temelli bant azaltımı (SPB-BA) yöntemi ile elde edilmektedir.



Şekil 11.1: Geliştirilen tüm yöntemlerin sınıflandırma başarımları ve DVM eğitim ve test aşamalarında harcanan toplam hesaplanma süreleri

Şekil 11.2’de tüm yöntemlerin sınıflandırma sonuçları sadece DVM test aşamasında harcanan hesaplanma süreleri ile beraber gösterilmektedir. Test aşamasında harcanan hesaplanma süreleri bant azaltımı yöntemlerinde düşük olmakla beraber bu yöntemlerin sınıflandırma başarımlarında doğrudan DVM ile karşılaştırıldığında önemli miktarda bir iyileşme görülmemektedir. Bant azaltımı yöntemlerinde düşük bantlı veriler üzerinden DVM sınıflandırma yapıldığı için test (sınıflandırma) süresi düşmektedir. Diğer yöntemlerin (bant azaltımı kullanmayan) test süreleri tümleştirme temelli DVM (AKA-Tüm) ve çok çözünürlüklü DVM (ÇÇ-DVM) hariç doğrudan DVM test süresine yakındır. ÇÇ-DVM ile test süresi sıradüzensel bir yapı üzerinden sınıflandırma yapılması nedeniyle düşüktür. AKA-Tüm ile ise birden fazla veri tanımlaması DVM ile sınıflandırıldıktan sonra karar tümleştirilmesi uygulanması nedeniyle sınıflandırma (test) süresi yüksektir. En yüksek DVM sınıflandırma başarımları AKA-Tüm ile elde edilmektedir ve bu yöntemin sınıflandırma süresi diğer yöntemlere göre daha fazladır.



Şekil 11.2: Geliştirilen tüm yöntemlerin sınıflandırma başarımları ve DVM test aşamalarında harcanan toplam hesaplanma süreleri

Tablo 11.1: Geliştirilen tüm yöntemlerin kısa isimleri ve bu yöntemlerin kısa açıklamaları

Yöntem	Yöntemin Açıklaması
DVM	Doğrudan DVM sınıflandırma
2B-AKA-DVM	2-B AKA ile DVM sınıflandırma
H-2B-AKA-DVM	Hızlı 2-B AKA ile DVM sınıflandırma
D-2B-AKA-DVM	1. İKF'ye dalgacık uzayında gürültü giderimi uygulandıktan sonra 2B-AKA-DVM ile sınıflandırılması
AKA-BÇ-DVM	2-B AKA temelli birleşik çekirdek
AKA-Tüm	AKA temelli karar tümleştirme yöntemi
SEÖ-DVM	Sınır eğitim örneklerinin çıkarımı temelli DVM sınıflandırma
ÇÇ-DVM	Çok çözünürlüklü DVM sınıflandırma
GÖ-TÖ1	Genlik öznitellikleri ve 1. türev öznitelliklerinin ardı ardına eklenmesi sonrası DVM sınıflandırma
ÖA-DVM	Örnek aradeğerleme ile eğitim verisi artırma yöntemi sonrası DVM sınıflandırma
SPB-DVM	Spektral bükme sonrası DVM sınıflandırma
1-BD-EHT	1-BD sonrası en hızlı tırmanış bant azaltımı
ÖA-Fİ	Faz ilintisi temelli öznitelik azaltımı
SPB-BA	Spektral bükme temelli bant azaltımı sonrası DVM ile sınıflandırma
TBA-GÖ+TÖ1+TÖ2	Genlik, spektral birinci türev ve spektral ikinci türev öznitelliklerinden bant çıkarılması sonrası DVM ile sınıflandırma

11.2. Gelecek Çalışmalar

Eğitilmiş sınıflandırma yöntemlerinin başarımının eğitim verisinin miktarına ve kalitesine bağlı olduğu bilinmektedir. Uzaktan algılama görüntülerinde eğitilmiş veri elde etme işlemi zaman alıcı ve masraflı işlemler gerektirmektedir. Son zamanlarda kullanılmaya başlanılan aktif öğrenme (active learning), ve yarı eğitilmiş sınıflandırma yöntemleri (semi-supervised learning) ile bu problemler azaltılmaya çalışılmaktadır. Gelecek çalışmalarda özgün aktif öğrenme ve yarı eğitilmiş sınıflandırma yöntemleri geliştirilebilir.

Hiperspektral görüntülerin yüksek bant sayısına sahip olması sonucu işlemlerin hesapsal yükü fazla olmaktadır ve bu verilerin saklanması büyük hafıza alanı

gerektirmektedir. Ayrıca ardışık dar dalga boylarında veri yakalandığı için ardışık bantlar arasında ilinti yüksek olmakta ve bunun sonucunda artıklık oluşmaktadır. Bu sebeplerden dolayı bant azaltımı yöntemleri büyük bir önem kazanmaktadır. Fakat DVM gibi yaygın olarak kullanılan sınıflandırma yöntemleri çekirdek uzayında çalışsa da birçok bant azaltımı yöntemi öznelilik uzayında çalışmaktadır. Gelecek çalışmalar olarak çekirdek uzayında çalışan bant azaltımı yöntemleri geliştirilebilir.

KAYNAKLAR

- [1] Landgrebe, D. A., “Signal Theory Methods in Multispectral Remote Sensing”, *John Wiley and Sons*, (2003).
- [2] Dalponte, M., Bruzzone, L., Vescovo, L., Giannelle, D., “The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas”, *Remote Sensing of Environment*, 113, 2345-2355, (2009).
- [3] Swain, P., “Fundamentals of pattern recognition in remote sensing”, *in Remote Sensing: The Quantitative Approach*. New York: McGraw-Hill, 36–188, (1978).
- [4] Civco, D. L., “Artificial neural networks for land-cover classification and mapping”, *Journal of Geographical Information Systems*, 7, 173–186, (1993).
- [5] Dreyer, P., “Classification of land cover using optimized neural nets on SPOT data”, *Photogrammetric Engineering and Remote Sensing*, 59, 617–621, (1993).
- [6] Bischof, H., Leona, A., “Finding optimal neural networks for land use classification”, *IEEE Transactions on Geoscience and Remote Sensing*, 36, 337–341, (1998).
- [7] Yang, H., Van der Meer, F., Bakker, W., Tan, Z. J., “A back-propagation neural network for mineralogical mapping from AVIRIS data”, *International Journal of Remote Sensing*, 20, 97–110, (1999).
- [8] Bruzzone, L., Fernández-Prieto, D., “A technique for the selection of kernel-function parameters in RBF neural networks for classification of remote-sensing images”, *IEEE Transactions on Geoscience and Remote Sensing*, 37, 1179–1184, (1999).
- [9] Giacinto, G., Bruzzone, L., “Combination of neural and statistical algorithms for supervised classification of remote-sensing images”, *Pattern Recognition Letters*, 21, 399–405, (2000).
- [10] Bruzzone, L., Cossu, R., “A multiple-cascade-classifier system for a robust and partially unsupervised updating of land-cover maps”, *IEEE Transactions on Geoscience and Remote Sensing*, 40, 1984–1996, (2002).
- [11] Camps-Valls, G., Bruzzone, L., “Kernel-based methods for hyperspectral image classification”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 1351–1362, (2005).

- [12] Gualtieri, J. A., Crompton, R. F., “Support vector machines for hyperspectral remote sensing classification”, *SPIE 27th Applied Imagery Pattern Recognition Workshop*, 221–232, (1998).
- [13] Gualtieri, J. A., Chettri, S. R., Crompton, R. F., Johnson, L. F., “Support vector machine classifiers as applied to AVIRIS data”, *Airborne Geoscience Workshop*, Feb. (1999).
- [14] Huang, C., Davis, L. S., Townshend J. R. G., “An assessment of support vector machines for land cover classification”, *International Journal of Remote Sensing*, 23, 725–749, (2002).
- [15] Camps-Valls, G., Gómez-Chova, L., Calpe, J., Soria E., Martín, J. D., Alonso, L., Moreno, J., “Robust support vector method for hyperspectral data classification and knowledge discovery”, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1530–1542, (2004).
- [16] Melgani F., Bruzzone, L., “Classification of hyperspectral remotesensing images with support vector machines”, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1778–1790, (2004).
- [17] Mika, S., Rätsch, G., Schölkopf, B., Smola, A., Weston, J., Müller, K.-R., “Invariant Feature Extraction and Classification in Kernel Spaces”, in *Advances in Neural Information Processing Systems*, Cambridge, MA: MIT Press, (1999).
- [18] Dundar M. M., Landgrebe, A., “A cost-effective semisupervised classifier approach with kernels”, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 264–270, (2004).
- [19] Demir, B., Ertürk, S., “Hyperspectral image classification using relevance vector machines”, *IEEE Geoscience and Remote Sensing Letters*, 4, 586-590, (2007).
- [20] Cortes, C., Vapnik, V., “Support vector networks”, *Machine Learning*, 20, 273-297, (1995).
- [21] Ben-Hur, A., Horn, D., Siegelmann, H., Vapnik, V., “Support vector clustering”, *Journal of Machine Learning Research*, 2, 125–137, (2001).
- [22] Rätsch, G., Schölkopf, B., Smola, A., Mika, S., Onoda, T., Müller, K.-R., “Robust Ensemble Learning”, in *Advances in Large Margin Classifiers*, A. Smola, P. Bartlett, B. Schölkopf, and D. Schuurmans, Eds. Cambridge, MA: MIT Press, 207–219, (1999).
- [23] <http://www.kernelmachines.org> (**Ziyaret tarihi: 10 Ocak 2010**).
- [24] Camps-Valls, G., Gómez-Chova, L., Muñoz-María, J., Vila-Francis, J., Calpe-Maravilla, J., “Composite kernels for hyperspectral image classification”, *IEEE Geoscience and Remote Sensing Letters*, 3, 93–97, (2006).

- [25] Benediktsson, J.A., Palmason J.A., Sveinsson, J.R., “Classification of hyperspectral data from urban areas based on extended morphological profiles”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 480-491, (2005).
- [26] Fauvel, M., Benediktsson, J. A., Chanussot J., Sveinsson, J. R., “Spectral and spatial classification of hyperspectral data using SVMs and morphological profile”, *IEEE Transactions on Geoscience and Remote Sensing*, 46, 3804-3814, (2008).
- [27] Farag, A., Mohamed, R., El-Baz, A., “A unified framework for map estimation in remote sensing image segmentation”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 1617-1634, (2005).
- [28] Tarabalka, Y., Chanussot, J., Benediktsson, J. A., Angulo, J., Fauvel, M., “Segmentation and classification of hyperspectral data using watershed”, *IEEE International Geoscience and Remote Sensing Symposium*, Boston, USA, (2008).
- [29] Benediktsson, J.A., Garcia, X.C., Waske, B., Chanussot, J., Sveinsson, J.R., Fauvel, M., “Ensemble methods for classification of hyperspectral data”, *IEEE International Geoscience and Remote Sensing Symposium*, Boston, USA, (2008).
- [30] West, T., Bruce, L. M., “Multiclassifiers and decision fusion in the wavelet domain for exploitation of hyperspectral data”, *IEEE Geoscience and Remote Sensing Symposium*, Barcelona, Spain, (2007).
- [31] Fauvel, M., Chanussot, J., Benediktsson, J. A., “A combined support vector machines classification based on decision fusion”, *IEEE International Geoscience and Remote Sensing Symposium*, (2006).
- [32] Du, Q., “Decision fusion for classifying hyperspectral imagery with high spatial resolution”, *SPIE Newsroom*. DOI: 10.1117/2.1200908.1733, (2009).
- [33] Chen H., Chen, C.H., “Hyperspectral image data unsupervised classification using Gauss-Markov random fields and PCA principle”, *IEEE International Geoscience and Remote Sensing Symposium*, Toronto, Canada, (2002).
- [34] Chiang, S., Chang, C.-I., Ginsberg, I. W., “Unsupervised hyperspectral image analysis using independent component analysis”, *IEEE International Geoscience and Remote Sensing Symposium*, Honolulu, HI, (2000).
- [35] Halldorsson, G.H., Benediktsson, J.A., Sveinsson, J.R., “Source based feature extraction for support vector machines in hyperspectral classification”, *IEEE International Geoscience and Remote Sensing Symposium*, Alaska, USA, (2004).
- [36] Kaewpajit, S., Moigne, J. L., El-Ghazawi, T., “Automatic reduction of hyperspectral imagery using wavelet spectral analysis”, *IEEE Transactions on Geoscience and Remote Sensing*, 41, 863–871, (2003).
- [37] Jimenez-Rodriguez, L. O., Arzuaga-Cruz, E., Velez-Reyes, M., “Unsupervised linear feature-extraction methods and their effects in the classification of high-dimensional data”, *IEEE Transactions on Geoscience and Remote Sensing*, 45, 469–483, (2007).

- [38] Rui, H., Mingyi, H., “Band selection based on feature weighting for classification of hyperspectral data”, *IEEE Geoscience and Remote Sensing Letters*, 2, 156–159, (2005).
- [39] Jain, A., Zongker, D., “Feature selection: Evaluation, application, and small sample performance”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19, 153-189, (1997).
- [40] Smits, P.C., “Comparison of some feature subset selection methods for use in remote sensing image analysis”, *IEEE International Geoscience and Remote Sensing Symposium*, Sydney, Australia, (2001).
- [41] Serpico, S.B., Bruzzone, L., “A new search algorithm for feature selection in hyperspectral remote sensing images”, *IEEE Transactions on Geoscience and Remote Sensing*, 39, 1360–1367, (2001).
- [42] Huang, N. E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N-C., Tung, C.C., Liu, H.H., “The empirical mode decomposition and the hilbert Spectrum for nonlinear and non-stationary time series analysis”, *Proc. R. Soc. London. A.*, 454, 903-995, (1998).
- [43] Natarajan, B., Bhaskaran, V., Konstantinides, K., “Low-complexity block-based motion estimation via one-bit transforms”, *IEEE Transactions on Circuits and Systems for Video Technology*, 7, 702–706, (1997).
- [44] Ertürk S., “Multiplication-Free One-Bit Transform for Low-Complexity Block-Based Motion Estimation”, *IEEE Signal Processing Letters*, 14, 109-112, (2007)
- [45] Urhan, O., Güllü, M. K., Ertürk, S., “Modified phase-correlation based robust hard-cut detection with application to archive film”, *IEEE Transactions on Circuits and Systems for Video Technology*, 16, 753–770, (2006).
- [46] Braccini C., Oppenheim, A. V., “Unequal bandwidth spectral analysis using digital frequency warping”, *IEEE Transactions on Acoustics Speech, Signal Processing*, ASSP-22, 236–244, (1974).
- [47] Landgrebe, D., ‘AVIRIS NW Indiana’s Indian Pines 1992 data set,’<http://dynamo.ecn.purdue.edu/~biehl/MultiSpec/documentation.html>, (**Ziyaret tarihi: 10 Ocak 2010**).
- [48] Ham, J., Chen, Y., Crawford, M. M., Ghosh, J., “Investigation of the random forest framework for classification of hyperspectral data”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 492-501, (2005).
- [49] Dell’Acqua, “Exploiting spectral and spatial information in hyperspectral urban data with high resolution”, *IEEE Geoscience and Remote Sensing Letters*, 1, 322–326, (2004).
- [50] Burges, C., “A tutorial on support vector machines for pattern recognition”, *Data Mining and Knowledge Discovery*, 2, 121–167, (1998).

- [51] Schölkopf, B., Smola, A., “Learning With Kernels”, **Cambridge, MA: MIT Press**, (2002).
- [52] Hsu C.-W., Lin, C.-J., “A comparison of methods for multiclass support vector machines”, **IEEE Transactions on Neural Networks**, 13, 415 - 425, (2002).
- [53] Zhidong, Z., Yang, W., “A new method for processing end effect in empirical mode decomposition”, **International Conference on Communications, Circuits and Systems**, Kokura, Japan, pp. 841-845, (2007).
- [54] Janusauskas, A., Jurkonis, R., Lukosevicius, A., Kurapkiene, S., Paunksnis, A., “The empirical mode decomposition and the discrete wavelet transform for detection of human cataract in ultrasound signals”, **Informatica, Lith. Acad. Sci.**, 16, 541-556, (2005).
- [55] Goncalves, P., Abry, P., Rilling, G., Flandrin, P., “Fractal dimension estimation: empirical mode decomposition versus wavelets”, **IEEE International Conference on Acoustics, Speech and Signal Processing**, Honolulu, Hawaii, U.S.A., pp. III-1153-III-1156, (2007).
- [56] Bhagavatula, R., Savvides, M., “Analyzing facial images using empirical mode decomposition for illumination artifact removal and improved face recognition”, **IEEE International Conference on Acoustics, Speech and Signal Processing**, Honolulu, Hawaii, U.S.A., I-505-I-508, (2007).
- [57] Linderhed, A., “Image compression based on empirical mode decomposition”, **Proc. of SSAB Symposium Image Analysis**, Uppsala, 110-113, (2004),
- [58] Linderhed, A. “Adaptive Image Compression with Wavelet Packets and Empirical Mode Decomposition”, **Linköping Studies in Science and Technology**, Dissertation No. 909, ISBN 91-85295-81-7, (2004).
- [59] Bhuiyan, S. M. A., Adhami, R. R., Khan, J. F., “Fast and adaptive bidimensional empirical mode decomposition using order-statistics filter based envelope estimation”, **EURASIP Journal on Applied Signal Processing**, 2008, Article ID 728356, (2008).
- [60] Bhuiyan, S. M. A., Adhami, R. R., Khan, J. F., “A novel approach of fast and adaptive bidimensional empirical mode decomposition”, **IEEE International Conference on Acoustics, Speech and Signal Processing**, Las Vegas, Nevada, U.S.A., (2008).
- [61] Lee, J-C., Huang, P. S., Chiang, C-S., Tu, T.-M. and Chang C-P., “An Empirical Mode Decomposition Approach for Iris Recognition”, **IEEE International Conference on Image Processing**, Atlanta, GA, (2006).
- [62] Boudraa, A.O., Cexus, J.C., Benramdane, S. and Beghadi, A., “Noise filtering using empirical mode decomposition”, **International Symposium on Signal Processing and its Applications**, Sharjah, United Arab Emirates, (2007).

- [63] Wu, K.L, Hsieh, P.F., “Empirical mode decomposition for dimensionality reduction of hyperspectral data”, *IEEE International Geoscience and Remote Sensing Symposium*, 2, 1241- 1244, (2005).
- [64] Weng, B., Barner, K. E., “Optimal signal reconstruction using the empirical mode decomposition”, *EURASIP Journal on Advances in Signal Processing*, Article ID 845294, 12 pages, doi:10.1155/2008/845294, (2008).
- [65] Richards J. A., Jia, X., “Remote Sensing Digital Image Analysis: An Introduction”, *New York: Springer-Verlag*, (1999).
- [66] Foody, G. M., “Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy”, *Photogrammetric Engineering and Remote Sensing*, 70, 627-633, (2004).
- [67] Pizurica, A., Philips, W., “Estimating the probability of the presence of a signal of interest in multiresolution single and multiband image denoising”, *IEEE Transactions on Image Processing*, 15, 654-665, (2006).
- [68] Akbulut O., “Bir-bit dönüşümü temelli blok hareket kestirimlerinin H.264/AVC’ye uygulanması”, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, İzmit, (2007)
- [69] Swain, P. H., Davis, S. M., “Remote sensing: the quantitative approach”, *New York: McGraw-Hill*, (1978).
- [70] Bruzzone, L., Roli, F., Serpico, S. B., “An extension to multiclass cases of the Jeffreys-Matusita distance”, *IEEE Transactions on Geoscience and Remote Sensing*, 33, 1318–1321, (1995).
- [71] Bruzzone, L., Serpico, S. B., “A technique for feature selection in multiclass cases”, *International Journal Remote Sensing*, 21, 549–563, (2000).
- [72] Tyo J. S., Konsolakis A., Diersen D. I., Olsen R. C., “Principal components-based display strategy for spectral imagery”, *IEEE Transactions on Geoscience and Remote Sensing*, 41, 708–718, (2003).
- [73] Zhu, Y., Varshney, P. K., Chen, H., “Evaluation of ICA based fusion of hyperspectral images for color display”, *International Conference on Information Fusion*, Quebec, Canada, (2007).
- [74] Zhu, Y., Varshney, P. K., Chen, H., “Dimensionality reduction of hyperspectral images for color display using segmented independent component analysis”, *IEEE International Conference on Image Processing*, San Antonio, Texas, (2007).
- [75] Jacobson, N. P., Gupta, M. R., “Design goals and solutions for display of hyperspectral images”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, -2692, (2005).

- [76] Foody, G. M., Mathur, A., “The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM”, *Remote Sensing Environment*, 103, 179–189, (2006).
- [77] Foody, G.M., “The significance of border training patterns in classification by a feedforward neural network using back propagation learning”, *International Journal of Remote Sensing*, 20, 3549-3562, (1999).
- [78] Foody, G. M., “Issues in training set selection and refinement for classification by a feedforward neural network”, *IEEE International Geoscience and Remote Sensing Symposium*, Seattle, WA, (1998).
- [79] Wang, J., Wu, X., Zhang, C., “Support vector machines based on K-means clustering for real-time business intelligence systems”, *International Journal of Business Intelligence and Data Mining*, 1, 54-64, (2005).
- [80] Schohn, G., Cohn, D., “Less is more: active learning with support vector machines”, *Proceedings of the Seventeenth International Conference on Machine Learning*, 839-846, (2000).
- [81] Keshavarz, A.; Ghassemian, H.; Dehghani, H., “Hierarchical classification of Hyperspectral images by using SVMs and same class neighborhood property”, *IEEE International Geoscience and Remote Sensing Symposium*, Seoul, Korea, (2005).
- [82] Chui C. K., “An Introduction to Wavelets”, *Academic Press*, San Diego, ISBN 0121745848, (1992).
- [83] Ertürk, A., Ertürk, S., “Unsupervised segmentation of hyperspectral images using modified phase correlation”, *IEEE Geoscience and Remote Sensing Letters*, 3, 527-531, (2006).
- [84] Chang, C-I., Chakravarty, S., “Spectral derivative feature coding for hyperspectral signature analysis”, *Proceedings of the SPIE*, 630, 63020F, (2006).
- [85] Tsai, F., Philpot, W. D., “Derivative analysis of hyperspectral data”, *Remote Sensing Environment*, 66, 41–51, (1998).
- [86] Cohn, D., Atlas, L., Ladner, R., “Improving generalization with active learning”, *Machine Learning*, 15, 201-221, (1994).
- [87] Schohn, G., Cohn, D., “Less is more: active learning with support vector machines”, *Proceedings of the Seventeenth International Conference on Machine Learning*, Stanford, CA, (2000).
- [88] Mitra, P., Shankar, B. U., Pal, S. K., “Segmentation of multispectral remote sensing images using active support vector machines”, *Pattern Recognition Letters*, 25, 1067–1074, (2004).
- [89] Bruzzone, L., Chi, M. Marconcini, M., “A Novel transductive SVM for the semisupervised classification of remote-Sensing Images”, *IEEE Transactions on Geoscience and Remote Sensing*, 44, 3363-3373, (2006).

- [90] Chi M., Bruzzone, L., “Semi-supervised classification of hyperspectral images by SVMs optimized in the primal”, *IEEE Transactions on Geoscience and Remote Sensing*, 45, 1870-1880, (2007).
- [91] Zur, R.M., Jiang, Y., Metz, C.E., “Comparison of two methods of adding jitter to artificial neural network training”, *International Congress Series*, pp. 886-889, (2004).
- [92] Holmstrom, L., Koistinen P., “Using additive noise in back-propagation training”, *IEEE Transactions on Neural Networks*, 3, 24-38, (1992).
- [93] Oppenheim, A. V., Johnson, D. H., Steiglitz, K., “Computation of spectra with unequal resolution using the FFT”, *Proc. IEEE*, 59, 299–301, (1971).
- [94] Braccini C., Oppenheim A. V., Unequal Bandwidth Spectral Analysis Using Digital Frequency Warping”, *IEEE Transactions on Acoustics, Speech, Signal Processing*, 22, 236–244, (1974).
- [95] Goncharoff, V., Chandran, S., “Adaptive speech modification by spectral warping”, *IEEE International Conference on Acoustics, Speech and Signal Processing*, New York, NY, (1988).
- [96] Lee, L., Rose, R., “A frequency warping approach to speaker normalization”, *IEEE Transactions on Speech and Audio Processing*, 6, 49–60, (1998).
- [97] Evangelista, G., Cavaliere, S., “Discrete frequency warped wavelets: theory and applications”, *IEEE Transactions on Signal Processing*, 46, 874-885, (1998).
- [98] Demidenko, S., Piuri, V., “Using spectral warping for instrumentation and measurements in mixed-signal testing”, *IEEE Instrumentation & Measurement Technology Conference*, Venice, Italy, (1999).
- [99] Bailey, D.G., Allen, W., Demidenko, S.N., “Spectral warping revisited”, in *Proc. IEEE International Workshop on Electronic Design, Test, and Applications*, Perth, Australia, (2004).
- [100] Chang, J.-H., “Warped discrete cosine transform-based noisy speech enhancement”, *IEEE Transactions on Circuits and Systems II*, 52, 535–539, (2005).
- [101] Caporale, S., De Marchi, L., Speciale, N., “An iterative warping algorithm for arbitrary frequency maps”, *International Symposium on Nonlinear Theory and its Applications*, Bologna, Italy, (2006).
- [102] Cho, N. I., Mitra, S. K., “Warped discrete cosine transform and its application in image compression”, *IEEE Transactions on Circuits and Systems for Video Technology*, 10, 1364–1373, (2000).
- [103] Ertürk, S., “Warped discrete cosine transform based low bit-rate block coding using image down-sampling”, *EURASIP Journal on Advances in Signal Processing*, Article ID 43948, 5 pages, (2007).

- [104] Zhu, Y., Varshney, P., Chen, H., “Evaluation of ICA based fusion of hyperspectral images for color display”, *International Conference Information Fusion*, Québec City, QC, Canada, (2007).
- [105] Cui, M., Razdan, A., Hu, J., Wonka, P., “Interactive hyperspectral image visualization using convex optimization”, *IEEE Transactions on Geoscience and Remote Sensing*, 47, 1673–1684, (2009).
- [106] Kotwal, K., Chaudhuri, S., “Visualization of hyperspectral images using bilateral filtering”, *IEEE Transactions on Geoscience and Remote Sensing*, accepted for publication.
- [107] Bruzzone, L., Persello, C., “Handbook of Pattern Recognition and Computer Vision”, *World Scientific*, vol. 4, ed. by Prof. C.H. Chen. (2009).
- [108] Bhattacharyya, A. “On a measure of divergence between two statistical populations defined by their probability distributions”, *Bulletin of the Calcutta Mathematical Society* 35, 99–109, (1943).
- [109] Hughes, G. F., “On the mean accuracy of statistical pattern recognizers”, *IEEE Transactions on Information Theory*, IT-14, 55–63, (1968).
- [110] Benediktsson, J. A., Kanellopoulos, I., “Classification of multisource and hyperspectral data based on decision fusion”, *IEEE Transactions on Geoscience and Remote Sensing*, 37, 1367–1377, (1999).
- [111] Jeon, B. Landgrebe, D. A., “Decision fusion approach for multitemporal classification”, *IEEE Transactions on Geoscience and Remote Sensing*, 37, 1227–1233, (1999).
- [112] Licciardi, G., Pacifici, F., Tuia, D., Prasad, S., West, T., Giacco, F., Thiel, C., Inglada, J., Christophe, E., Chanussot, J., Gamba, P., “Decision Fusion for the Classification of Hyperspectral Data: Outcome of the 2008 GRS-S Data Fusion Contest”, *IEEE Transactions on Geoscience and Remote Sensing*, 47, 3857 – 3865, (2009).
- [113] Alpaydm, E., Introduction to Machine Learning, *MIT Press*, (2004).
- [114] Perumal, K., Bhaskaran, R., “SVM based effective land use classification system for multispectral remote sensing images”, *International Journal of Computer Science and Information Security*, 6, 97-105, (2009).
- [115] Platt, J.C., “Probabilities for SV Machines,” in Advances in Large Margin Classifiers, A. Smola, P. Bartlett, B. Schölkopf, and D. Schuurmans, Eds., *MIT Press*, pp. 61-74, (1999).
- [116] Benediktsson, J. A., Swain P. H., Ersoy, O. K., “Neural network approaches versus statistical methods in classification of multisource remote sensing data,” *IEEE Transactions on Geoscience and Remote Sensing*, 28, 540-552, (1990).

- [117] Demir, B., Çelebi, A., Ertürk, S., “A Low-complexity approach for color display of hyperspectral remote-sensing images Using One-Bit Transform Based Band Selection”, *IEEE Transactions on Geoscience and Remote Sensing*, 47, 97-105, (2009).
- [118] Rosenfeld, A. Hummel, R. and Zucker, S. “Scene labelling by relaxation algorithms,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-6, no. 6, pp. 420–433, (1976).
- [119] Plaza, A. Martinez, P. Plaza, J. and Perez. R.M. “Dimensionality Reduction and Classification of Hyperspectral Image Data Using Sequences of Extended Morphological Transformations,” *IEEE Transactions on Geoscience and Remote Sensing*, 43, pp. 466-479, (2005).

EKLER

EK-A. DESTEK VEKTÖR MAKİNELERİ

Bu bölümde uzaktan algılama görüntülerinin sınıflandırılmasında yaygın olarak kullanılan DVM sınıflandırma yönteminin matematiksel ifadesi verilerek yöntem teorik olarak açıklanmaktadır [50, 51].

$I \times J$ piksel boyutlarında d -boyutlu bir V verisi için eğitilmiş sınıflandırma problemi düşünelim. Eğitim verisi $E = \{X, Y\}$, $X = \{\mathbf{x}_i | \mathbf{x}_i \in \mathbb{R}^d\}_{i=1}^N \subset V$ ve $Y = \{y_i\}_{i=1}^N$ verilerinden oluşmaktadır. Burada X , V verisinin bir alt kümesini, Y bu alt kümedeki verilerin sınıf bilgilerini (sınıf etiketlerini) ve N toplam eğitim verisi sayısını göstermektedir. DVM sınıflandırma yöntemi iki sınıflı sınıflandırma problemlerini çözmektedir ve iki sınıflı DVM sınıflandırma problemleri için \mathbf{x}_i örneğinin sınıf bilgisi $y_i \in \{+1, -1\}$ olmaktadır. İkili DVM'nin amacı d -boyutlu öznitelik uzayını ayırma düzlemi $H (H : \langle \mathbf{w} \cdot \mathbf{x} \rangle + b = 0)$ ile her biri bir sınıfla ilişkili olan iki alt uzaya ayırmaktır. Ayırma fonksiyonu $f(\mathbf{x})$ 'in ($f(\mathbf{x}) = \langle \mathbf{w} \cdot \mathbf{x} \rangle + b$) işareti $\text{sgn}(f(\mathbf{x}))$ test verisinin hangi sınıfa ait olduğu belirtmektedir. Bu durumda örneğin, $f(\mathbf{x}) > 0$ ise $y = +1$, $f(\mathbf{x}) \leq 0$ ise $y = -1$ olmaktadır. DVM eğitim aşamasında, ayırma düzlemi (hiperdüzlem) ile bunun her iki tarafında bulunan veri örnekleri arasındaki mesafenin maksimum olması için düzlemin pozisyonu en uygun şekilde sokulmaktadır. Burada \mathbf{w} vektörü, hiperdüzleme olan normaldir ve düzlemin yönünü belirlemektedir. Ayırma düzleminin orijine olan uzaklığı $b / \|\mathbf{w}\|$ ve bir \mathbf{x} örneğinin ayırma düzlemine uzaklığı $f(\mathbf{x}) / \|\mathbf{w}\|$ 'dir [50, 51].

A.1. Doğrusal DVM (Geniş Marjin –Maximum Marjin)

Doğrusal ayrılabilir sınıfları birbirinden ayıran pek çok karar düzlemini bulmak mümkündür. DVM bu karar düzlemlerinden her iki sınıfa uzak olanını yani iki sınıf arasındaki uzaklığı büyükleyen en uygun ayırt etme yüzeyini belirlemektedir. Bu düzleme en yakın vektörler de destek vektörleri olarak isimlendirilmektedir. Eğitim örneklerinden elde edilen destek vektörleri sınıflandırma için önemlidir. Karar (test) aşamasında ise destek vektörleri kullanılarak test verilerinin hangi sınıfa ait olduğu belirlenmektedir. En yakın noktaların (destek vektörleri) en uygun hiperdüzleme uzaklığı $1/\|\mathbf{w}\|$ 'dir. En uygun ayırma düzlemi, uzaklığı büyükleyen dolayısıyla $\|\mathbf{w}\|^2$ değerini küçükleyen düzlem olarak bulunmaktadır. Böyle bir düzlemin bulunması aşağıdaki en uygun şekle sokma problemi olarak ifade edilebilmektedir [50, 51].

$$\begin{aligned} \text{küçükle: } & \frac{1}{2}\|\mathbf{w}\|^2 \\ \text{kısıtlar: } & y_i \cdot [\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b] \geq 0, \quad \forall i = 1, 2, \dots, N \end{aligned} \quad (\text{A.1})$$

H_1 ve H_2 'nin ayırma düzlemi H 'ye paralel ve eşit uzaklıklı iki düzlem olduğu varsayılır ise $H_1 : f(\mathbf{x}) = \langle \mathbf{w} \cdot \mathbf{x} \rangle + b = 1$ ve $H_2 : f(\mathbf{x}) = \langle \mathbf{w} \cdot \mathbf{x} \rangle + b = -1$ 'dir. DVM eğitim aşamasının amacı H_1 ve H_2 düzlemleri arası uzaklığı aralarında hiçbir örnek kalmayacak şekilde en büyükleyecek \mathbf{w} ve b değerlerini bulmaktır. Denklem (A.1) ile gösterilen küçükleme problemi, hesapsal karmaşıklığı eğitim veri sayısına (N) bağlı olacak şekilde Lagrange denklemi ile ifade edilebilmektedir [50, 51].

$$L_p = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i [y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - 1] = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) + \sum_i \alpha_i \quad (\text{A.2})$$

Burada $\alpha_{i=1}^N$ Lagrange çarpanlarıdır. Denklem (A.2) \mathbf{w} ve b 'ye bağlı olarak küçüklenmeli ve $\alpha_i \geq 0$ olacak şekilde büyüklenmelidir. Bu denklemin çözümü ana terimin ve doğrusal kısıtlamaların dışbükey olması nedeni ile dışbükey karesel programlama problemidir. Denklem (A.2) ile gösterilen Lagrange denkleminin \mathbf{w} ve b 'ye göre türevi alınarak elde edilen (A.3)'deki tanımlamalar (A.2)'de yerine konularak (A.4) ile gösterilen ikili büyükleme problemi elde edilmektedir [50, 51].

$$\frac{\partial L_p}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_i \alpha_i y_i \mathbf{x}_i \quad (\text{A.3})$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow \sum_i \alpha_i y_i = 0$$

$$\text{büyükle: } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle \quad (\text{A.4})$$

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

Karush–Kuhn–Tucker (KKT) tamamlayıcı koşullarına göre en uygun α^* , \mathbf{w}^* ve b^* değerleri için $\alpha_i^* [y_i (\mathbf{w} \cdot \mathbf{x}_i + b^*) - 1] = 0$ koşulu sağlanmalıdır. Bu çözüme göre H_1 veya H_2 ayırma düzlemi üzerinde yer alan her \mathbf{x} vektörünün α değerleri sıfırdan farklıdır ve bu vektörler destek vektörü (DV) olarak isimlendirilmektedir. Lagrange çarpanı α için en uygun çözümün α^* olduğu varsayılır ise \mathbf{w} 'nin en uygun çözümü $\mathbf{w}^* = \sum_{i=1}^N y_i \alpha_i^* \mathbf{x}_i = \sum_{i \in DV} y_i \alpha_i^* \mathbf{x}_i$ olmaktadır. İkili problemde (dual problem) b kullanılmamaktadır ve önsel sınırlamalar (primal constraints) kullanılarak elde edilmelidir:

$$b = - \frac{\text{enbüyük}_{y_i=-1}(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle) + \text{enküçük}_{y_i=+1}(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle)}{2} \quad (\text{A.5})$$

\mathbf{w} ve b yukarıda bahsedilen en uygun şekle sokma problemi çözülerek hesaplandıktan sonra, test verileri denklem (A.6) ile belirtilen ayırma fonksiyonunun işareti kullanılarak sınıflandırılmaktadır.

$$f(\mathbf{x}) = \langle \mathbf{w} \cdot \mathbf{x} \rangle + b = \left(\sum_{i \in DV} y_i \alpha_i^* \mathbf{x}_i \right) \cdot \mathbf{x} + b = \sum_{i \in DV} y_i \alpha_i^* \langle \mathbf{x}_i \cdot \mathbf{x} \rangle + b \quad (\text{A.6})$$

Burada \mathbf{x} örnek bir test verisini ve \mathbf{x}_i i . destek vektörünü göstermektedir.

A.2. Doğrusal DVM (Yumuşak Marjin –Soft Margin)

Doğrusal ayrılabilir veri genelde bulunmamaktadır. Eğitim verisinin doğrusal olarak ayrılabilmesi durumunda geniş marjin (maximum margin) eğitim algoritması kullanılmamaktadır. Bu durumda yumuşak marjin (soft margin) algoritması kullanılmaktadır. Eğer veri doğrusal olarak ayrılamıyor ise düzenleme parametresi C ve arttıran yapay değişken ξ (slack variable) tanımlanmaktadır. Arttıran yapay değişken yanlış sınıflandırmaya verilen hatayı kontrol etmektedir. Bu sebeple eğitim algoritması eğitim verisindeki gürültüye ve aykırı örneklere (outliers) karşı dayanıklıdır. Verilerin doğrusal ayrılmama durumunda problem iki sınıflı veriyi, aynı sınıfa ait verinin mümkün olan en büyük oranını alt düzlemin aynı tarafında bırakacak şekilde ayıran alt düzlemi bulmaktır ve böyle bir düzlemin bulunması aşağıdaki en uygun şekle sokma problemi olarak ifade edilmektedir [50,51].

$$\begin{aligned} \text{küçükle: } & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \\ \text{kısıtlar: } & y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \quad \xi_i \geq 0 \end{aligned} \quad (\text{A.7})$$

Burada C düzenleme parametresidir ve hata ile ilişkili cezayı kontrol etmektedir. Bu nedenle marjinin genişliği ve izin verilen yanlış sınıflandırılan eğitim örneklerinin sayısı arasında ödünleşim sağlamaktadır. C değeri çok küçük seçilir ise yüksek hataya izin verilecek ve elde edilen ayırma fonksiyonu veri ile uyumlayacaktır. C değerinin büyük seçilmesi durumunda ise aşırı yüklenme oluşacak ve düşük sınıflandırma başarımı elde edilecektir. C parametresinin değeri sınıflandırma başarımı için önemlidir ve sınıflandırma öncesi model seçme (model selection) aşaması ile belirlenmektedir. Denklem (A.7)'de gösterilen en uygun şekle sokma problemindeki ilk terim, doğrusal ayrılabilir durumdaki ifade ile aynıdır. İkinci terim ise yanlış sınıflandırma noktasını kontrol etmektedir.

$$\begin{aligned} \text{büyükle: } & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle \\ \text{kısıtlar: } & \sum_{i=1}^N \alpha_i y_i = 0 \text{ ve } 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N \end{aligned} \quad (\text{A.8})$$

Denklem (A.8) ile (A.4) arasındaki tek farklılık Lagrange çarpanı $\alpha_{i=1}^N$ 'lere getirilen sınırlamadır. Yumuşak marjın algoritmalarında $\alpha_{i=1}^N$ 'lerin en büyük değeri C değerine sınırlandırılmıştır. Bu durumda KKT tamamlayıcı durumları denklem (A.9) ile gösterilmektedir.

$$\begin{aligned}\alpha_i [y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - 1 + \xi_i] &= 0, \quad i = 1, \dots, N \\ \xi_i (\alpha_i - C) &= 0, \quad i = 1, \dots, N\end{aligned}\tag{A.9}$$

$\alpha_{i=1}^N$ 'lerin değerlerine bağlı olarak üç durum oluşmaktadır.

$$1 - \alpha_i = 0 \text{ ise } \xi_i = 0 \text{ ve } y_i \cdot [\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b] \geq 1$$


$$2 - 0 \leq \alpha_i \leq C \text{ ise } y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) + \xi_i = 1 \text{ 'dir. Fakat } \xi_i = 0 \text{ verilir ise } y_i \cdot [\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b] = 1 \text{ 'dir.}$$

$$3 - \alpha_i = C \text{ ise } y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) + \xi_i = 1 \text{ 'dir. Fakat } \xi_i \geq 0 \text{ verilir ise } y_i \cdot [\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b] \leq 1 \text{ 'dir.}$$

KKT tamamlayıcı durumları denklem (A.10)'daki gibi yazılabilir.

$$\begin{aligned}\alpha_i = 0 &\rightarrow y_i f(\mathbf{x}_i) \geq 1 \\ 0 < \alpha_i < C_i &\rightarrow y_i f(\mathbf{x}_i) = 1 \\ \alpha_i = C_i &\rightarrow y_i f(\mathbf{x}_i) \leq 1\end{aligned}\tag{A.10}$$


$\alpha_i = C$ ise elde edilen destek vektörleri sınır destek vektörleri olarak isimlendirilmektedir ve bu durumda $\xi_i \geq 0$ olmaktadır. $0 \leq \alpha_i \leq C$ ise elde edilen destek vektörleri sınırsız destek vektörleri olarak isimlendirilmekte ve H_1 veya H_2 ayırma düzlemi üzerinde bulunmaktadır. Şekil A.1 örnek bir doğrusal ayırlamayan veri için ayırma düzlemini ve destek vektörlerini göstermektedir.



Şekil A.1: Örnek bir doğrusal ayrılamayan veri ve elde edilen ayırma düzlemi [107]

A.3. Doğrusal Olarak Ayrılamayan DVM

DVM ile sınıflandırmada verilerin doğrusal ayrılamadığı durumlarda, doğrusal olarak ayrılamayan sınıflardaki her bir vektör, doğrusal olmayan $\phi()$ gibi bir dönüşümle daha yüksek boyutlu bir uzaya (Hilbert öznelik uzayı, $\phi: \mathbb{R}^d \rightarrow H$) taşınarak elde edilen yeni verinin doğrusal olarak ayrılmaya daha uygun hale getirilmesi yoluna gidilebilmektedir. Buradaki güçlük, denklem (A.8)'de belirtilen öznelik uzayındaki iç çarpımın gerçekleşmesidir ve bu güçlük çekirdek yaklaşımıyla uzçözülmektedir. Çekirdek yöntemleri ile orijinal giriş uzayı, yüksek boyutlu çekirdek öznelik uzayına yansıtılmaktadır. Çekirdek fonksiyonu genelde $K()$ ile gösterilmektedir. Çekirdek fonksiyonu, öznelik uzayındaki iç çarpımı gerçekleştirdiğinden $\phi()$ dönüşümünün analitik olarak bilinmesine gerek yoktur ve sadece $K()$ 'nın belirlenmesi yeterlidir ($K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)\phi(\mathbf{x}_j)$). Şekil A.2'de örnek bir verinin, giriş öznelik uzayında ve çekirdek fonksiyonu kullanılarak elde edilen yüksek boyutlu öznelik uzayındaki konumları gösterilmektedir.



Şekil A.2: Giriş verisinin çekirdek fonksiyonu kullanılarak çekirdek öznelik uzayına dönüşümü (a) giriş öznelik uzayı, (b) çekirdek öznelik uzayı [107]

Yumuşak marjın algoritması doğrusal olmayan problemler için aşağıdaki en uygun şekilde sokma problemi ile ifade edilmektedir :

$$\text{büyükle: } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (\text{A.11})$$

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

Sınıflandırma fonksiyonu denklem (A.12) ile ifade edilmektedir.

$$f(\mathbf{x}) = \sum_{i \in DV} y_i \alpha_i^* K(\mathbf{x}_i, \mathbf{x}) + b \quad (\text{A.12})$$

DVM'de Mercer koşullarını sağlayan ve simetrik kesin pozitif olan çekirdek fonksiyonları kullanılarak doğrusal olarak ayrılmayan verilerin doğrusal olarak ayrılmaya daha uygun bir uzaya dönüştürülmesi sağlanmaktadır [50, 51]. Literatürde değişik uygulamalar için çok çeşitli çekirdek fonksiyonları bulunmakla birlikte en yaygın kullanılan çekirdekler doğrusal, çokterimli çekirdek ve radyal taban çekirdek (RTF) fonksiyonlarıdır (A.13). Uygun çekirdek parametreleri kullanılarak daha iyi sınıflandırma sonuçları elde edilebilmektedir.

$$\text{Doğrusal çekirdek: } K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j$$

$$\text{Çok terimli çekirdek: } K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i \cdot \mathbf{x}_j)^d \quad (\text{A.13})$$

Radyal taban çekirdek: $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$

Burada γ ve d parametreleri kullanıcı giriřli çekirdek parametreleridir.

A.4. Çok Sınıflı DVM

DVM ikili sınıflandırma için tasarlanmıştır ve çoklu sınıflandırmaya etkin olarak nasıl uyarlanacağı devam eden araştırma konusudur. Çok sınıflı DVM sınıflandırmayı gerçekleřtirmek amacıyla ikili sınıflandırmaları birleřtiren yöntemler ve bütün verilerin aynı anda kullanılarak tek aşamada çok sınıflı sınıflandırma probleminin çözümüne yönelik yöntemler literatürde bulunmaktadır [52]. DVM ile çok sınıflı sınıflandırma, ya ikili DVM'ler belirli kurallar çerçevesinde birleřtirilerek ya da en uygun řekle sokma problemleri çözülerek gerçekleřtirilmektedir. Aynı veri miktarı için en uygun řekle sokma probleminin çözümü ikili sınıflandırmaların çözümüne göre daha fazla hesapsal yük gerektirmektedir. En yaygın kullanılan ikili sınıflandırmaları birleřtiren yöntemler bire-bir DVM ve bire-hepsi DVM yöntemleridir. Bire-hepsi çok sınıflı DVM sınıflandırma yöntemi n sınıf sayısı olmak üzere n tane DVM modeli geliřtirmektedir. Örneğin, i . DVM modelinde i . sınıfın bütün elemanları pozitif etiketli sınıfın, kalan tüm diđer sınıfların bütün elemanları negatif etiketli sınıfın elemanları olmak üzere eğitim işlemi gerçekleřtirilmektedir. Burada sınıflandırma aşamasında ise test örnekleri bütün modeller kullanılarak test işlemine sokulmakta ve hiperdüzleme en uzak olan sınıfa etiketlenmektedir [52]. Bire-bir çok sınıflı DVM sınıflandırma yöntemi bütün ikili sınıflandırmalar için bir model geliřtirerek, n sınıf sayısı olmak üzere $n(n-1)/2$ tane DVM modeli geliřtirmektedir. Sınıflandırma aşamasında ise test örnekleri bütün modeller kullanılarak test işlemine sokulmakta ve karar için en çok oyu alan kazanır yaklaşımı kullanılmaktadır. Test verileri en çok oyu alıp kazanan sınıfa dahil edilmektedir [52].

KİŞİSEL YAYINLAR VE ESERLER

1. Demir B., Ertürk S., “Decision fusion of empirical mode decomposition based hyperspectral image classification results”, *IEEE Geoscience and Remote Sensing Letters*, (hakem değerlendirmesinde).
2. Demir, B., Güllü K., Ertürk, S., “Hyperspectral image classification using denoising of intrinsic mode functions”, *IEEE Geoscience and Remote Sensing Letters*, (yayınlanmak üzere kabul edildi).
3. Demir, B., Ertürk, S., “Empirical mode decomposition of hyperspectral images for support vector machine classification”, *IEEE Transactions on Geoscience and Remote Sensing*, (yayınlanmak üzere kabul edildi).
4. Demir, B., Ertürk, S., “Clustering based extraction of border training patterns for accurate SVM classification of hyperspectral images”, *IEEE Geoscience and Remote Sensing Letters*, 6, 840-844, (2009).
5. Demir, B., Çelebi, A., Ertürk, S., “A Low-complexity approach for color display of hyperspectral remote-sensing images Using One-Bit Transform Based Band Selection”, *IEEE Transactions on Geoscience and Remote Sensing*, 47, 97-105, (2009).
6. Demir, B., Ertürk, S., “Improved classification and segmentation of Hyperspectral images using spectral warping”, *International Journal of Remote Sensing*, vol. 29, 3657-3663, (2008).
7. Demir, B., Ertürk, S., “Phase correlation based redundancy removal in feature weighting band selection for hyperspectral Images”, *International Journal of Remote Sensing*, 29, 1801-1807,(2008).
8. Demir B., Ertürk S., “Empirical mode decomposition based decision fusion for higher hyperspectral image classification accuracy”, *International Conference on Geoscience and Remote Sensing Symposium*, Honolulu, Hawaii, USA, (2010).
9. Demir B., Ertürk S., “Improving SVM classification accuracy using a hierarchical approach for hyperspectral images”, *IEEE International Conference on Image Processing*, Cairo, (2009).
10. Demir B., Ertürk S., “Accurate SVM classification using border training patterns”, *First Workshop on Hyperspectral Image and Signal Processing: Evolution on Remote Sensing*, Grenoble, France, (2009).

11. Demir B., Ertürk S., “An empirical mode decomposition and composite kernel approach to increase hyperspectral image classification accuracy”, *International Conference on Geosience and Remote Sensing Symposium*, Cape Town, South Africa, (2009).
12. Demir B., Ertürk S., Güllü K., “Wavelet shrinkage denoising of intrinsic mode functions of hyperspectral image bands for classification with high accuracy”, *International Conference on Geosience and Remote Sensing Symposium*, Cape Town, South Africa, (2009).
13. Demir B., Ertürk S., “Increasing hyperspectral image classification accuracy for data sets with limited training samples by sample interpolation”, *4th International Conference on Recent Advances in Space Technologies (RAST2008)*, (2009).
14. Demir B., Ertürk S., “Spectral magnitude and spectral derivative feature fusion for improved classification of hyperspectral images”, *International Conference on Geosience and Remote Sensing Symposium*, Boston, Massachusetts, U.S.A, (2008).
15. Demir B., Ertürk S., “Reducing the computational load of hyperspectral band selection using the one-bit transform of hyperspectral bands”, *International Conference on Geosience and Remote Sensing Symposium*, Boston, Massachusetts, USA, (2008).
16. Demir B., Ertürk S., “Empirical mode decomposition pre-process for higher accuracy hyperspectral image classification”, *International Conference on Geosience and Remote Sensing Symposium*, Boston, Massachusetts, USA, (2008).
17. Demir B., Ertürk S., “Phase correlation based supervised classification of hyperspectral images using multiple class representatives”, *International Conference on Geosience and Remote Sensing Symposium*, Barcelona, Spain, (2007).
18. Demir B., Ertürk S., “Improved hyperspectral image classification with noise reduction pre-process”, *European Signal Processing Conference (EUSIPCO-2008)*, Lausanne, Switzerland, (2008).
19. Demir B., Ertürk S., “Empirical mode decomposition based decision fusion for hyperspectral image classification”, *IEEE 17th Signal Processing and Communications Applications Conference (SIU'2010)*, Diyarbakır, (2010).
20. Demir B., Ertürk S., “High accuracy hyperspectral image classification based on empirical mode decomposition and composite kernel”, *IEEE 17th Signal Processing and Communications Applications Conference (SIU'2009)*, Antalya, (2009).

21. Demir B., Ertürk S., “Hiperspektral görüntülemenin savunma teknolojileri uygulamaları ve spektral eğriltme sayesinde yüksek tanıma başarımı”, **4th National Defense Technologies Conference (SAVTEK 2008)**, (2008).
22. Demir B., Ertürk S., “Hyperspectral image classification based on empirical mode decomposition”, **IEEE 16th Signal Processing and Communications Applications Conference (SIU'2008)**, Didim, (2008).
23. Demir B., Ertürk S., “Wavelet denoising before support vector classification of hyperspectral images”, **IEEE 15th Signal Processing and Communications Applications Conference (SIU'2007)**, Eskişehir, (2007).

ÖZGEÇMİŞ

1984 Ordu doğumlu olan Begüm Demir lisans ve yüksek lisans derecelerini sırasıyla 2005 ve 2007 yıllarında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden aldı. 2007 yılından beri Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nde doktora eğitimine devam etmektedir ve aynı bölümde araştırma görevlisi olarak çalışmaktadır. Yüksek lisans eğitimi sırasında Prof. Dr. Sarp Ertürk ile birlikte hiperspektral görüntülerin sınıflandırılması üzerine çalışmalara başladı ve bu alanda uluslararası dergi ve uluslararası konferans yayınları bulunmaktadır. Mart 2009-Eylül 2009 tarihleri arasında Tübitak 2214 yurt dışı araştırma burs programı desteğiyle İtalya'da bulunan Trento Üniversitesi, Uzaktan Algılama Laboratuvarında misafir araştırmacı olarak çalıştı. Doktora tezi kapsamı dışındaki kişisel yayınları ve eserleri aşağıda verilmektedir.

1. Demir, B., Persello, C., Bruzzone, L., “Batch mode active learning methods for the interactive classification of remote sensing images”, *IEEE Transactions on Geoscience and Remote Sensing*, (yayınlanmak üzere kabul edildi).
2. Yapıcı, Y., Demir, B., Ertürk, S., Urhan, O., “Down-sampling based multiple description image coding using optimal filtering”, *Journal of Electronic Imaging*, 17, Article ID 033018, (2008).
3. Demir, B., Ertürk, S., “Hyperspectral image classification using relevance vector machines”, *IEEE Geoscience and Remote Sensing Letters*, 4, (586-590), 2007.
4. Demir, B., Ertürk, S., “Block motion estimation using adaptive modified two-bit transform”, *IET Image Processing*, 1, 215-222, (2007).
5. Demir, B., Ertürk, S., Urhan, O., ”Improved quality multiple description 3D mesh coding with optimal filtering”, *IEEE International Conference on Image Processing*, Cairo, Egypt, (2009).
6. Ateş, Ç., Ürgün, Y., Demir, B., Urhan, O., Ertürk, S., “Polyphase downsampling based multiple description image coding using optimal filtering with flexible redundancy insertion”, *IEEE International Conference on Signals and Electronic Systems*, Krakow, Poland, (2008).
7. Kızıltoprak, Z., Demir, B., Diri, B., “Ön-işlem kullanılarak hiperspektral görüntülerde ilgililik vektör makineleri ile sınıflandırma başarımının artırılması”, *IEEE 16th Signal Processing and Communications Applications Conference (SIU'2008)*, Didim, (2008).

8. Demir, B., Ertürk, S., “Hyperspectral data classification using RVM with pre-segmentation and RANSAC”, *International Conference on Geosience and Remote Sensing Symposium*, Barcelona, Spain, (2007).
9. Demir, B., Ertürk, S., “Achieving more sparsity in hyperspectral SVM classification using unsupervised pre-segmentation in the training phase”, *III. International Conference on Recent Advances in Space Technologies (RAST 2007)*, İstanbul, (2007).
10. Demir, B., Ertürk, S., “Vektör makinaları temelli hiperspektral sınıflandırma için seyreklik/ sınıflandırma başarımı deęiş tokuşu”, *IEEE 15th Signal Processing and Communications Applications Conference (SIU’2007)*, Eskişehir, (2007).
11. Demir, B., Ertürk, S., “Block motion estimation using modified two-bit transform”, *Lecture Notes in Computer Science (LNCS)*, Springer-Verlag, 4263, 522-531, (2006).
12. Yıldırım, İ., Demir, B., Ertürk, S., “3-dimensional modeling and visualization of cultural assets for e-government”, *IEEE Signal Processing and Communications Applications Conference (SIU’2006)*, Antalya, (2006).
13. Demir, B., Ertürk, S., “Flexible multiple description 3-D model coding using wavelet subdivision surfaces”, *IEEE Signal Processing and Communications Applications Conference (SIU’2006)*, Antalya, (2006).