

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

HİPERSPEKTRAL GÖRÜNTÜLER İÇİN UZAMSAL
YAKLAŞIMLAR

ALP ERTÜRK

KOCAELİ 2013

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

HİPERSPEKTRAL GÖRÜNTÜLER İÇİN UZAMSAL
YAKLAŞIMLAR

ALP ERTÜRK




Doç.Dr. M. Kemal GÜLLÜ
Danışman, Kocaeli Üniv.

Prof.Dr. Cem ÜNSALAN
Jüri Üyesi, Yeditepe Üniv.

Doç.Dr. Cabir VURAL
Jüri Üyesi, Marmara Üniv.

Doç.Dr. Oğuzhan URHAN
Jüri Üyesi, Kocaeli Üniv.

Yrd.Doç.Dr. Osman BÜYÜK
Jüri Üyesi, Kocaeli Üniv.


.....

.....

.....

.....

.....

Tezin Savunulduğu Tarih: 11.10.2013

ÖNSÖZ VE TEŞEKKÜR

Dünyada kullanımı her gün artan ve yayılan hiperspektral görüntü teknolojileri üzerine Kocaeli Üniversitesi Görüntü ve İşaret İşleme Laboratuvarında (KULİS) gerçekleştirilen tezlerden biri olan bu tezin, hiperspektral görüntüleme ve hiperspektral görüntü işleme üzerine çalışan veya çalışmayı düşünen herkese faydalı olmasını temenni ediyorum.

Bu tez çalışması TÜBİTAK tarafından 111E052 nolu proje kapsamında kısmen desteklenmiştir.

Tez çalışmalarım boyunca destek ve yardımlarını eksik etmeyen tez danışmanım Doç. Dr. M. Kemal Güllü'ye ve tez izleme jürimde yer alan Doç. Dr. Oğuzhan Urhan ve Doç. Dr. Cabir Vural'a yorum ve yönlendirmeleri için teşekkür ederim.

Bu çalışma Prof. Dr. Sarp Ertürk olmadan gerçekleşemezdi. Kendisine hem kendim hem de ülkemizin bilimsel gelişimi adına sonsuz teşekkürlerimi sunarım.

Tükenmeyen destekleriyle güçlendiren, umutlarıyla yolumu aydınlatan aileme ve Burcu'ya hiçbir teşekkür yeterli değildir. Sizi seviyorum.

Ekim - 2013

Alp ERTÜRK

İÇİNDEKİLER

ÖNSÖZ ve TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ	ix
SİMGELER DİZİNİ VE KISALTMALAR	xi
ÖZET.....	xiii
ABSTRACT	xiv
GİRİŞ	1
1. SON ELEMAN ÇIKARIMI	6
1.1. Son Eleman Sayısı Tespiti.....	7
1.1.1. HFC.....	8
1.1.2. HySime	8
1.1.3. EML	11
1.2. Son Elemanların Veride Saf Olarak Bulunduğunu Varsayan Son Eleman Çıkarımı Yöntemleri	12
1.2.1. N-FINDR.....	13
1.2.2. VCA	14
1.3. Son Elemanların Veride Saf Olarak Bulunduğu Varsayımını Yapmayan Son Eleman Çıkarımı Yöntemleri.....	14
1.3.1. MVSA	15
1.3.2. SISAL	16
1.4. Son Eleman Çıkarımında Uzamsal Bilginin Kullanımı	18
1.4.1. Uzamsal ve spektral bilgileri bir arada kullanan yöntemler.....	19
1.4.2. Uzamsal bilgilerin ön-işleme yoluyla kullanılması.....	20
1.5. Özgün Çalışma: Son Eleman Çıkarımı için Anomali Gözetken Ön- işleme Yaklaşımı	24
1.5.1. Motivasyon.....	25
1.5.2. Anomali tespiti yöntemleri.....	26
1.5.3. Yöntemin açıklaması.....	29
1.5.4. Deneysel sonuçlar	30
1.5.5. Vargılar.....	41
2. SPEKTRAL KARIŞIM ANALİZİ	42
2.1. Doğrusal Karışım Modeli ve En Küçük Kareler Tabanlı Yöntemler.....	44
2.1.1. En küçük kareler tabanlı yöntemler ile deneysel sonuçlar	47
2.1.2. Son eleman çıkarımı ve spektral karışım analizi deneysel sonuçları	50
2.2. Doğrusal Spektral Karışım Analizi için Bulanık Mantık Kullanımı:	63
2.2.1. FLICM.....	64
2.2.2. FLICM ile spektral karışım analizi	65
2.2.3. Özgün çalışma: Spektral uzaklıklı FLICM ile spektral karışım analizi	66
2.3. Doğrusal Olmayan Spektral Karışım Analizi.....	71
2.3.1. Doğrusal olmayan spektral karışım analizi literatür özeti.....	72
2.3.2. Özgün çalışma: Çekirdek FLICM ile spektral karışım analizi.....	73

3. UZAMSAL BAĞIMLILIK ESASINA GÖRE ÇÖZÜNÜRLÜK ARTIRIMI.....	81
3.1. Benzetimli Tavlama ile Uzamsal Bağlılık Esasına Göre Çözünürlük Artırımı	84
3.1.1. Yöntemin açıklaması.....	84
3.1.2. Deneysel sonuçlar	85
3.2. Özgün Çalışma: Parçacık Sürü Optimizasyonu ile Uzamsal Bağlılık Esasına Göre Çözünürlük Artırımı.....	93
3.2.1. Parçacık sürü optimizasyonu.....	93
3.2.2. İkili parçacık sürü optimizasyonu	94
3.2.3. Özgün yöntemin açıklaması	97
3.2.4. Deneysel sonuçlar	99
3.2.5. Vargılar.....	107
4. UZAMSAL BİLGİ KULLANARAK SINIFLANDIRMA BAŞARIMININ ARTIRILMASI.....	108
4.1. Özgün Çalışma: Spektral Gradyan Geliştirmeli AKA	109
4.1.1. AKA	110
4.1.2. Spektral gradyan geliştirmeli AKA.....	114
4.1.3. Deneysel sonuçlar	118
4.1.4. Vargılar.....	133
SONUÇLAR ve ÖNERİLER.....	134
KAYNAKLAR	137
KİŞİSEL YAYINLAR ve ESERLER.....	148
ÖZGEÇMİŞ	149

ŞEKİLLER DİZİNİ

Şekil 1.1.	Hiperspektral veri ve spektral imzalar	6
Şekil 1.2.	Son elemanların oluşturduğu, dışbükey geometride dağılmış veri	12
Şekil 1.3.	Veride oluşturulan simpleks yapılar (a) Rastgele seçilmiş veri noktaları için (b) Son elemanlar için	13
Şekil 1.4.	VCA işlemi	14
Şekil 1.5.	Son elemanları içermeyen veride son elemanlar ve VCA çözümü	15
Şekil 1.6.	MVSA süreci	16
Şekil 1.7.	Spektral tabanlı son eleman çıkarımı yöntemleri için aynı veriler (a) hiperspektral veri (b) piksel vektörleri uzamsal olarak yer değiştirilmiş veri	18
Şekil 1.8.	SPP yönteminin çalışması	21
Şekil 1.9.	RBSPP yöntemi	21
Şekil 1.10.	SSPP yöntemi	23
Şekil 1.11.	RX çevrit yüzeyleri	27
Şekil 1.12.	Fractal_1 verisi	31
Şekil 1.13.	Fractal_1 verisi son eleman imzaları	31
Şekil 1.14.	Fractal_1 verisine eklenen anomali imzaları	33
Şekil 1.15.	30dB SNR Fractal verisi için görsel sonuçlar (a) VCA ile bulunan son eleman konumları (b) ISODATA ile elde edilen bölgeler (c) RBSPP+VCA ile bulunan son eleman konumları (d) SSPP+VCA ile bulunan son eleman konumları (e) Veriye eklenen anomali noktaları (f) KRX ile tespit edilen anomali noktaları (g) RBSPP+KRX+VCA ile bulunan son eleman konumları (h) SSPP+KRX+VCA ile bulunan son eleman konumları	35
Şekil 1.16.	Şekil 1.15'te görselleri verilen veri için KRX eşiği = 0,84 sonucu	35
Şekil 1.17.	Fractal_1 verisine eklenen dört anomali imzası	36
Şekil 1.18.	Cuprite verisi için spektral bant görseli	38
Şekil 1.19.	Salinas verisi için görsel sonuçlar (a) Spektral bant görüntüsü #120 (b) VCA ile bulunan son eleman konumları (c) ISODATA ile elde edilen bölgeler (d) RBSPP+VCA ile bulunan son eleman konumları (e) SSPP+VCA ile bulunan son eleman konumları (f) KRX ile bulunan anomali noktaları (g) RBSPP+KRX+VCA ile bulunan son eleman konumları (h) SSPP+KRX+VCA ile bulunan son eleman konumları	40
Şekil 2.1.	Makroskobik ve mikroskobik karışım	42
Şekil 2.2.	Doğrusal karışım ve doğrusal olmayan karışım	43
Şekil 2.3.	Son elemanlar ve spektral karışım analizi için "kuruyemiş tabağı" benzetimi	44
Şekil 2.4.	Kullanılan son eleman imzaları	48
Şekil 2.5.	Sentetik veri bolluk oranları	48
Şekil 2.6.	30dB SNR gürültülü veri üzerinden LS tabanlı yöntemlerle elde edilen bolluk oranları (a) Koşulsuz LS ile (b) SCLS ile (c) NSCLS ile (d) NCLS ile (e) NNCLS ile (f) FCLS ile	49
Şekil 2.7.	USGS kütüphanesinden alınan spektral imzalar	51

Şekil 2.8.	Saf son eleman içeren sentetik verideki bolluk oranları	52
Şekil 2.9.	Saf son eleman içeren sentetik veriden SPEE+FCLS ile elde edilen bolluk oranları	52
Şekil 2.10.	Saf son eleman içermeyen sentetik verideki bolluk oranları.....	54
Şekil 2.11.	Saf son eleman içermeyen sentetik veriden MVSA+FCLS ile elde edilen bolluk oranları	54
Şekil 2.12.	Saf son eleman içermeyen sentetik veriden SPEE+FCLS ile elde edilen bolluk oranları	54
Şekil 2.13.	Saf son eleman içermeyen gürültülü sentetik verideki bolluk oranları	55
Şekil 2.14.	Saf son eleman içermeyen gürültülü sentetik veriden MVSA+FCLS ile elde edilen bolluk oranları	56
Şekil 2.15.	Saf son eleman içermeyen gürültülü sentetik veriden NFINDR+FCLS ile elde edilen bolluk oranları	56
Şekil 2.16.	Hyperion verisi yer doğrusu haritası	58
Şekil 2.17.	Hyperion verisi en büyük bolluk oranı haritaları (a) N-FINDR 7 son eleman (b) N-FINDR 7 son eleman, $w_{spp} = 3$ (c) N-FINDR 7 son eleman, $w_{spp} = 5$ (d) N-FINDR 7 son eleman, $w_{spp} = 7$ (e) N-FINDR 11 son eleman (f) N-FINDR 11 son eleman, $w_{spp} = 3$ (g) N-FINDR 11 son eleman, $w_{spp} = 5$ (h) N-FINDR 11 son eleman, $w_{spp} = 7$ (i) VCA 7 son eleman (j) VCA 7 son eleman, $w_{spp} = 3$ (k) VCA 7 son eleman, $w_{spp} = 5$ (l) VCA 7 son eleman, $w_{spp} = 7$ (m) VCA 11 son eleman (n) VCA 11 son eleman, $w_{spp} = 3$ (o) VCA 11 son eleman, $w_{spp} = 5$ (p) VCA 11 son eleman, $w_{spp} = 7$	59
Şekil 2.18.	Hyperion verisi en büyük bolluk oranı haritaları - 2 (a) SPEE 7 son eleman (b) SPEE 11 son eleman (c) MVSA 7 son eleman (d) MVSA 11 son eleman (e) SISAL 7 son eleman (f) SISAL 11 son eleman	60
Şekil 2.19.	Hyperion verisi en büyük bolluk oranı eşiklenmiş haritaları (a) N-FINDR 7 son eleman (b) N-FINDR 7 son eleman, $w_{spp} = 3$ (c) N-FINDR 7 son eleman, $w_{spp} = 5$ (d) N-FINDR 7 son eleman, $w_{spp} = 7$ (e) N-FINDR 11 son eleman (f) N-FINDR 11 son eleman, $w_{spp} = 3$ (g) N-FINDR 11 son eleman, $w_{spp} = 5$ (h) N-FINDR 11 son eleman, $w_{spp} = 7$ (i) VCA 7 son eleman (j) VCA 7 son eleman, $w_{spp} = 3$ (k) VCA 7 son eleman, $w_{spp} = 5$ (l) VCA 7 son eleman, $w_{spp} = 7$ (m) VCA 11 son eleman (n) VCA 11 son eleman, $w_{spp} = 3$ (o) VCA 11 son eleman, $w_{spp} = 5$ (p) VCA 11 son eleman, $w_{spp} = 7$	61
Şekil 2.20.	Hyperion verisi en büyük bolluk oranı eşiklenmiş haritaları - 2 (a) SPEE 7 son eleman (b) SPEE 11 son eleman (c) MVSA 7 son eleman (d) MVSA 11 son eleman (e) SISAL 7 son eleman (f) SISAL 11 son eleman.....	62
Şekil 2.21.	Spektral bant görselleri (a) sentetik veri için (b) 10dB SNR gürültü uygulanmış veri için	67
Şekil 2.22.	Spektral bant görselleri (a) Sentetik veri. 10dB SNR uygulanmış veriden (b) FCLS ile geri oluşturulan veri (c) FLICM ile geri oluşturulan veri (d) Özgün FLICM ile geri oluşturulan veri ($\varphi = 0,5$).....	69

Şekil 2.23. AVIRIS Indian Pine verisi için elde edilen bolluk oranları (a) FCLS ile (b) FLICM ile (c) Özgün FLICM ile	69
Şekil 2.24. ROSIS Pavia University verisi için elde edilen bolluk oranları (a) FCLS ile (b) FLICM ile (c) Özgün FLICM ile	70
Şekil 2.25. Doğrusal olmayan spektral karışımlar.....	72
Şekil 2.26. 30dB SNR için bolluk haritaları (a) Gerçek bolluk haritaları (b) FCLS ile (c) FLICM ile (d) KFLICM ile	76
Şekil 2.27. 10dB SNR için bolluk haritaları (a) Gerçek bolluk haritaları (b) FCLS ile (c) FLICM ile (d) KFLICM ile	77
Şekil 2.28. KFLICM ile 10dB SNR'da elde edilen bolluk oranları (a) $\sigma^2 = 10$ (b) $\sigma^2 = 1000$	77
Şekil 2.29. Soldan sağa FLCS, FLICM ve KFLICM hata oranları (a) 10dB SNR (b) 30 dB SNR.....	78
Şekil 2.30. Indian Pine verisi için bolluk haritaları (a) FCLS ile (b) FLICM ile (c) KFLICM ile	79
Şekil 3.1. Uzamsal bağımlılık (a) Bolluk oranları (b) Olası bir piksel altı dağılımı (c) Uzamsal bağımlılık esasına göre en olası piksel altı dağılımı.....	82
Şekil 3.2. Verilen örnek için alt-piksel seviyesinde iki olası etiket dağılımı	83
Şekil 3.3. Uzamsal çözünürlük artırımı deneylerinde kullanılacak yaklaşım	86
Şekil 3.4. Sentetik son eleman imzaları.....	87
Şekil 3.5. (a) Yer doğrusu verisi (b) 3×3 oranında küçültülmüş yer doğrusu verisi	87
Şekil 3.6. Sentetik veri için (a) benzetimli tavlama öncesi dağılımı (b) benzetimli tavlama sonrası dağılımı.....	88
Şekil 3.7. AVIRIS Indian Pine verisi (a) yer doğrusu (b) alt-örneklenmiş yer doğrusu.....	88
Şekil 3.8. Sınıflandırma haritası (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için	89
Şekil 3.9. Bolluk oranları ile orantılı olarak uzamsal olarak rastgele dağıtılmış alt-pikseller (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için	90
Şekil 3.10. FCLS ve benzetimli tavlama sonucunda elde edilen alt-piksel dağılımı (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için	90
Şekil 3.11. FLICM ve benzetimli tavlama sonucunda elde edilen alt-piksel dağılımı (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için	91
Şekil 3.12. Hyperion verisi için alt-pikselde son eleman dağılımı.....	92
Şekil 3.13. Hyperion verisi parçası için alt-piksel seviyesinde uzamsal olarak rastgele dağılım ve benzetimli tavlama sonrası dağılım	92
Şekil 3.14. BPSO süreci	96
Şekil 3.15. Örnek parçacıklar	98
Şekil 3.16. Şekil 3.15'teki örnek parçacıklar için alt-piksel etiket dağılımları	98
Şekil 3.17. (a) Sentetik yer doğrusu (b) Son eleman imzaları.....	99

Şekil 3.18.	Sentetik veri için 3×3 alt-örneklemede sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği.....	100
Şekil 3.19.	Sentetik veri için 5×5 alt-örneklemede sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (50 parçacık) (d) Özgün yöntem sonucu (150 parçacık).....	102
Şekil 3.20.	Sentetik veri için 5×5 alt-örneklemede maliyet-yineleme grafikleri (a) Benzetimli tavlama ile (b) Özgün yöntem ile (50 parçacık) (c) Özgün yöntem ile (150 parçacık).....	103
Şekil 3.21.	Indian Pine ile oluşturulan sentetik veri için sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği	104
Şekil 3.22.	Pavia Üniversitesi verisi için sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği	106
Şekil 4.1.	Indian Pine verisi 30. spektral bant için iki boyutlu AKA (a) Orijinal bant görüntüsü (b) Birinci İKF (c) İkinci İKF (d) Üçüncü İKF (e) Artıklık işareti.....	113
Şekil 4.2.	Indian Pine verisi 29. spektral bant için iki boyutlu AKA (a) Orijinal bant görüntüsü (b) Birinci İKF (c) İkinci İKF (d) Üçüncü İKF (e) Artıklık işareti.....	113
Şekil 4.3.	GA işlem akışı.....	115
Şekil 4.4.	Indian Pine verisi 30. spektral bant için elde edilen bant görseli (a) İlk iki İKF eşit ağırlıkla toplandığında (b) İlk üç İKF eşit ağırlıkla toplandığında.....	117
Şekil 4.5.	Indian Pine verisi 30. spektral bant için elde edilen bant görseli (a) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (b) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında	117
Şekil 4.6.	Indian Pine verisi % 5 VEO'da sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında (c) İlk iki İKF eşit ağırlıkla toplandığında (d) İlk üç İKF eşit ağırlıkla toplandığında (e) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (f) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında	124
Şekil 4.7.	Pavia Üniversitesi verisi % 5 VEO'da sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında	127
Şekil 4.8.	Pavia Üniversitesi verisi % 5 VEO'da özgün yöntem ile elde edilen sınıflandırma haritaları -2 (a) İlk iki İKF eşit ağırlıkla toplandığında (b) İlk üç İKF eşit ağırlıkla toplandığında (c) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (d) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında	128

Şekil 4.9. Pavia Üniversitesi verisi yeni yer doğrusu ile sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında (c) İlk iki İKF eşit ağırlıkla toplandığında (d) İlk üç İKF eşit ağırlıkla toplandığında.....	129
Şekil 4.10. Pavia Üniversitesi verisi yeni yer doğrusu için özgün yaklaşım ile sınıflandırma haritaları - 2 (a) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (b) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında	130

TABLolar DİZİNİ

Tablo 1.1. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, N-FINDR ile.....	32
Tablo 1.2. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, VCA ile	32
Tablo 1.3. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, MVSA ile.....	32
Tablo 1.4. İki anomali içeren Fractal_1 verisinde SAD sonuçları, N-FINDR ile.....	34
Tablo 1.5. İki anomali içeren Fractal_1 verisinde SAD sonuçları, VCA ile.....	34
Tablo 1.6. İki anomali içeren Fractal_1 verisinde SAD sonuçları, MVSA ile.....	34
Tablo 1.7. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, N-FINDR ile.....	36
Tablo 1.8. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, VCA ile.....	36
Tablo 1.9. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, MVSA ile.....	37
Tablo 1.10. Anomali içermeyen Cuprite verisi için ortalama SAD sonuçları.....	38
Tablo 1.11. İki anomali içeren Cuprite verisi için ortalama SAD sonuçları	38
Tablo 2.1. LS tabanlı yöntemlere göre RMSE sonuçları.....	50
Tablo 2.2. Saf son eleman içeren sentetik veride sonuçlar.....	52
Tablo 2.3. Saf son eleman içermeyen sentetik veride sonuçlar.....	53
Tablo 2.4. Saf son eleman içermeyen gürültülü sentetik veride sonuçlar	55
Tablo 2.5. Hyperion verisinde sonuçlar.....	57
Tablo 2.6. Bulanık mantık ile spektral karışım analizinde $RMSE_{\text{bolluk}}$ sonuçları	68
Tablo 2.7. Bulanık mantık ile spektral karışım analizinde $RMSE_{\text{veri}}$ sonuçları	68
Tablo 2.8. Sentetik veri için $RMSE_{\text{bolluk}}$ sonuçları	78
Tablo 2.9. Sentetik veri için $RMSE_{\text{veri}}$ sonuçları.....	79
Tablo 3.1. Sınıflandırma başarımları.....	90
Tablo 3.2. Sentetik veri için ortalama hesaplar, 3×3	100
Tablo 3.3. Sentetik veri için ortalama hesaplar, 5×5	101
Tablo 3.4. Sentetik veri için sayısal sonuçlar	103
Tablo 3.5. Indian Pine ile oluşturulan sentetik veri için ortalama hesaplar.....	105
Tablo 3.6. Pavia Üniversitesi verisi için sayısal sonuçlar	106
Tablo 4.1. Indian Pine verisi yer doğrusu örnek sayıları.....	119
Tablo 4.2. Pavia Üniversitesi verisi yer doğrusu örnek sayıları.....	119
Tablo 4.3. DC Mall verisi yer doğrusu örnek sayıları	120
Tablo 4.4. Özgün yöntem için Indian Pine verisinde tespit edilen İKF ağırlıkları	121
Tablo 4.5. Indian Pine verisi için DVM sonuçları.....	122
Tablo 4.6. Indian Pine verisi ortalama (DC) değerler önceden çıkarılınca DVM sonuçları.....	122
Tablo 4.7. Indian Pine verisi için Bhattacharya uzaklıkları	123
Tablo 4.8. Indian Pine verisi tüm sınıflar kullanıldığında DVM sonuçları.....	125
Tablo 4.9. Pavia Üniversitesi verisinde tespit edilen İKF ağırlıkları	125
Tablo 4.10. Pavia Üniversitesi verisi için DVM sonuçları.....	125

Tablo 4.11. Özgün yöntem için DC Mall verisinde tespit edilen İKF ağırlıkları.....	126
Tablo 4.12. DC Mall verisi için DVM sonuçları.....	126
Tablo 4.13. McNemar testi sonuçları	127
Tablo 4.14. Gauss süreci yaklaşımı ile Indian Pine verisi için sonuçlar	131
Tablo 4.15. En yakın komşular yaklaşımı ile Indian Pine verisi için sonuçlar	131
Tablo 4.16. AKA öncesi SFBE (40 bant) kullanıldığında Indian Pine verisi için sonuçlar	132
Tablo 4.17. AKA sonrası SFBE (40 bant) kullanıldığında Indian Pine verisi için sonuçlar	133

SİMGELER DİZİNİ VE KISALTMALAR

C	: Uzamsal çözünürlük artırımı için maliyet fonksiyonu
$C_{b\phi}$	: Çekirdek uzayında arka plan ilintisi
d_{ij}	: Pikseller arası Öklid uzaklığı
e_k	: k . son eleman vektörü
e_{max}	: Üst zarf işareti
e_{ort}	: Ortalama zarf işareti
e_{min}	: Alt zarf işareti
E	: Özdeğer matrisi
F_k	: Gauss süzgeci
G_{ki}	: Bulanık yerel bilgi işlevi
IKF_l	: l . İçkin Kip Fonksiyonu
J	: Nesnel işlev
M	: Son eleman matrisi
$O(i)$	: Ortak olabilirlik fonksiyonu
$\tilde{O}(i)$	: Logaritmik ortak olabilirlik fonksiyonu
$\hat{R}_x$	: İlinti matrisi
q	: Son eleman sayısı
Q	: Son elemanların oluşturduğu yapının hacmi
$SpGrad$	: Spektral gradyan
w_{l_k}	: l spektral bandının k . İKF'si için elde edilen ağırlık
z_i	: i spektral bandındaki piksel değerleri
α	: Bolluk oranları
β_i	: i spektral bandının bağlanım vektörü
γ	: FLICM yumuşatma parametresi
δ	: FCLS'de negatif olmama kriterinin ağırlığı
ξ_i	: i spektral bandının gürültüsü
λ_k	: İlinti matrisinin k . özdeğeri
A_b	: Arka plan özdeğerlerinin köşegen matrisi
$\hat{\mu}_b$	: Arka plan ortalama vektörü
$\mu_{b\phi}$	: Çekirdek uzayında arka plan ortalaması
ρ_k	: Ortak değişinti matrisinin k . özdeğeri
σ_i^2	: i spektral bandı için değişinti
σ_{nk}^2	: k . spektral bant için gürültü değişintisi
$\hat{\Sigma}_b$	: Arka plan kovaryans matrisi
τ	: AKA için ampirik olarak belirlenen eşik değeri
φ	: FLICM yönteminde SAD uzaklığı ağırlık değişkeni

Kısaltmalar

AKA	: Ampirik Kip Ayrışımı
AKA-SG	: Ampirik Kip Ayrışımı – Spektral Gradyan Geliştirmeli
BPSO	: Binary Particle Swarm Optimization (İkili Parçacık Sürü Optimizasyonu)

CFAR	: Constant False Alarm Rate (Sabit Yanlış Alarm Oranı)
EEA	: Endmember Extraction Algorithm (Son Eleman Çıkarım Algoritması)
EML	: Eigenvalue Likelihood Maximization (Özdeğer Olabilirlik En Büyükleme)
FCLS	: Fully Constrained Least Squares (Tam Koşullu En Küçük Kareler)
FLICM	: Fuzzy Local Information C-Means (Bulanık Yerel Bilgi C-Ortalamlar)
FPGA	: Field Programmable Gate Array (Alan Programlanabilir Kapı Dizisi)
GA	: Genetik Algoritma
HFC	: Harsanyi-Farrand-Chang Yöntemi
HYSIME	: Hyperspectral Signal Identification by Minimum Error (En Küçük Hatayla Hiperspektral İşaret Belirleme)
KFLICM	: Kernel Fuzzy Local Information C-Means (Çekirdek Bulanık Yerel Bilgi C-Ortalamlar)
KRX	: Kernel Reed-Xiaoli Algorithm (Çekirdek Reed-Xialoi Algoritması)
LS	: Least Squares (En Küçük Kareler)
MVC-NMF	: Minimum Volume Constrained Nonnegative Matrix Factorization (En Küçük Hacim Kısıtla Negatif Olmayan Matris Faktörizasyonu)
MEI	: Morphological Eccentricity Index (Morfolojik Dışmerkezlik Endeksi)
MVES	: Minimum Volume Enclosing Simplex (En Küçük Hacim Kapsayan Simpleks)
MVSA	: Minimum Volume Simplex Algorithm (En Küçük Hacimli Simpleks Algoritması)
NCLS	: Nonnegatively Constrained Least Squares (Negatif Olmama Koşullu En Küçük Kareler)
NNCLS	: Normalize Edilmiş NCLS
NSCLS	: Normalize Edilmiş SCLS
ODVM	: Olasılıksal Destek Vektör Makineleri
OSP	: Orthogonal Subspace Projection (Dikgen Alt-uzay İzdüşümü)
PPI	: Pixel Purity Index (Piksel Saflık İndeksi)
PSO	: Parçacık Sürü Optimizasyonu
PSVM	: Probabilistic Support Vector Machines
RBF	: Radial Basis Function (Radyal Taban Fonksiyonu)
RBSP	: Region-Based Spatial Preprocessing (Alan-Tabanlı Uzamsal Önileme)
RX	: Reed-Xiaoli Algorithm (Reed-Xiaoli Algoritması)
PSO	: Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
SA	: Simulated Annealing (Benzetimli Tavlama)
SAD	: Spectral Angular Distance (Spektral Açısız Uzaklık)
SCLS	: Sum-to-one Constrained Least Squares (Bire Toplanma Koşullu En Küçük Kareler)
SFBE	: Sequential Forward Band Extraction (Ardışık İleri Bant Çıkarımı)
SISAL	: Simplex Identification via Split Augmented Lagrangian (Ayrık Genişletilmiş Lagrange ile Simpleks Tanımlama)
SNR	: Signal-to-Noise Ratio (İşaret-Gürültü Oranı)
SPP	: Spatial Preprocessing (Uzamsal Önileme)
SSPP	: Spatial-Spectral Preprocessing (Uzamsal-Spektral Önileme)
SVD	: Singular Value Decomposition (Tekil Değer Ayrışımı)
VCA	: Vertex Component Analysis (Zirve Bileşen Analizi)
VD	: Virtual Dimensionality (Sanal Boyutluluk)

HİPERSPEKTRAL GÖRÜNTÜLER İÇİN UZAMSAL YAKLAŞIMLAR

ÖZET

Hiperspektral görüntüler içerdikleri yüksek miktardaki spektral bilgi sayesinde sınıflandırma, tespit ve tanıma gibi görüntü işleme işlevlerinin standart görüntülere göre çok daha başarılı olarak gerçekleştirilebilmesini sağlamaktadır. Ancak hiperspektral görüntülerde, yüksek spektral çözünürlüğe rağmen, özellikle uydu sistemlerinde, platform veri saklama kapasitesi ve yer istasyonuna veri iletimi bant-genişliği gibi konulardaki teknik kısıtlamalardan dolayı, uzamsal çözünürlük genellikle düşüktür. Uzamsal çözünürlüğün yetersiz olduğu durumlarda, görüntüdeki piksellerin spektral yanıtı tek materyale ait olmamakta, son eleman adı verilen saf materyal spektrumlarının karışımı durumunda olmaktadır. Son eleman çıkarımı ve spektral karışım analizi için geliştirilen özgün yaklaşımlar ve başarımları artırma çalışmaları, hiperspektral görüntü işleme alanında son yıllarda en gündemde olan araştırma konuları haline gelmiştir.

Ancak son eleman analizi ve spektral karışım analizi yöntemlerinin çoğu, sınıflandırma ve tespit yöntemlerinde de olduğu gibi, spektral özelliklere dayanmaktadır ve uzamsal bilgiyi ihmal etmektedir. Bu durum, elde edilebilecek başarıyı kısıtlamaktadır. Bu tez kapsamında üzerine odaklanılmış olan iki bağlantılı konudan biri, hiperspektral görüntülerde son eleman çıkarımı, spektral karışım analizi ve sınıflandırma işlemlerinin uzamsal işleme kullanılarak başarımlarının artırılmasıdır.

Tez kapsamında çalışılan diğer konu ise hiperspektral görüntülerin uzamsal çözünürlüklerinin artırılmasıdır. Son eleman analizi ve spektral karışım analizi ile piksel altı seviyesinde bilgi edinmekle birlikte, verinin uzamsal çözünürlüğü gerçek anlamda artırılmamaktadır. Görüntü işleme alanında uzamsal çözünürlüğün artırılması için en sık kullanılan yaklaşım olan, yüksek uzamsal çözünürlüklü bir görüntü ile kaynaştırma yaklaşımı ise hiperspektral görüntü ile aynı bölgeden aynı zamanda / koşullarda elde edilmiş yüksek çözünürlüklü ayrı bir görüntü gereksinimi yüzünden kısıtlı uygulamaya sahiptir. Bu yüzden, bu tez kapsamında hiperspektral verilerin uzamsal çözünürlüklerinin ek bir görüntü kullanılmadan artırılması üzerinde çalışılmıştır.

Anahtar Kelimeler: Hiperspektral Görüntü İşleme, Sınıflandırma, Son Eleman Çıkarımı, Spektral Karışım Analizi, Uzamsal Çözünürlük.

SPATIAL APPROACHES FOR HYPERSPECTRAL IMAGES

ABSTRACT

Hyperspectral images, with the large amount of spectral information they contain, provide increased capability of image processing tasks such as classification, detection, and recognition with respect to standard images. However, in hyperspectral images, despite high spectral resolution, spatial resolution is generally low, especially in satellite systems, due to technical limitations such as platform data storing capacity and ground station data transfer bandwidth. When the spatial resolution is inadequate, the spectral responses of pixels do not belong to a single material, but are a mixture of pure material spectrums, called endmembers. Novel approaches and performance enhancing studies developed for endmember extraction and spectral mixture analysis have become the prominent research subjects in hyperspectral image processing field, in recent years.

Nevertheless, similar to classification and detection methods, most endmember extraction and spectral mixture analysis methods rely on spectral properties and disregard spatial information. This situation limits the performance that can be achieved. One of the two related topics focused on within the scope of this thesis is enhancing the performance of endmember extraction, spectral mixture analysis and classification processes by utilizing spatial information.

The other subject studied in the scope of this thesis is spatial resolution enhancement of hyperspectral images. While sub-pixel level information is acquired with endmember extraction and spectral mixture analysis, spatial resolution of the data is not enhanced in real terms. The most commonly used approach to increase spatial resolution in image processing field, fusion with a high spatial resolution image, has limited applicability due to the need for a high spatial resolution image of the same location, acquired in the same time / conditions as the hyperspectral image. Therefore, within the scope of this thesis, spatial resolution enhancement of hyperspectral images without using an additional image is studied.

Keywords: Hyperspectral Image Processing, Classification, Endmember Extraction, Spectral Mixture Analysis, Spatial Resolution.

GİRİŞ

Uzaktan algılama, insan doğasında yer alan çevresini keşfetme ve anlama ihtiyacının doğal bir uzantısı olan bir teknoloji olup, dünyadan bilgi edinme ve bu bilgiyi algılayabileceğimiz bir şekilde sunma ve değerlendirme esasına dayanmaktadır. Hiperspektral görüntüleme ise uzaktan algılama alanındaki en güçlü araçlardan biridir. Standart görüntü algılayıcıları geniş bir dalga boyu aralığında yansıyan ışığı tek veya az sayıda dalga boyu aralığında birleştirirken, hiperspektral görüntü algılayıcıları genel olarak 0,4 – 2,5 μm dalga boyu aralığında, yani görünür bölge, yakın kızılötesi ve orta kızılötesi bölgelerinden, her biri en çok 10 – 20 nm bant genişliğine sahip yüzlerce spektral bantta görüntü toplayabilmektedir.

Hiperspektral sistemlerle alınan görüntüde her görüntü elemanı için dalga boyuna bağlı neredeyse sürekli bir spektrum bilgisi elde edilmektedir. Bu yüksek miktardaki spektral bilgi sayesinde hiperspektral görüntülerdeki görüntü elemanlarının değişimi, benzerlik ve farklılıkları optik veya çoklu spektral (multispektral) görüntülere göre çok daha başarılı olarak hesaplanabilmektedir [1]. Bu da hiperspektral görüntü kullanılarak yapılan sınıflandırma, tanıma, tespit gibi görüntü tanıma işlevlerinin hiperspektral görüntü işleme ile optik ve çoklu-spektral görüntü işlemeye göre çok daha yüksek başarımlı gerçekleştirilebilmesini sağlamaktadır [1].

Hiperspektral görüntü işlemede temel olarak kullanılan araç, spektral imza kavramıdır [2]. Bir malzemenin dalga boyuna göre elde edilen spektral yansıma oranı eğrisine o malzemenin spektral imzası adı verilmektedir. Her malzemenin yansıttığı, yaydığı ve soğurduğu elektromanyetik radyasyon, dalga boyuna göre ve malzemenin içkin fiziksel yapısı ve kimyasal bileşenlerine bağlı olarak farklılık göstermektedir. Spektral imza her malzeme ve kimyasal yapı için farklı ve eşsiz olduğundan, görsel olarak ayırım yapılamayan durumlarda dahi yüksek ayırıştırma yeteneği sağlamaktadır.

Hiperspektral görüntü işleme, gelişmekte olan bir araştırma alanı olup, uygulama alanları oldukça yaygındır. Bu uygulama alanları arasında arkeoloji, çevre, geri-

dönüşüm, gıda, ilaç sanayi, madencilik, ormancılık, savunma, şehir planlama, tarım, tekstil ve tıp gibi niceleri sayılabilir. Örnek uygulamalar arasında, gıda alanında tazelik ve nemlilik kontrolü; yağ/şeker/protein içeriği ve dağılımı ölçümü; ilaç sanayi alanında ilaçlarda etkin maddelerin ve dağılımlarının tespiti; madencilik alanında hızlı ve düşük masraflı petrol, mineral, maden ve doğal taş rezervi keşfi; savunma alanında hedef ve gömülü mayın tespiti; geri-dönüşümde atık sınıflandırılması gibi birçok uygulama sayılabilir.

Hiperspektral görüntü işlemenin önemi arttıkça, yüksek uzamsal çözünürlük gerektiren uygulamalarda hiperspektral görüntü işlemenin başarımından faydalanma isteği de artmaktadır. Görüntü sınıflandırmada da yüksek başarımlar, sonuçların güvenilirliği ve detaylı içerik gibi gerekliliklerin karşılanabilmesi için hem yüksek spektral hem de yüksek uzamsal çözünürlüğe aynı anda ihtiyaç duyulmaktadır [3]. Ancak hiperspektral görüntüler yüksek spektral çözünürlüklerine rağmen genel olarak düşük uzamsal çözünürlüğe sahiptir. Günümüzde aktif ve erişilebilir uydulardan elde edilen hiperspektral imgelerin uzamsal çözünürlüğü genel olarak 20-30m aralığındadır. Uydu sistemlerinde yüksek uzamsal çözünürlüklere sahip algılayıcıların tasarımı platform veri saklama kapasitesi ve imgelerin uydudan yer istasyonuna iletim bant-genişliği gibi teknik nedenlerden ötürü henüz mümkün olamamaktadır [4]. Uçak platformlarından alınan hiperspektral imgelerde, düşük irtifada 2-3 m uzamsal çözünürlüğe ulaşılabilen, fakat bu durumda görüntülenebilen alan küçülmektedir. Ayrıca, uçak platformundan elde edilen hiperspektral imgeler büyük maliyetler getirdiklerinden, özel uygulamalar dışında kullanımlarının verimi tartışmalıdır. Uzamsal çözünürlüğün yetersiz olduğu durumlarda ise görüntüdeki pikseller tek bir materyale ait olmamakta, son eleman adı verilen saf materyal spektrumlarının birer karışımı durumunda olmaktadır. Bu noktada, veri hakkında piksel-altı seviyesinde bilgi elde edebilmek için son eleman çıkarımı ve spektral karışım analizi yaklaşımları kullanılmaktadır.

Bu tez kapsamında gerçekleştirilen çalışmalar iki grupta toplanabilir. İlk grupta son eleman çıkarımı, spektral karışım analizi ve sınıflandırma işlemlerinin başarımının artırılması yer almaktadır. Başarımların artırımı için verideki uzamsal bilgilerin verimli bir şekilde değerlendirilmesi ile uzamsal işleme ve spektral işlemeyi bir arada kullanan yaklaşımlar üzerinde durulmuştur.

Tez kapsamında alıřılan diğerkonu ise hiperspektral grntlerin uzamsal znrlklerinin artırılmasıdır. Yksek spektral znrlkl grntlerin dřk olan uzamsal znrlğn arttırmak iin literatrde en sık kullanılan yaklařım bu grntlerin yksek uzamsal znrlkl bir grnt ile kaynařtırılması, bařka bir deyiřle yksek uzamsal znrlkl grntdeki bilgilerin dřk uzamsal znrl grntye yklenmesidir. Ancak, iki farklı grntleme sistemi ile elde edilmiř grntler arasındaki akıřtırma sorunları ve daha temel bir kısıt olan, hiperspektral grnt ile aynı blgeden aynı zamanda/kořullarda elde edilmiř yksek uzamsal znrlkl ayrı bir grnt gereksinimi bu yaklařımın kullanılabilirliğini ciddi lde sınırlamaktadır. Bu nemli sınırlandırmalar yznden, bu tez kapsamında hiperspektral grntlerin uzamsal znrlklerini ve dolayısıyla bu grntlerden elde edilecek sınıflandırma bařarımlarını, yksek uzamsal znrlkl bir grnt kullanmadan, grntnn ikin zelliklerini kullanarak arttıracak zgn yntemler zerine alıřılmıřtır. Bu amala son eleman ıkarımı, spektral karıřım analizi ve uzamsal bağımlılık esasına gre alıřan yaklařımların bir arada kullanılması zerinde durulmuř ve katkılar elde edilmiřtir.

Bu tez kapsamında geliřtirilen zgn yntemler ařağıdaki řekilde zetlenebilir:

Son eleman ıkarımında, uzamsal n-iřleme yntemleri ile son eleman ıkarımı bařarımının arttırılabildiğiliteratrdeki alıřmalarda gzlemlenmiřtir. Bu amala kullanılan n-iřleme yaklařımlarının nemli bir kısmı, son eleman ıkarımını homojen blgelere ynlendirmekte, bylece son elemanların geiř blgeleri yerine homojen blgelerden ve daha saf olarak elde edilmesi ihtimali arttırılmaktadır. Ancak bu tr bir yaklařım ile anomali noktaları ve dolayısıyla anomali son elemanlarının tespiti imkansız olmaktadır. Son eleman ıkarımı ve spektral karıřım analizi ile, zellikle “byk veri” problemi iin nemli olan, anlamlı bir veri zeti elde edildiğigz nne alındığında, kullanıcı iin nem tařıyabilecek anomali son elemanlarının kaırılmasının olumsuz etkisi anlařılmaktadır. Bu tez kapsamında geliřtirilen zgn yaklařım sayesinde uzamsal n-iřleme ile anomali tespitini birleřtiren bir n-iřlem uygulanarak, son elemanların geiř blgeleri yerine homojen blgelerden ve anomali noktalarından seilmesi saėlanmaktadır ve bu yaklařımla son eleman ıkarımı bařarımının arttırılabildiğigsterilmektedir.

Verideki uzamsal bilgilerin bulanık olarak spektral karışım analizine dahil edilmesi ile daha yumuşak geçişli bolluk haritaları elde edildiği literatürdeki çalışmalarda gösterilmiştir. Bu tez kapsamında uzamsal ve spektral işlemeyi pekiştirmeli olarak birleştirmek amacıyla spektral uzaklık tabanlı bulanık mantık ile spektral karışım analizi yöntemi özgün olarak geliştirilmiştir.

Verinin spektral bantları arasındaki veya ele alınan problemdeki doğrusal olmayan ilişkiler, çekirdek (kernel) yaklaşımları kullanılarak, doğrusal olmayan fonksiyon net şekilde bilinmese de sağlanabilmekte, bu sayede yüksek başarımlı elde edilebilmektedir. Bu tez kapsamında, literatürdeki çekirdek uzayında en küçük kareler tabanlı spektral karışım analizi yaklaşımlarına benzer olarak, çekirdek uzayında bulanık mantık ile spektral karışım analizi yöntemi özgün olarak geliştirilmiştir.

Hiperspektral görüntülerde uzamsal çözünürlük artırımı için ikili (binary) parçacık sürü optimizasyonu ile uzamsal bağımlılık esasına dayanan bir çözünürlük artırımı yaklaşımı özgün olarak geliştirilmiştir. Geliştirilen yüksek başarımlı yaklaşım, literatürdeki benzer yöntemlere göre paralelleştirilmeye çok daha fazla yatkındır. Yöntemin ardışık işlem yükü yüksek olmakla birlikte, paralelleştirmeye yüksek yatkınlığı ve donanım mimarisine uygunluğu sayesinde paralel işleme mimarisi ile çok daha düşük işlem süresine ulaşmak mümkün olacaktır.

Ampirik kip ayrışımı yönteminin hiperspektral görüntü sınıflandırma başarımlarını, sınıflandırma öncesine uzamsal işleme dahil ederek, arttırdığı önceki çalışmalarda gösterilmiştir. Bu tez kapsamında, uzamsal ve spektral işlemeyi birleştiren, ampirik kip ayrışımı ve spektral gradyan tabanlı özgün bir yöntem geliştirilerek yüksek sınıflandırma başarımları elde edilmiştir. Geliştirilen yöntem ile elde edilen başarımlar standart ampirik kip ayrışımı yaklaşımına göre istatistiki açıdan önemlidir.


Bu tez aşağıdaki şekilde düzenlenmiştir.

Bölüm 1’de son eleman çıkarımı işlenmiş, son eleman çıkarımı için literatürdeki farklı yaklaşımlar incelenmiş ve geliştirilen özgün yöntem tanıtılarak deneysel sonuçlar paylaşılmıştır. Bölüm 2’de spektral karışım analizi üzerinde durulmuş, doğrusal karışım analizi için literatürde önde gelen en küçük kareler tabanlı

yöntemler aktarılmış ve son eleman çıkarımı ile birlikte kapsamlı deneysel sonuçlar sunulmuştur. Ayrıca bu bölümde bulanık mantık ile spektral karışım analizi işlenmiş, bu alanda geliştirilen özgün yaklaşımlar ve deneysel sonuçlar paylaşılmıştır. Bölüm 3’de ek bir görüntü kullanmadan uzamsal çözünürlüğün arttırılması için kullanılan uzamsal bağımlılık esasına göre çözünürlük artırımı yaklaşımı açıklanmıştır. Bu bölümde, literatürde yer alan güncel bir yaklaşım ve bu tez kapsamında özgün olarak gerçekleştirilen ikili parçacık sürü optimizasyonu temelli yaklaşım detaylı olarak işlenmiş, sentetik ve gerçek verilerde deneysel sonuçlar sunulmuştur. Bölüm 4’te ise uzamsal ve spektral işleme ile hiperspektral verilerde sınıflandırma başarımının artırılması için geliştirilen ampirik kip ayrışımı ve spektral gradyan temelli özgün yaklaşım açıklanmış ve elde edilen deneysel sonuçlar aktarılmıştır.

1. SON ELEMAN ÇIKARIMI

Hiperspektral görüntüler iki uzamsal boyut ve bir spektral boyut olmak üzere veri küpü şeklindedir. Görüntüdeki her piksel için dalga boyuna göre bir yansıma elde edilmekte ve materyallere ait yansıma eğrilerine o materyalin spektral imzası adı verilmektedir. Hiperspektral veri yapısı ve spektral imza kavramı Şekil 1.1’de görülmektedir.



Şekil 1.1. Hiperspektral veri ve spektral imzalar [5]

Hiperspektral verilerde piksellerin içerdiği çok miktardaki bilgi, spektral imza kavramı ile birlikte kullanılarak, sınıflandırma, tanıma ve tespit gibi görüntü işleme uygulamalarında standart görüntülere göre yüksek başarımlar sağlamaktadır. Ancak bu tür görüntü işleme uygulamalarının çoğu her pikselin tek bir materyalin tepkisinden oluştuğunu varsaymakta olmasına rağmen, hiperspektral verilerde, düşük uzamsal çözünürlük, mikroskobik karışımlar ve çoklu saçılım sonucu, ölçülen spektrumlar saf materyallerin spektrumları olmayıp, bu spektrumların birer karışımı şeklinde olmaktadır [5]. Başka bir deyişle, görüntü elemanları için elde edilen yansıma eğrileri materyallerin saf olarak bulundukları hallerdeki yansıma eğrilerinin birer karışımı olarak elde edilmektedir.

Materyallerin saf olarak bulundukları hallerin spektral imzalarına son eleman, bir hiperspektral veriden saf spektral imzaları elde etme problemine ise son eleman çıkarımı adı verilmektedir. Ancak ilgilenilen saf materyaller probleme bağlı olarak değişebilir. Örneğin yere döşenmiş tuğlalar, tuğlaların arasındaki harç ve tuğlalardaki çatlaklarda büyüyen iki tür bitki içeren bir hiperspektral veride, diğer materyallerin kapladığı alan küçük olduğundan dolayı ilgilenilen tek son eleman tuğla olabilir. Benzer şekilde, iki bitki türü arasında ayırıştırma yapmamak ve dolayısıyla tuğla, harç ve bir bitki son elemanı çıkarmak istenebilir. Ancak bitkilerden birinin zararlı olduğu bir durumda iki bitki türünün son elemanları da önemli olacaktır [5]. Bu örnekten de anlaşılacağı üzere, istenen son elemanlar veriye ve probleme göre değişebilmektedir.

Literatürde yer alan çoğu son eleman çıkarımı yönteminde hiperspektral verinin dışbükey bir geometride dağılmış olduğu varsayımı yapılmakta ve son elemanların tespitinde bu varsayımdan yararlanılmaktadır. Ancak bu yaklaşım verideki tüm pikselleri oluşturan son eleman sayısının bilinmesini gerektirmektedir. Bu yüzden literatürde çeşitli son eleman sayısı tespiti yöntemleri geliştirilmiştir.

1.1. Son Eleman Sayısı Tespiti

Hiperspektral verilerde boyut azaltımında ve son eleman çıkarımı yöntemlerinin başarımında verideki son eleman sayısı büyük önem taşımaktadır. Bu sayı olması gerekenden daha düşük bir sayı olarak alınırsa çıkarılan son elemanlar saf olmak yerine karışımli olacaktır [6]. Son eleman sayısı gerçek son eleman sayısından büyük alınırsa ise bu sefer de aynı materyale ait gürültü etkisine maruz kaldığından dolayı farklılaşmış son elemanlar elde edilebilmektedir [6].

Son eleman sayısı tespiti için hiperspektral verinin spektral boyutluluğu, bir başka deyişle en az kaç adet spektral imza kullanılarak en düşük kayıpla ifade edilebileceği, kestirilmektedir. Bu amaçla geliştirilen yaklaşımlar arasında sanal boyutluluk (virtual dimensionality, VD) kavramı dikkat çekmektedir. Bu kavram [7]'de önerilmiş ve [8]'de geliştirilmiş olup, hiperspektral verideki spektral olarak ayrık imza sayısını betimlemektedir. Bu kavram üzerine geliştirilen Harsanyi-Farrand-Chang yöntemi (HFC) [9], literatürde en sık kullanım bulan son eleman sayısı tespiti yöntemlerindendir.

Bu bölüm kapsamında HFC, literatürde çok sık kullanım bulan diğer bir son eleman sayısı tespiti yöntemi olan En Küçük Hatayla Hiperspektral İşaret Belirleme (Hyperspectral Signal Subspace Identification by Minimum Error-HySime) [10], ve daha güncel bir yöntem olan Özdeğer Olabilirlik En Büyükleme (Eigenvalue Likelihood Maximization-EML) [6] detaylı olarak aktarılacaktır.

1.1.1. HFC

HFC, hiperspektral verinin ortak değişinti ve ilinti (korelasyon) matrislerinin özdeğerlerini kullanan bir son eleman sayısı tespiti yaklaşımıdır. HFC’de ilk aşamada verinin ilinti matrisi R ve ortak değişinti matrisi K kestirilir. İlinti matrisinin özdeğerleri λ vektörü, ortak değişinti matrisinin özdeğerleri ise ρ vektörü ile ifade edildiğinde ve gürültünün de sıfır ortalamalı beyaz gürültü olduğu varsayıldığında Denklem (1.1) ve (1.2)’ye ulaşılır;

$$\lambda_k > \rho_k > \sigma_{nk}^2, \quad k = 1, \dots, q \quad (1.1)$$

$$\lambda_k = \rho_k = \sigma_{nk}^2, \quad k = q + 1, \dots, L \quad (1.2)$$

Burada σ_{nk}^2 k . spektral kanal için gürültü değişintisini, q verinin spektral boyutluluğunu, L ise toplam spektral bant sayısını göstermektedir. Bu denklem ikilisinin açıklaması olarak, gürültüye karşılık gelen özdeğerlerin ortak değişinti ve ilinti matrislerinde aynı olduğu ve işarete (son elemanlara) karşılık gelen özdeğerler için ilinti matrisi özdeğerlerinin ortak değişinti matrisi özdeğerlerine göre daha büyük olduğu bilgisi belirtilebilir.

Bu aşamada $z_i = \lambda_i - \rho_i$ tanımlaması yapılarak ve Neyman-Pearson testi ile z_i eşiklenerek son eleman sayısı q tespit edilir. Ancak bunun uygulanması için hatalı alarm değerinin sabitlenmesi gerekmektedir. Hatalı alarm değeri için genel olarak 0,001, 0,0001 veya 0,00001 kullanılmaktadır.

1.1.2. HySime

HySime, verinin bit alt-uzaya izdüşümü alındığında oluşan hatanın en aza indirgenmesi esasına dayanan özdeğer ayrıştırması temelli eğitimsiz ve değişkenlerden bağımsız bir yöntemdir [10].

Yöntem ilk olarak çoklu bağlanım (regresyon) ile işaret ve gürültü ilinti matrislerini kestirmektedir. Gürültü kestirimi için, L spektral bant, N piksel sayısı olmak üzere, gürültü içeren veri $N \times L$ boyutlu Z matrisi ile ifade edildiğinde, z_i verideki i spektral bandında tüm piksellerin değerlerini içeren bir vektör olmaktadır. $Z_{\partial i} = [z_1, \dots, z_{i-1}, z_{i+1}, \dots, z_L]$ ise $N \times (L - 1)$ boyutlu bir veri olmaktadır. z_i diğer spektral bantların doğrusal bir birleşimi olarak,

$$z_i = Z_{\partial i} \beta_i + \xi_i \quad (1.3)$$

ile ifade edilebilir. $\beta_i (L - 1) \times 1$ boyutlu bağlanım vektörü, ξ_i ise $N \times 1$ boyutlu model hatası vektörüdür. Bağlanım vektörü, en küçük kareler yöntemi ile,

$$\hat{\beta}_i = (Z_{\partial i}^T Z_{\partial i})^{-1} Z_{\partial i}^T z_i \quad (1.4)$$

şeklinde kestirildiğinde, gürültü vektörü,

$$\hat{\xi}_i = z_i - Z_{\partial i} \hat{\beta}_i \quad (1.5)$$

ile bulunmaktadır. Bu durumda gürültü ilinti matrisi ise, gürültü sıfır ortalamalı kabul edildiğinde,

$$\hat{R}_n = [\hat{\xi}_1, \dots, \hat{\xi}_N]^T [\hat{\xi}_1, \dots, \hat{\xi}_N] / N \quad (1.6)$$

ile elde edilmektedir. Sonraki adımda ise işaret alt-uzayı işaret ilinti matrisine ait özvektörlerin bir alt-kümesi kullanılarak ifade edilmekte ve işaret ile gürültülü izdüşümü arasındaki fark en aza indirilerek tespit edilmektedir. Gürültü sıfır ortalamalı Gauss dağılımlı kabul edilmekte ve x işareti için ilinti matrisi, özdeğer ayrıştırması ile,

$$\hat{R}_x = [\hat{x}_1, \dots, \hat{x}_N]^T [\hat{x}_1, \dots, \hat{x}_N] / N \quad (1.7)$$

$$\hat{R}_x = E \Sigma E^T \quad (1.8)$$

şeklinde yazılmaktadır. Bu denklemde E ve Σ , $\hat{R}_x$ 'e ait özvektör ve özdeğer matrisleridir. E matrisi birbirine dik iki parçaya ayrılır, $E_k \equiv [e_{i1}, \dots, e_{ik}]$ ve $E_k^\perp \equiv [e_{ik+1}, \dots, e_{iL}]$. İşaretin $\langle E_k \rangle$ üzerine izdüşümü, gürültülü veri vektörü $y = x + n$ kullanılarak,

$$\hat{x}_k = U_k y = E_k E_k^T y \quad (1.9)$$

şeklinde elde edilmektedir. En küçüklenmesi istenen hata ise,

$$H(k|x) = E[(x - \hat{x}_k)^T (x - \hat{x}_k) | x] \quad (1.10)$$

ile tespit edilir. Bu denklemde $\hat{x}_k = U_k(x + n)$ ve $\hat{x}_k$ 'nin birinci momenti $x_k = U_k x$ kullanılarak,

$$H(k|x) = E[(x - x_k - U_k n)^T (x - x_k - U_k n) | x] \quad (1.11)$$

elde edilir. Bu denklem,

$$H(k|x) = b_k^T b_k + \text{tr}(U_k \hat{R}_n U_k^T) \quad (1.12)$$

şeklinde de ifade edilebilir. Bu denklemde $b_k = x - x_k = U_k^\perp x$ olmakta ve $U = U^T$, $U^2 = U$ ve $U^\perp = I - U$ özellikleri dikkate alındığında,

$$H(k|x) = \text{tr}(U^\perp R_y) + 2\text{tr}(U_k \hat{R}_n) \quad (1.13)$$

sonucuna ulaşılmaktadır. İşaret alt-uzayını tespit etmek için, her k ve her permütasyon $\pi = \{i_1, \dots, i_L\}$ 'a göre Denklem (1.13)'teki fark değerini en küçüklemek gerekmektedir.

Denklem (1.13),

$$(\hat{k}, \hat{\pi}) = \arg \min_{k, \pi} \left\{ \sum_{j=1}^k -e_{i_j}^T \hat{R}_y e_{i_j} + 2 - e_{i_j}^T \hat{R}_n e_{i_j} \right\} \quad (1.14)$$

şeklinde tekrar yazılabilir. Bu ifade,

$$(\hat{k}, \hat{\pi}) = \arg \min_{k, \pi} \left\{ \sum_{j=1}^k \delta_{i_j} \right\} \quad (1.15)$$

şeklinde sadeleştirilmektedir. Bu denklemin en küçüklenmesini sağlayan özvektör sayısı verinin boyutluluğunu, dolayısıyla da kaç son eleman içerdiği bilgisini vermektedir.

1.1.3. EML

EML yöntemi, yakın zamanda geliştirilmiş olan, parametrelerden arınmış ve hızlı bir son eleman sayısı kestirimi yöntemidir [6]. Yöntem temel olarak, HFC gibi, hiperspektral verinin ilinti ve ortak değişinti matrislerinin özdeğerlerinin farklarına dayanmaktadır. HFC yönteminde olduğu gibi z_i değerleri elde edildikten sonra, bu değerlerin dağılımı Gauss dağılımı olarak,

$$z_i \sim \mathcal{N}(\mu_i, \sigma_i^2) \quad , \quad i \leq q \quad (1.16)$$

$$z_i \sim \mathcal{N}(0, \sigma_i^2) \quad , \quad i > q \quad (1.17)$$

şeklinde modellenmektedir. Bu denklem ikilisindeki μ_i ortalaması bilinmemekte olup, örnek sayısı yeterince büyük olduğunda değişinti $\sigma_i^2 \approx (2 / N)(\lambda_i^2 + \rho_i^2)$ ile elde edilir. Ortak bir olabilirlik fonksiyonu,

$$O(i) = \prod_{l=i}^q \frac{1}{\sigma_l} \exp\left(-\frac{z_l^2}{2\sigma_l^2}\right) \quad (1.18)$$

şeklinde tanımlanmaktadır. Logaritmik olarak,

$$\check{O}(i) = -\sum_{l=i}^q \frac{z_l^2}{2\sigma_l^2} - \sum_{l=i}^q \log \sigma_l \quad (1.19)$$


Sinyal bolluğu oranı yeterince fazlaysa, $i < q$ durumu için μ_i sıfıra yakın olmamakta, z_i büyük olduğundan dolayı da (1.19)'daki ilk terim sıfıra yakın olmaktadır. $i > q$ durumunda ise bu terim çok daha büyük bir değer almaktadır. Üstelik hiperspektral verinin değerleri $[0 - 1]$ aralığında normalize edildiğinde $-\log(\sigma_i)$ değeri pozitif olmakta ve i arttıkça Denklem (1.19)'daki $-\sum_{l=i}^q \log \sigma_l$ terimi küçülmektedir. Bu durum sonucunda $\check{H}(i)$ fonksiyonunun global maksimumu $i = q + 1$ değerinde elde edilmektedir. Başka bir deyişle, verideki son eleman sayısı,

$$q = \arg \max_i \{\check{O}(i)\} - 1 \quad (1.20)$$

ile elde edilmektedir.

1.2. Son Elemanların Veride Saf Olarak Bulunduğunu Varsayan Son Eleman Çıkarımı Yöntemleri

Hiperspektral verilerden son eleman çıkarımı için literatürde geliştirilmiş birçok yöntem bulunmaktadır. Bu yöntemlerin çoğunluğu verideki piksel vektörlerinin bu son elemanların spektral imzalarının doğrusal birer karışımı olduğunu varsaymakta ve hiperspektral veriyi bu son elemanlara göre dışbükey bir geometride dağılmış olarak modellemektedir. Şekil 1.2’de iki boyutlu uzayda dağılmış veri noktaları ve bu noktaları dışbükey bir yapıda kapsayan son elemanlar şeklinde görülmektedir.




Şekil 1.2. Son elemanların oluşturduğu, dışbükey geometride dağılmış veri

Bununla beraber, son eleman çıkarımı yaklaşımları genel olarak iki farklı grupta değerlendirilebilir. Bu gruplar, son elemanların veride saf olarak bulunduğu varsayan ve bu varsayımı yapmayan yöntemlerdir. Son elemanların veride saf olarak bulunduğunu varsayan yöntemler veriyi modelleyen dışbükey yapının köşegen noktalarının veride bulunduğunu varsaymakta ve bu veri noktalarını tespit etmeyi amaçlamaktadır. Bu gruba giren son eleman çıkarımı yöntemleri arasında piksel saflık indeksi (Pixel Purity Index–PPI) [11], dikgen alt-uzay izdüşümü (Orthogonal Subspace Projection–OSP) [12], N-FINDR [13] ve zirve bileşen analizi (Vertex Component Analysis–VCA) [14] gibi yöntemler sayılabilir. Bu tez kapsamında, literatürde bulunan her son eleman çıkarımı yöntemi açıklanmayacak olup, sadece ilerleyen bölümlerde kullanılmış olan N-FINDR ve VCA yöntemleri ile ilgili detaylı bilgi verilecektir. Bu iki yöntemin tercih edilmesi, diğer yöntemlere göre daha yüksek başarımlarından ve literatürdeki yaygınlıklarından kaynaklanmaktadır. Okuyucu diğer yöntemler ile ilgili detaylar için ilgili referanslara yönlendirilmektedir.

1.2.1. N-FINDR

N-FINDR yönteminde, veri içinden son eleman sayısı kadar ve veri uzayındaki en büyük simpleks yapıyı oluşturan veri noktaları tespit edilmektedir. Bu işlem Şekil 1.3’de sadeleştirilmiş olarak gösterilmektedir. Dört adet son eleman için, rastgele seçilmiş dört veri noktasının oluşturduğu simpleks yapı Şekil 1.3 (a)’da, veride dört veri noktası ile oluşturulabilecek en büyük simpleks yapı ise Şekil 1.3 (b)’de görülmektedir.



Şekil 1.3. Veride oluşturulan simpleks yapılar (a) Rastgele seçilmiş veri noktaları için (b) Son elemanlar için [15]


N-FINDR işlemi için, veride eğer k adet son eleman varsa veri öncelikle temel bileşenler analizi yöntemi ile bant çıkarımı yapılarak $(k-1)$ boyuta indirgenmektedir. Bunun nedeni k adet son elemanın k köşeli simpleks yapıyı $(k-1)$ boyutlu düzlemde oluşturmasıdır. Elde edilen düzlemde en büyük hacme sahip simpleksi oluşturan veri elemanlarını tespit etmek için matris determinanı kullanılmaktadır. Hacim hesabı için determinanı alınan matris,

$$M = \begin{bmatrix} 1 & 1 & \dots & 1 \\ e_1 & e_2 & \dots & e_k \end{bmatrix}_{k \times k} \quad (1.21)$$

şeklinde olup, i numaralı aday son eleman vektörü e_i ile gösterilmektedir. En büyük determinant değerinin elde edildiği k adet veri noktası, en büyük hacimli simpleks yapıyı oluşturan noktalar olup, bu noktalar son elemanlar olarak kabul edilmektedir.

1.2.2. VCA


VCA, boyut indirgeme sonrası, yinelemeli olarak, ilgili yineleme sayısına kadar tespit edilen son elemanların oluşturduğu alt-uzaya dik yönde verinin izdüşümünü almaktadır. Bu izdüşümü işlemi sırasında oluşan dışbükey koni yapısının son elemanların oluşturduğu alt-uzaya izdüşümü bir simpleks yapı oluşturmaktadır. Oluşan simpleks yapısı S_p 'nin f_1 vektörü üzerine izdüşümü alınarak uç nokta m_a elde edilmekte, m_a 'ya dik olan f_2 vektörü üzerine izdüşümü alınarak ise m_b noktası tespit edilmektedir. Bu işlem son eleman sayısı kadar nokta elde edilene kadar sürmektedir. İzdüşümler için tekil değer ayrışımı (Singular Value Decomposition-SVD) kullanılmaktadır. VCA işlemi Şekil 1.4'te görselleştirilmiştir. VCA işlemsel olarak OSP yöntemine benzemekte olup, temel fark VCA'da işlem öncesi gürültü karakterizasyonu uygulanarak gürültüye karşı gürbüzlük kazanılmasıdır.



Şekil 1.4. VCA işlemi [14]

1.3. Son Elemanların Veride Saf Olarak Bulunduğu Varsayımını Yapmayan Son Eleman Çıkarımı Yöntemleri

Son elemanların veride saf olarak bulunmadığı durumlarda, saf olarak bulunma varsayımını yapan son eleman çıkarımı yöntemlerinin başarımı düşecektir. Bu tür bir veri yapısı basitleştirilmiş olarak Şekil 1.5'te görselleştirilmiştir. Üç adet son elemanın karışımından oluşan bu veride son elemanlar verinin içinde saf olarak bulunmadığından dolayı, N-FINDR veya VCA gibi yöntemler ile doğru son elemanlar elde edilemeyecektir.




Şekil 1.5. Son elemanları içermeyen veride son elemanlar ve VCA çözümü

Bu durumlarda son elemanların veride bulunduğu varsayımını yapmayan yöntemler kullanılmalıdır. Bu yöntemler arasında en küçük hacimli simpleks algoritması (Minimum Volume Simplex Algorithm-MVSA) [16], ayrık genişletilmiş Lagrange ile simpleks tanımlama (Simplex Identification via Split Augmented Lagrangian-SISAL) [17], en küçük hacim kısıtlı negatif olmayan matris faktörizasyonu (Minimum Volume-Constrained Nonnegative Matrix Factorization-MVC-NMF) [18] ve minimum hacim kapsayan simpleks (Minimum Volume Enclosing Simplex-MVES) [19] yöntemleri sayılabilir. Bu bölümde, ilerleyen bölümlerde kullanılmış olan MVSA ve SISAL yöntemleri açıklanacak olup, diğer yöntemler için okuyucu ilgili referanslara yönlendirilmektedir. Veride son elemanların saf olarak bulunduğu varsayımını yapmayan yöntemlerde dikkat edilmesi gereken bir nokta, elde edilen son elemanların her zaman dünyada var olan materyallere denk gelmemesi ve sentetik son elemanlar elde edilebilir olmasıdır.

1.3.1. MVSA

MVSA yöntemi, veri kümesini kapsayan en küçük simpleks yapısını bulmaya amaçlamaktadır. Bu simpleks yapısını oluşturan köşe elemanlarının son elemanlar oldukları kabul edilmektedir. Bu işlem gerçekleştirilirken yerel minimumlara takılmanın azalması için işlem VCA yönteminin çıktısı olarak verdiği noktaların bir nevi şişirilmiş, başka bir deyişle veri kümesinden uzaklaştırılmış hallerinden başlamaktadır. İşlem yinelemeli olarak doğru çözüme yakınsamaktadır. Bu süreç Şekil 1.6'da basitleştirilmiş olarak görselleştirilmiştir.



Şekil 1.6. MVSA süreci

MVSA algoritması, ilerleyen bölümlerde daha detaylı bahsedilecek olan doğrusal karışım modelinden yola çıkmaktadır. Veriye uygulanan boyut indirgeme sonrası, doğrusal karışım modeli,

$$Y = MS \quad , \quad S \geq 0 \quad , \quad \bar{1}_p^T S = \bar{1}_n^T \quad (1.22)$$

şeklinde ifade edilebilir. Bu denklemde Y , sütunları veri vektörleri y_i , $i = 1, 2, \dots, n$, olan veri matrisi, S bolluk oranları matrisi, M ise son eleman matrisidir. $Q \equiv M^{-1}$ kullanılarak, Denklem (1.9)'daki kısıtları sağlayan en küçük hacmi oluşturan Q ,

$$Q^* = \arg \max_Q \log|\det(Q)| \quad , \quad QY \geq 0 \quad , \quad \bar{1}_p^T QY = \bar{1}_n^T \quad (1.23)$$

şeklinde tespit edilir. Bu denklem içbükey olmayan bir yapıda olup, çok sayıda yerel en büyük nokta içermektedir. Sistematik olarak global en iyi çözüm tespit edilememekte, ancak olabilecek en iyi sub-optimal çözümün bulunması amaçlanmaktadır. Bu amaçla ardıl karesel programlama yöntemleri kullanılmakta ve Q , Q' 'ya bağlı olarak da M tespit edilmektedir.

1.3.2. SISAL

SISAL, MVSA gibi minimum hacim tabanlı bir yöntem olup, değişken ayrıştırma sonrası genişletilmiş Lagrange optimizasyonuna dayanmaktadır. Denklem (1.23) elde edildikten sonra,

$$Q^* = \arg \min_Q (-\log|\det(Q)|) + \lambda \|QY\|_h \quad , \quad \bar{1}_p^T QY = \bar{1}_n^T \quad (1.24)$$

şeklinde güncellenmektedir. Bu denklemde $\|X\|_h \equiv \sum_{ij} h([X]_{ij})$ ve $h(x) = \max\{-x, 0\}$ ifade etmektedir. $\|QY\|_h$ terimi ile katı kistas, yumuşak bir düzenleme terimine dönüştürülmektedir. Bu sayede işlem kolaylığı sağlanmakta, gürültü ve aykırı değerlere karşı gürbüzlük kazanılmaktadır. $f(Q) = -\log|\det(Q)|$ alındığında, Denklem (1.11) karesel yakınsama ile aşağıdaki şekilde çözülür:

1. $k = 0, \mu > 0$ ve $Q_0 = VCA(Y)$
2. tekrarla:
3. $l_k = f(Q_k) + \lambda\|Q_k Y\|_h$
4. $g = -vec(Q^{-1})$
5. $Q_{k+1} \in \arg \min_Q g^T Q + \mu\|Q - Q_k\|^2 + \lambda\|Q_k Y\|_h$, $1_p^T Q Y = 1_n^T$
6. Eğer $f(Q_{k+1}) + \lambda\|Q_{k+1} Y\|_h > l_k$:
7. Bul $Q \in \{\alpha Q_{k+1} + (1 - \alpha)Q_k : 0 < \alpha < 1\}$,
8. öyle ki $f(Q) + \lambda\|Q Y\|_h \leq l_k$, $Q_{k+1} = Q$
9. $k \leftarrow k + 1$
10. Durma koşulu sağlanana kadar devam et.

Bu süreçte $\|Q - Q_k\|^2$ terimi $\|Q_{k+1} - Q_k\|^2$ farkının sınırsız büyümemesi için olup, 6 - 8 satırları ise nesnel işlevin artmamasını sağlamak içindir. 5. satırdaki işlemi çözmek için bu yöntemde değişken ayrıştırıcı genişletilmiş Lagrange algoritması kullanılmaktadır. Değişken ayrıştırması aşağıdaki şekilde gerçekleştirilmektedir;

$$\min_{q,z} E(q, z), \quad Bq = a, \quad Aq = z, \quad B = (I \otimes 1_p^T), \quad A = (Y^T \otimes I) \quad (1.25)$$

$$E(q, z) \equiv g^T q + \mu\|q - q_k\|^2 + \lambda\|z\|_h \quad (1.26)$$

Genişletilmiş Lagrange ifadesi ise Denklem (1.27) ve (1.28)'deki şekilde olmaktadır,

$$\mathcal{L}(q, z, d, \tau) \equiv E(q, z) + \alpha^T (Aq - z) + \tau\|Aq - z\|^2 \quad (1.27)$$

$$\mathcal{L}(q, z, d, \tau) \equiv E(q, z) + \tau\|Aq - z - d\|^2 + c \quad (1.28)$$

Bu denklemlerde α Lagrange katsayıları olup, $d = -\alpha/(2\tau)$ eşitliği vardır. Bu denklemin çözümü ayırık genişletilmiş Lagrange ile yinelemeli olarak aşağıdaki eşitliklerle elde edilerek yukarıda verilen algoritmanın 5. adımı için kullanılmaktadır;


$$q_{k+1} = F^{-1}b - F^{-1}B^T(BF^{-1}B^T)^{-1}(BF^{-1}b - a) \quad , \quad (1.29)$$

$$F \equiv (\mu I + \tau A^T A) \quad , \quad b \equiv \mu q_t - g + \tau A^T (z_t + d_t) \quad (1.30)$$

$$z_{t+1} = \text{soft}_-(Aq_{t+1} - d_t, \mu/\tau), \quad \text{soft}_-(x, \beta) = \left(\max \left\{ \left| x + \frac{\beta}{2} \right| - \frac{\beta}{2}, 0 \right\} \right) \left(\frac{x}{|x|} \right) \quad (1.31)$$

1.4. Son Eleman Çıkarımında Uzamsal Bilginin Kullanımı

Literatürde yer alan son eleman çıkarımı yöntemlerinin çoğu sadece spektral bilgi tabanlı olup, uzamsal bilgileri işleme dahil etmemektedir. Bu yaklaşım, doğal olarak elde edilebilecek başarıyı kısıtlamaktadır. Şekil 1.7 (a)'da bir hiperspektral veri ve Şekil 1.7 (b)'de bu verinin piksel vektörlerinin yerleri uzamsal olarak rastgele karıştırılmış halleri verilmiştir.



Şekil 1.7. Spektral tabanlı son eleman çıkarımı yöntemleri için aynı veriler (a) hiperspektral veri (b) piksel vektörleri uzamsal olarak yer değiştirilmiş veri

Sadece spektral bilgiyi kullanan son eleman çıkarımı yöntemleriyle, ki önceki bölümlerde açıklamaları verilen yöntemler de bu gruba dahildir, iki veriden elde edilecek son elemanlar aynıdır. Bu da önemli bir bilgi olan uzamsal bilgiyi işleme dahil etmenin başarıyı arttırabileceği fikrini vermektedir. Bu amaçla literatürde kullanılan iki yaklaşım bulunmaktadır. Bunlar, uzamsal bilgiler ile spektral bilgileri bir arada kullanmayı amaçlayan son eleman çıkarımı yöntemleri ve uzamsal bilgiyi ön-işleme yoluyla işleme dahil eden yöntemlerdir.

1.4.1. Uzamsal ve spektral bilgileri bir arada kullanan yöntemler

Uzamsal ve spektral bilgiyi bir arada kullanan yöntemlerden literatürde en bilinenleri otomatik morfolojik son eleman çıkarımı (Automatic Morphological Endmember Extraction-AMEE) [20], uzamsal-spektral son eleman çıkarımı (Spatial-Spectral Endmember Extraction-SSEE) [21] ve uzamsal saflık tabanlı son eleman çıkarımı (Spatial Purity based Endmember Extraction-SPEE) [22] yöntemleridir.

AMEE yöntemi uzamsal ve spektral bilgileri bütünleştirmek için genişletilmiş morfolojik profilleri kullanmaktadır. Morfolojik işlemleri hiperspektral veriye genişletmek için piksellerin spektral uzaydaki saflığına dayanan bir sıralama ilişkisi kullanılmıştır. Bu tanım ile genişletilmiş morfolojik aşındırma ve yayma dönüşümleri, sırasıyla verideki uzamsal komşuluklardaki spektral açıdan en saf ve en katışıklı piksellerin bulunmasına karşılık gelmektedir. Algoritma ile farklı boyutlarda yapı elemanları kullanılarak uzamsal ve spektral bilgi piramidi oluşturulur. Oluşan aşındırma ve yayma sonuç imgeleri piksellerinin iki piramitteki değerlerinin farklarına dayanarak morfolojik dışmerkezlik endeksi (Morphological Eccentricity Index-MEI) elde edilir. Daha sonra MEI imgesinde alan büyütme uygulanarak, oluşan alanların ortalama spektrumları son elemanlar olarak alınır. Önemsiz son elemanların elenmesi işlemleriyle nihai son eleman kümesi elde edilir.

SSEE ise uzamsal düzlemde yerel arama pencereleri kullanarak bu penceredeki verilere SVD uygulamakta ve verinin özvektörlerini elde etmektedir. Elde edilen özvektörlerin üzerine verinin izdüşümü alınarak, izdüşümde uçlarda kalan noktalar son eleman adayları olarak belirlenmektedir. Daha sonra aday son elemanların arama penceresi içinde spektral açıdan benzerleri de tespit edilip, adayın kendisi ile benzerlerinin ortalaması olarak güncellenmektedir. Bu işlem son eleman sayısı kadar aday nokta kalana kadar yinelemeli olarak devam etmekte, kalan aday noktalar son elemanlar olarak kabul edilmektedir.

SPEE yaklaşımında ilk olarak hiperspektral veri basit bir çekirdek yapısı ile taranarak SVD işlemine sokulmaktadır. SVD sonucunda tek bir özvektör elde edilen veya ilk özvektörünün genliği diğer özvektörlerinkinden bir eşik değeri kadar büyük olan bölgelerin homojen olduğu varsayılmaktadır. Daha sonra her homojen bölgedeki piksel vektörlerinin ortalama spektrumu hesaplanmakta ve o bölgeye

temsilci olarak atanmaktadır. Temsilci spektrumların aralarındaki uzamsal ve spektral açısal uzaklık az olanlar, ait oldukları bölgelerin büyüklüğüne göre ağırlıklı ortalama kullanılarak birleştirilmektedir. İstenen son eleman sayısına ulaşınca kadar bu birleştirme işlemi devam etmekte, çıktı olarak elde edilen imzalar son elemanlar olarak kabul edilmektedir.


1.4.2. Uzamsal bilgilerin ön-işleme yoluyla kullanılması

Uzamsal bilgileri son eleman çıkarımı işlemine dahil etmek amacıyla son yıllarda yaygın kullanım bulmuş başka bir yaklaşım ise bu bilgilerin ön-işleme yoluyla dahil edilmesidir. Bu yaklaşımda genel olarak kabul edilen varsayım saf spektral imzaların uzamsal olarak homojen bölgelerde olmalarının geçiş (karışıklı) bölgelerde olmalarından daha yüksek olasılıklı olduğudur. Bu varsayım altında geliştirilen uzamsal ön-işleme (Spatial Preprocessing-SPP) [23], bölge-tabanlı uzamsal ön-işleme (Region Based Spatial Preprocessing-RBSPP) [24] ve uzamsal-spektral ön-işleme (Spatial Spectral Preprocessing-SSPP) [25] yöntemleri bu tez kapsamında kullanılmış olup, açıklamaları bu bölümde paylaşılacaktır.

1.4.2.1. SPP

SPP yöntemi ile son eleman çıkarımı öncesinde, simpleks yapısındaki veri noktaları, veri kümesi içinde bulundukları konumun uzamsal homojenlik oranına göre hareket ettirilmektedir. SPP işlemi sadeleştirilerek Şekil 1.8’de görselleştirilmiştir.


Şekil 1.8’de farklı spektral içeriğe sahip pikseller farklı renkler ile gösterilmiştir. Her piksel vektörü, etrafında alınan bir pencere içinde kalan komşu piksel vektörleriyle homojenliği ile ters orantılı olarak dışbükey simpleks yapısında merkeze doğru hareket ettirilmektedir. Homojenlik ölçütü olarak pikseli çevreleyen bir pencere içindeki değişinti değeri kullanılmaktadır. Homojen olmayan bölgelerde yer alan veri noktaları simpleks merkezine doğru daha çok hareket ettirilmekte, homojen bölgelerde yer alan veri noktaları ise daha az hareket ettirilmektedir. Böylece, ön-işlem sonrası, uzamsal olarak homojen bölgelerde yer alan veri noktalarının simpleks köşelerinde kalarak son eleman olarak alınma ihtimalleri artmaktadır.



Şekil 1.8. SPP yönteminin çalışması [23]

1.4.2.2. RBSPP

RBSPP işlemi Şekil 1.9’da özetlenmiştir.



Şekil 1.9. RBSPP yöntemi

İşlem, eğitimsiz bir kümeleme adımı ile başlamaktadır. Bu kümeleme işlemi ile hiperspektral veri, her biri kendi içinde spektral açıdan benzer olan uzamsal kümelerle ayrılmaktadır. [23]’de bu amaçla ISODATA [26], k-ortalamlar [27] ve hiyerarşik kümeleme [28] yöntemleri kullanılmış olup, bu tez kapsamında RBSPP yöntemi ISODATA kümeleme yöntemi ile ele alınacaktır. Kümeleme adımı ile en az son eleman sayısı kadar, en çok ise bu sayının iki katı kadar küme elde edilmektedir.

Daha sonra, elde edilen her kümenin ortalama spektrumuna OSP uygulanmakta, bu sayede dikgen ve spektral olarak birbirinden farklı belirli sayıda küme elde edinmek amaçlanmaktadır. OSP işlemi ilk olarak en yüksek parlaklık değerine sahip ortalama spektrumu olan kümeden başlar;

$$R_1 = \arg \left\{ \max_l \sum_{l=1}^r M_l M_l^T \right\} \quad (1.32)$$

Bu denklemde M_l l kümesinin, $l = 1, 2, \dots, r$, ortalama spektrumunu, r ise önceki adımda elde edilen toplam küme sayısını göstermektedir. R_1 elde edildikten sonra izdüşümü $U_1 = [M_1]$ alınarak ilk çıktı kümesi olarak atanır.

Sonra, ikinci küme, ilk çıktı kümesinin ortalama spektrumuna en büyük izdüşümü veren ortalama spektrumuna sahip küme olarak belirlenir;

$$R_2 = \arg \left\{ \max_l \left[(P_{U_1}^\perp M_l)^T (P_{U_1}^\perp M_l) \right] \right\} \quad , \quad P_{U_1}^\perp = I - U_1 (U_1^T U_1)^{-1} U_1^T \quad (1.33)$$

$U_2 = [M_1 M_2]$ alınarak devam edilir.

Algoritma, son eleman sayısında küme elde edilene kadar, yinelemeli olarak bu işlemi aşağıdaki denkleme göre tekrarlar;

$$R_j = \arg \left\{ \max_l \left[(P_{U_{j-1}}^\perp M_l)^T (P_{U_{j-1}}^\perp M_l) \right] \right\} \quad (1.34)$$

Bu denklemde, $P_{U_{j-1}}^\perp$,


$$P_{U_{j-1}}^\perp = I - U_{j-1} (U_{j-1}^T U_{j-1})^{-1} U_{j-1}^T \quad (1.35)$$

şeklinde ifade edilmektedir.

RBSPP işlemi tamamlandıktan sonra, spektral-tabanlı son eleman çıkarımı yöntemine girdi olarak tüm veri yerine, sadece RBSPP sonucunda elde edilen kümelerdeki piksel vektörleri verilmektedir.

1.4.2.3. SSPP

SSPP yöntemi RBSPP yöntemi ile benzerlik göstermekte olup, RBSPP aksine, ön-ışılme sürecine spektral işlemei de dahil etmektedir. SSSP süreci Şekil 1.10'da paylaşılmıştır.



Şekil 1.10. SSPP yöntemi [25]

SSPP işlemei aşağıdaki adımlarla özetlenebilir:

1. Gauss süzgeçleme adımı: Bu adımda hiperspektral verinin her spektral bandı bir Gauss süzgeci ile süzgeçlenmektedir. Yumuşatma oranı σ değışkeni ile kontrol edilmekte ve bu aynı zamanda uzamsal bilgiye verilen önemi belirlemektedir. k spektral bandı için piksel tabanlı Gauss süzgeçleme işlemei,

$$F_k[x(i,j)] = \sum_{i'=1}^r \sum_{j'=1}^c G(i-i', j-j') \cdot x_k(i', j') \quad , \quad G(i', j') = \frac{1}{2\pi\sigma^2} e^{-\frac{i'^2+j'^2}{2\sigma^2}} \quad (1.36)$$

şeklinde yapılmaktadır. r verinin satır sayısını, c sütun sayısını göstermektedir.

2. Uzamsal homojenlik indeksi: Bir önceki adımda elde edilen uzamsal olarak süzgeçlenmiş spektral bantlar ile orijinal spektral bantların karekök ortalama karesel hata (Root Mean Square Error-RMSE) farkı kullanılarak uzamsal homojenlik indeksi hesaplanmaktadır. RMSE değeri ne kadar büyükse piksel vektörü ile komşuluğundaki piksel vektörleri o kadar farklı olup, homojenlik indeksi değeri de o kadar küçüktür.

3. Eğitimsiz kümeleme adımı: İlk iki adıma paralel olarak, RBSPP yönteminde olduğu gibi, veriye eğitimsiz kümeleme uygulanmaktadır. [25]'te bu amaçla temel bileşenler analizi sonrası ISODATA yöntemi kullanılmıştır.
4. Kaynaştırma adımı: 2. adımda elde edilen homojenlik indisi değerleri ve 3. adımda elde edilen kümeler kullanılarak veriden bir alt-küme seçmek amaçlanmaktadır. $\rho \in [0, 100]$ değişkeni her kümeden seçilecek piksel vektörü oranını belirlemektedir. Bu piksel vektörleri seçilirken en yüksek homojenlik indisi değerine sahip olandan en düşük değere sahip olana doğru seçilir. Tercihe bağlı olarak ayrıca spektral saflık tabanlı bir seçme işlemi de gerçekleştirilebilir. Bu amaçla temel bileşen analizi sonucunda elde edilen bileşenlerin izdüşümleri alınarak, uçlarda kalan piksellere 1, ortalarında kalan piksellere 0 olacak şekilde ağırlık ataması yapılabilir. Bir eşik değeri ile bu eşik değerinin altında kalan ağırlığa sahip pikseller atılabilir ve kümelerden bu ağırlıklara göre $\beta \in [0, 100]$ değişkeni oranında piksel vektörü seçilebilir.
5. Spektral tabanlı son eleman çıkarımı yöntemine tüm veri yerine seçilen piksel vektörleri verilmekte, böylece son elemanlar homojen bölgelerden seçilerek başarımın arttırılması amaçlanmaktadır.

1.5. Özgün Çalışma: Son Eleman Çıkarımı için Anomali Gözetin Ön-işleme Yaklaşımı

Tez kapsamında gerçekleştirilen özgün çalışmalardan biri bu bölümde paylaşılabacaktır. Bu özgün çalışmada, literatürde yer alan uzamsal ön-işleme yaklaşımları ile anomali tespiti yaklaşımları birleştirilmekte ve iki yönlü bir ön-işleme yaklaşımı kullanılmaktadır. Bu yaklaşımın amacı, bir yandan son elemanların karışıklı bölgeler yerine homojen bölgelerden seçilmesini sağlarken, bir yandan da olası anomali son elemanlarını kaybetmemektedir. Başka bir deyişle, geliştirilen yöntem son eleman çıkarımı işlemini karışıklı bölgeler yerine homojen bölgelere ve anomali noktalara yönlendirmektedir. Geliştirilen özgün yöntem spektral tabanlı tüm son eleman çıkarımı yöntemleriyle kullanıma uygun olup son eleman çıkarımı yönteminin kendisini değiştirmemekte, bir ön-işlem niteliği taşımaktadır. Yaklaşımının geliştirilmesinin altında yatan motivasyon ve problem tanımı bir sonraki bölümde paylaşılacak olup, daha sonra sırasıyla anomali tespiti yöntemleri, geliştirilen yöntemin açıklaması ve deneysel sonuçlar paylaşılacak ve vargılar ile bölüm tamamlanacaktır.

1.5.1. Motivasyon

Önceki bölümlerde bahsedildiği üzere, literatürdeki çoğu son eleman çıkarımı yaklaşımı hiperspektral verideki uzamsal bilgiyi ihmal etmektedir. Bu amaçla geliştirilen ön-işleme yaklaşımları son eleman çıkarımı işlemini homojen bölgelere yönlendirerek uzamsal bilgiyi işleme dahil etmiş olmaktadır. Bu sayede son eleman çıkarımının başarımı arttırılabilmektedir. Ancak RBSPP ve SSPP gibi ön-işleme yöntemleri verideki geçiş bölgelerini atıp homojen bölgeleri son eleman çıkarımına girdi olarak verirken aynı zamanda anomali noktalarını da elemektedir [23].

Anomali, tanım olarak, verinin geri kalanından, ya da veride bulundukları konumun komşuluğundaki diğer noktalardan önemli oranda farklılık gösteren bir noktadır. Anomali tespiti, verideki bu olağandışı ve önemli olabilecek noktaları tespit etmeyi amaçlayan eğitimsiz bir hedef tespiti yaklaşımıdır. Anomali tespitinde hedef olan anomaliler ile ilgili ön bilgi gerekmemekte ve belirli hedef imzaları ile eşleştirme yaklaşımı kullanılmadığından, hiperspektral veriye atmosferik düzeltme uygulanması ihtiyacı da oluşmamaktadır. Anomali tespiti hiperspektral verilerde birçok çalışmada kullanılmış olup, tespit edilen anomaliler arasında ekinlerde stres konumları, petrol kirliliği, nadir mineraller, gömülü mayınlar ve insan yapımı malzemeler gibi birçokları sayılabilir [29].

Son eleman çıkarımında başarımın arttırılması için işlemi homojen bölgelere yönlendirirken anomali noktalarının kaybedilmesi, mayın tespiti gibi askeri uygulamalar başta olmak üzere, birçok uygulama için istenmeyen durumlar yaratabilecektir. Anomali tespiti yöntemi son eleman çıkarımından ayrı olarak kullanılarak bu istenmeyen durumların giderilebileceği düşünülebilir. Ancak özellikle veri boyutunun çok yüksek olduğu hiperspektral verilerde son eleman çıkarımı ve bir sonraki bölümde bahsedilecek olan spektral karışım analizi ile verinin bir özeti çıkarılması, gerek veri tarama uygulamaları açısından gerekse sıkıştırma açısından önem taşımaktadır. Verinin özeti sağlayan son eleman imzaları içerisinde anomali son elemanlarının da bulunması, bu imzaların incelenmesi ile, ilgili anomalinin öneminin belirlenmesini sağlayacak ve önemsiz anomaliler kolaylıkla elenirken önemli anomali noktaları kaybedilmemiş olacaktır.

Bu özgün çalışma kapsamında, bu amaçla, son eleman çıkarımı öncesi literatürdeki uzamsal ön-işleme yöntemleri ve anomali tespiti yöntemleri bir arada kullanılmaktadır.

1.5.2. Anomali tespiti yöntemleri

1.5.2.1. Reed-Xiaoli yöntemi

Reed-Xiaoli (RX) algoritması [30] çoklu-spektral görüntüler için geliştirilmiş olan, genelleştirilmiş benzerlik oranı testine dayalı sabit yanlış-alarm oranı uyarlanır bir yöntemdir. RX hiperspektral verilerde de anomali tespiti için başarıyla kullanılmıştır [31, 32]. RX’de verinin arka planı sıfır ortalamaya ve bilinmeyen bir ortak değişinti matrisine sahip bir Gauss dağılımı ile modellenmektedir. Anomali imzası, gürültü olarak kabul edilebilecek bu Gauss dağılımı ile hedef imzasının toplamı olarak modellenmektedir. Kullanılan iki hipotez şu şekilde gösterilebilir:

$$H_0: x = n \quad \text{Anomali yok} \quad (1.37a)$$


$$H_1: x = as + n \quad \text{Anomali var} \quad (1.37b)$$

H_1 hipotezinde $a > 0$ olmaktadır. n arka plan gürültüsü, s bilinmeyen anomali imzasıdır. Bu hipotezler kapsamında arka plan $N(0, C_b)$, anomali ise $N(s, C_b)$ olarak modellenmektedir.

Bu iki hipoteze dayanarak, anomali tespiti, piksel vektörlerinin arka plan modeli ile Mahalanobis uzaklığı hesaplanarak gerçekleştirilmektedir. Test edilen piksel vektörü etrafında alınan pencere aracılığıyla yerel ortalama giderimi ve ortak değişinti kestirimi yapılmakta, böylece yerel Gauss dağılımı koşulu zorlanmaktadır.

$$RX(r) = (r - \hat{\mu}_b)^T \hat{\Sigma}_b^{-1} (r - \hat{\mu}_b) \quad (1.38)$$

Bu denklemde r test edilen piksel vektörünü, $\hat{\mu}_b$ ve $\hat{\Sigma}_b$ ise sırasıyla pencere içinde kestirilen arka plan ortalama vektörü ve ortak değişinti matrisini betimlemektedir. RX değeri 0 - 1 aralığında değer almakta olup bir eşik değeri ile karşılaştırılarak test edilen piksel vektörünün anomali olup olmadığına karar verilir. Bir piksel vektörü için etrafında alınan penceredeki Gauss dağılımı ve piksel anomali ise bu dağılıma göre konumu Şekil 1.11’de sadeleştirilerek sunulmuştur.



Şekil 1.11. RX çevrit yüzeyleri [29]

Pratikte, RX'in başarımını iyileştirmek için kullanılabilen çeşitli uygulama notları şunlardır [4]:

Koruma penceresi: Test edilecek piksel vektörü etrafında bir koruma penceresi yaklaşımı kullanılarak test edilecek piksel vektörünün ve pencere boyutuna bağlı olarak yakın komşuluğunda piksel vektörlerinin, arka plan ortalama ve ortak değişinti kestirimine dahil edilmemesi sağlanılabilir.

İki-pencere yaklaşımı: Arka plan ortalama kestirimi için kullanılan pencerenin boyutu, ortak değişinti kestirimi için kullanılan pencerenin boyutundan daha küçük alınabilir. Bunun nedeni ortalama vektörünün genel olarak ortak değişinti matrisinden daha hızlı değişmesidir.

Dış pencere boyutu: Ortak değişinti kestirimi için kullanılan dış pencerenin boyutunun tekil matris oluşumundan kaçınacak kadar büyük ve işlem yükünün çok yüksek olmayacağı kadar küçük olması gerekmektedir.

1.5.2.2. Çekirdek RX yöntemi

RX farklı spektral bantlar arasındaki yüksek seviye ilişkileri dikkate almamaktadır. Çekirdek RX (Kernel RX-KRX) , spektral bantlar arasındaki doğrusal olmayan ilişkiyi dikkate alabilmek için doğrusal olmayan eşleme kullanmaktadır ve RX'e göre daha az yanlış alarm vermektedir. Ayrıca, Gauss dağılımı varsayımının daha üst boyutlu uzayda daha geçerli olduğu belirtilmektedir [33].

Doğrusal olmayan eşleme, literatürde çekirdek numarası (kernel trick) [34] olarak bilinen yaklaşım sayesinde, var olan doğrusal eşleme fonksiyonu hakkında detaylı bilgi olmadan, gerçekleştirilebilmektedir. RX çekirdek öznitelik uzayında,

$$RX(\Phi(r)) = (\Phi(r) - \hat{\mu}_{b\Phi})^T \hat{C}_{b\Phi}^{-1} (\Phi(r) - \hat{\mu}_{b\Phi}) \quad (1.39)$$

şeklinde ifade edilmektedir. Bu denklemde $C_{b\phi}$ ve $\mu_{b\phi}$, sırasıyla, öznitelik uzayında kestirilen arka plan ortak değişinti matrisini ve ortalama vektörünü betimlemektedir. Çekirdek numarası kullanılarak $C_{b\phi}$,

$$\hat{C}_{b\phi} = V_\phi \Lambda_b V_\phi^T \quad (1.40)$$

şeklinde ifade edilebilmektedir. Bu denklemde Λ_b özdeğerlerin köşegen matrisi, V_ϕ ise sütunları $C_{b\phi}$ matrisinin öznitelik uzayındaki özvektörleri olan matristir. V_ϕ matrisini $X_{b\phi} B$ olarak ifade ettiğimizde B merkeze çekilmiş ve özdeğerlerin karekökleri ile normalize edilmiş çekirdek matrisinin özvektör matrisi olmaktadır. Denklem (1.40)'taki ifade Denklem (1.39)'da kullanılıncı,

$$RX(\Phi(r)) = (\Phi(r) - \hat{\mu}_{b\Phi})^T X_{b\Phi} B \Lambda_b^{-1} B^T X_{b\Phi}^T (\Phi(r) - \hat{\mu}_{b\Phi}) \quad (1.41)$$

elde edilmektedir. Bu denklem çekirdek haritaları cinsinden,

$$\Phi(r)^T X_{b\Phi} = k(X_b, r)^T - \frac{1}{N} \sum_{i=1}^N k(x(i), r) \equiv K_r^T \quad (1.42)$$

$$\hat{\mu}_{b\Phi}^T X_{b\Phi} = \frac{1}{N} \sum_{i=1}^N K(x(i), X_b) - \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N k(x(i), x(j)) \equiv K_{\hat{\mu}_b}^T \quad (1.43)$$

$$\hat{K}_b^{-1} = \frac{1}{N} B \Lambda_b^{-1} B^T \quad (1.44)$$

şeklinde ifade edilmektedir. Çekirdek haritaları kullanılarak KRX denklemi,

$$KRX(r) = (K_r^T - K_{\hat{\mu}_b}^T)^T \hat{K}_b^{-1} (K_r^T - K_{\hat{\mu}_b}^T) \quad (1.45)$$

şeklinde elde edilmekte olup, bu denklem, eşleme fonksiyonu olan ϕ 'dan bağımsızdır ve çekirdek fonksiyonu k 'yi kullanmaktadır. RX bölümünde bahsedilen uygulama

notları KRX için de kullanılabilir. KRX genel olarak RX'den daha az yanlış alarm vermektedir, ancak işlem yükü büyük Gram matrislerinin hesaplanması ve terslenmesi gerektiğinden dolayı RX'e göre daha yüksektir.

1.5.3. Yöntemin açıklaması

Geliştirilen özgün yaklaşım şu şekilde özetlenebilir:

- 1) Verideki son eleman sayısı tespit edilir. Bu çalışmada bu amaç için HFC yöntemi kullanılmıştır.
- 2) Verideki geçiş bölgelerini son eleman çıkarımından elemek için veriye RBSP veya SSPP uygulanır. Eğitimsiz kümeleme için ISODATA yöntemi kullanılmıştır. ISODATA için küme sayısı son eleman sayısı ile bu sayının iki katı arasında değişecek şekilde ayarlanmıştır. ISODATA'nın diğer iki parametresi olan kümeleri birleştirmek için kullanılan uzaklık eşiği ve küme bölmek için kullanılan farklılık eşiği veriye göre seçilmektedir. RBSP yönteminin geri kalanında parametre gerekmekte olup, SSPP yöntemi iki temel, iki de tercihi parametre gerektirmektedir. Temel parametreler Gauss süzgeci için σ_{sspp} parametresi ve homojenlik indisine göre kümelerden seçilecek piksel vektörü oranını belirleyen ρ_{sspp} parametresidir. Tercihi parametreler ise spektral saflık eşiği ve spektral saflığa göre seçilecek piksel vektörü oranını belirleyen β_{sspp} parametreleridir. Bu parametrelerin belirlenmesi [25]'te olduğu gibi tarama ile tespit edilmiştir.
- 3) RBSP / SSPP adımına paralel olarak veriye KRX uygulanır. Çekirdek yapısı için radyal taban fonksiyonu (Radial Basis Function-RBF) kullanılmıştır. Başarım artırılması için tek piksel vektörlük koruma penceresi yaklaşımı kullanılmıştır. Koruma penceresinin bu boyutta seçilmesi kullanılan anomalilerin tek piksel boyutunda olmasından dolayıdır. Daha büyük boyutlu anomalilerde bu koruma penceresi boyutunun artırılması başarımı arttıracaktır. Ortalama kestirimi ve ortak değişinti matrisi kestirimi için aynı pencere boyutu kullanılmış olup, bu pencere boyutu 21×21 olarak belirlenmiştir. Pencere boyutunun seçiminde işlem yükü ve başarı arasında ödünleşme yapılmıştır. Standardizasyon için KRX çekirdeği için σ parametresi 40, KRX sonrası uygulanacak eşik değeri ise 0,7 olarak belirlenmiş olup, farklı veriler için farklı değerler daha yüksek başarımlar sağlayabilmektedir.

4) RBSP / SSPP sonucu seçilen piksel vektörleri ve KRX sonrası eşik değerinden geçen anomali noktaları spektral tabanlı son eleman çıkarımına girdi olarak verilmektedir.

1.5.4. Deneysel sonuçlar

Geliştirilen özgün yaklaşımının başarımının değerlendirilmesi amacıyla sentetik ve gerçek veriler üzerinde deneyler gerçekleştirilmiştir. Son eleman çıkarımı için N-FINDR, VCA ve MVSA yöntemleri kullanılmış olup, sentetik veriler için başarımlar gerçek son elemanlar ile veriden çıkarılan son elemanlar arasında spektral açısal uzaklık (Spectral Angular Distance-SAD) [35] cinsinden ölçülmüştür. SAD iki spektral imza arasındaki spektral açığı,

$$SAD = \cos^{-1} \left(\frac{\sum_{i=1}^n (t_i \times r_i)}{\sqrt{\sum_{i=1}^n t_i^2 \sum_{i=1}^n r_i^2}} \right) \quad (1.46)$$


ile tespit eder. Bu denklemde n verideki spektral bant sayısı, t tespit edilen spektrum ve r referans spektrumudur. Çıkarılan son elemanlar ile gerçek son elemanlar arasındaki SAD değeri ne kadar küçük olursa çıkarılan son elemanlar gerçek son elemanlara o kadar yakın olmaktadır. Geliştirilen yaklaşımın başarımı standart son eleman çıkarımı ve RBSP / SSPP yaklaşımlarıyla karşılaştırılmıştır.

1.5.4.1. Sentetik veride deneysel sonuçlar

Bu deneysel çalışmada 100 x 100 piksel boyutuna ve 221 spektral banda sahip olan “Fractal_1” verisi kullanılmıştır. Bu veri, doğada gözlemlenebilen bir uzamsal örüntüye sahiptir [23]. Sentetik veri 9 adet mineral son eleman imzası içermekte olup, bu son eleman imzaları U.S. Geological Survey (USGS) spektral kütüphanesinden elde edilmiştir. Bu imzalar *Kaolinite KGa1*, *Dumortierite*, *Nontronite*, *Alunite*, *Sphene*, *Pyrophyllite*, *Halloysite*, *Muscovite* ve *Kaolinite CM9* minerallerine aittir. Şekil 1.12’de Fractal_1 verisi üç renkli görüntüsü görülmekte olup, Şekil 1.13’de verinin içerdiği son eleman imzaları sunulmuştur.



Şekil 1.12. Fractal_1 verisi



Şekil 1.13. Fractal_1 verisi son eleman imzaları

Yöntemin başarımı verinin anomali içerdiği ve içermediği durumlar için hesaplanmıştır. Yöntemin gürültüye karşı gürbüzlüğünü denetlemek amacıyla veriye farklı işaret-gürültü oranlarında (Signal-to-Noise–SNR) sıfır ortalamalı toplamsal Gauss gürültüsü eklenmiştir. SSPP parametreleri için orijinal SSPP çalışmasında bu veri seti için bildirilmiş olan parametre değerleri kullanılmış olup, bu değerler $\sigma_{sspp} = 1,4$, $\beta_{sspp} = 30$ ve $\rho_{sspp} = 70$ 'dir.

Anomali içermeyen veri için, N-FINDR, VCA ve MVSA son eleman çıkarma yöntemleri ile birlikte elde edilen sonuçlar Tablo 1.1, Tablo 1.2 ve Tablo 1.3'de sunulmuştur. Tablo 1.1, Tablo 1.2 ve Tablo 1.3'den, RBSPP ve SSPP yöntemlerinin, ön-işleme kullanılmayan son eleman çıkarımına göre başarımı arttırabildiği gözlemlenmektedir. Bununla birlikte, orijinal RBSPP ve SSPP makalelerinde de karşımıza çıktığı gibi [24, 25], RBSPP ve SSPP ön-işleme yöntemlerinin SAD değerlerini arttırdığı durumlar da görülmektedir. Bu daha düşük başarı durumu,

verideki son elemanların hepsinin homojen bölgelerde yer almaması veya eleme sonucunda son eleman çıkarımı için kullanılacak piksellerin oluşturduğu veri simpleks yapısının önceki veri simpleks yapısından farklı olması sebebiyle, simplekstekki uç noktaların son elemanlara tam olarak denk gelmemesi kaynaklı olabilir.

Tablo 1.1. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, N-FINDR ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,0529	0,0570	0,0577	0,0575
RBSP	0,0578	0,0727	0,0733	0,0732
SSP	0,0529	0,0572	0,0578	0,0577
RBSP + KRX	0,0580	0,0726	0,0733	0,0732
SSP + KRX	0,0529	0,0571	0,0578	0,0577

Tablo 1.2. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, VCA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,0632	0,0566	0,0575	0,0574
RBSP	0,0807	0,0752	0,0732	0,0731
SSP	0,0641	0,0562	0,0572	0,0574
RBSP + KRX	0,0805	0,0777	0,0732	0,0749
SSP + KRX	0,0659	0,0562	0,0577	0,0574


Tablo 1.3. Anomali içermeyen Fractal_1 verisinde SAD sonuçları, MVSA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,3845	0,0895	0,0618	0,0749
RBSP	0,3565	0,1017	0,0733	0,1862
SSP	0,3233	0,0841	0,0615	0,1095
RBSP + KRX	0,3669	0,1107	0,0915	0,1022
SSP + KRX	0,3386	0,0852	0,0615	0,0611

Tablo 1.1, Tablo 1.2 ve Tablo 1.3'den görülebileceği üzere, anomali içermeyen verilerde, anomali içeren veriler için geliştirilmiş olan özgün yöntem, neredeyse her son eleman çıkarımı yöntemi ve gürültü oranı için, RBSP veya SSP kullanan

yaklaşım ile çok yakın SAD değerleri vermektedir. Bu durum, geliştirilen yöntemin anomali içermeyen verilerde başarımı önemli ölçüde kötüleştirmediğini göstermektedir. Bunun nedeni anomali olarak tespit edilen piksel sayısının küçük olması ve homojen bölgelere yönlendirme sürecini önemli şekilde etkilememesidir. Ayrıca, homojen olmayan, anomali olarak tespit edilen pikseller işleme dahil ediliyor olmasına rağmen, bazı durumlarda başarımın RBSPP veya SSPP'ye göre arttığı da gözlemlenmiştir (örneğin gürültüsüz veride SSPP ve MVSA ile). Bu durumun nedeni net bir şekilde belirgin olmamakla birlikte, yöntem sonucunda oluşan veri simpleks yapısı son elemanları ve gerçek simpleks yapısını daha iyi temsil eder durumda olabilir.

Anomali içeren sentetik veride deneysel sonuçları elde etmek için, bir önceki deneyde kullanılan veriye, USGS spektral kütüphanesinden “metal levha” ve “koyu kırmızı tuğla” spektral imzaları anomali olarak eklenmiştir. Bu spektral imzaların tercih edilmesinin nedeni, birçok uygulamada önem taşıyabilecek ve uydudan elde edilen hiperspektral verilerde küçük alan kapsayacak (az sayıda pikselle veya piksel-altında ifade edilecek) bina yapıları için uygun spektral imzalar olmalarıdır. Kullanılan anomali spektral imzaları Şekil 1.14’de sunulmuştur.



Şekil 1.14. Fractal_1 verisine eklenen anomali imzaları

Elde edilen SAD sonuçları Tablo 1.4, Tablo 1.5 ve Tablo 1.6’da sunulmuştur. Anomali içeren veriler için elde edilen sonuçlarda, önerilen SSPP + KRX yaklaşımının SSPP yaklaşımından her durumda, RBSPP + KRX yaklaşımının ise

RBSPSP'den MVSA ile 30dB SNR dışında her durumda daha düşük hata verdiği görülmektedir. Ayrıca, önerilen yaklaşım neredeyse her durum için standart son eleman çıkarımı yaklaşımından daha düşük hata vermekte olup, bu duruma istisna olan N-FINDR sonuçlarında, düşük başarımlı nedeninin önerilen yaklaşımın içerdiği RBSPSP ve SSPP'nin kötüleştirici etkisi olduğu anlaşılmaktadır. VCA ve MVSA son eleman çıkarımı yöntemlerinde ise önerilen yaklaşımın başarımlı ortaya çıkmaktadır.

Tablo 1.4. İki anomali içeren Fractal_1 verisinde SAD sonuçları, N-FINDR ile


Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,0519	0,0480	0,0498	0,0498
RBSPSP	0,1234	0,1345	0,1346	0,1344
SSPP	0,0764	0,1131	0,1151	0,0893
RBSPSP + KRX	0,0944	0,0955	0,0648	0,0647
SSPP + KRX	0,0697	0,0856	0,0499	0,0497

Tablo 1.5. İki anomali içeren Fractal_1 verisinde SAD sonuçları, VCA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,1256	0,1173	0,1456	0,0570
RBSPSP	0,1214	0,1001	0,0956	0,0945
SSPP	0,1084	0,1183	0,1208	0,1193
RBSPSP + KRX	0,1208	0,0715	0,0783	0,0635
SSPP + KRX	0,1028	0,1101	0,0870	0,0498


Tablo 1.6. İki anomali içeren Fractal_1 verisinde SAD sonuçları, MVSA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,4999	0,2149	0,0762	0,0538
RBSPSP	0,4542	0,2366	0,2378	0,9640
SSPP	0,4454	0,1951	0,1590	0,1603
RBSPSP + KRX	0,5196	0,1655	0,0938	0,0710
SSPP + KRX	0,5245	0,1796	0,0668	0,0517




Şekil 1.15. 30dB SNR Fractal verisi için görsel sonuçlar (a) VCA ile bulunan son eleman konumları (b) ISODATA ile elde edilen bölgeler (c) RBSPP+VCA ile bulunan son eleman konumları (d) SSPP+VCA ile bulunan son eleman konumları (e) Veriye eklenen anomali noktaları (f) KRX ile tespit edilen anomali noktaları (g) RBSPP+KRX+VCA ile bulunan son eleman konumları (h) SSPP+KRX+VCA ile bulunan son eleman konumları

Görsel sonuçlar Şekil 1.15'te verilmiştir. Şekil 1.15 (f)'de, anomali tespitinde yanlış alarmların sayısının az olmadığı görülmektedir. Bu durum, çalışmada kullanılmış olan genel KRX eşik değeri 0,7'nin sonucu olup, daha uygun bir eşik değeri seçilerek yanlış alarmların sayısı azaltılabilmektedir. Örneğin KRX eşik değeri olarak 0,84 kullanıldığında tespit edilen anomali konumları Şekil 1.16'da görülmektedir. Daha yüksek SNR değerlerinde ise hatalı tespitler sıfırlanabilmektedir.



Şekil 1.16. Şekil 1.15'te görselleri verilen veri için KRX eşik değeri = 0,84 sonucu

Fractal_1 verisine iki yerine dört adet anomali eklendiğinde elde edilen sonuçlar Tablo 1.7, Tablo 1.8 ve Tablo 1.9’da verilmiştir. Eklenen anomali imzaları, “metal levha”, “koyu kırmızı tuğla”, “çatı keçesi” ve “şeffaf fiberglas çatı”, Şekil 1.17’de görülmektedir.



Şekil 1.17. Fractal_1 verisine eklenen dört anomali imzası

Tablo 1.7. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, N-FINDR ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,0949	0,0301	0,0299	0,0297
RBSP	0,1079	0,1300	0,0975	0,0991
SSP	0,1185	0,1337	0,1144	0,1143
RBSP + KRX	0,0654	0,0339	0,0397	0,0397
SSP + KRX	0,1037	0,0301	0,0299	0,0297

Tablo 1.8. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, VCA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,1520	0,1285	0,1241	0,1316
RBSP	0,1571	0,1499	0,1593	0,1477
SSP	0,1632	0,1475	0,1444	0,1472
RBSP + KRX	0,1415	0,1354	0,2184	0,1195
SSP + KRX	0,1618	0,1270	0,1219	0,0750

Tablo 1.9. Dört anomali içeren Fractal_1 verisinde SAD sonuçları, MVSA ile

Ön-işleme	30dB SNR	50dB SNR	70dB SNR	Gürültüsüz
-	0,6411	0,3574	0,1810	0,0666
RBSP	0,5325	0,3143	0,3669	0,3315
SSPP	0,5200	0,2558	0,2202	0,2044
RBSP + KRX	0,6221	0,1317	0,0464	0,0419
SSPP + KRX	0,6263	0,3504	0,0786	0,0446


Dört anomali içeren veride de 30dB SNR MVSA dışında tüm durumlar için önerilen yöntem en iyi başarıyı vermekte ve sadece RBSP veya sadece SSPP ön-işleme yaklaşımlarına göre, son eleman çıkarımı başarımını kayda değer oranda arttırmaktadır.

1.5.4.2. AVIRIS Cuprite verisinde deneysel sonuçlar

Geliştirilen yöntemin gerçek hiperspektral veri üzerinde başarımını test etmek amacıyla AVIRIS Cuprite verisinin bir parçası, “f970619t01p02_r02_sc03.a.rfl”, kullanılmıştır. Veri 0,4 μm ile 2,5 μm dalga boyları arasında 224 spektral banda sahip olup, atmosferik gürültü içeren 32 bant elenerek 192 spektral bant kullanılmıştır. Verinin bir spektral bandı Şekil 1.18’de görülmektedir.

Cuprite verisinin içerdiği mineral türleri USGS spektral kütüphanesinde belirtilmiştir. Verinin orijinal hali ve veriye sentetik veri testinde kullanılmış olan iki anomali spektral imzası (koyu kırmızı tuğla ve metal levha) eklendiğinde başarımlar ölçülmüş olup, Tablo 1.10 ve Tablo 1.11’de sunulmuştur.

SSPP parametrelerin değerleri, orijinal SSPP makalesinde bu veri için önerilmiş olan, $\sigma_{sspp} = 1,2$, $\beta_{sspp} = 50$ ve $\rho_{sspp} = 50$ olarak alınmıştır. SAD değerleri veride en yüksek oranda bulunduğu bilinen ve USGS spektral kütüphanesinde yer alan 5 mineral imzası (*alunite*, *kaolinite*, *muscovite*, *buddingtonite*, *calcite*), ve anomali içeren veri için anomali imzaları üzerinden hesaplanmıştır. Son eleman çıkarımı için N-FINDR ve VCA kullanılmıştır.



Şekil 1.18. Cuprite verisi için spektral bant görseli

Tablo 1.10. Anomali içermeyen Cuprite verisi için ortalama SAD sonuçları

Ön-işleme Yöntemi	N-FINDR ile	VCA ile
-	0,1123	0,1487
RBSPP	0,1154	0,1528
SSPP	0,1192	0,1618
RBSPP + KRX	0,1097	0,1505
SSPP + KRX	0,1245	0,1635

Tablo 1.11. İki anomali içeren Cuprite verisi için ortalama SAD sonuçları


Ön-işleme Yöntemi	N-FINDR ile	VCA ile
-	0,1299	0,1115
RBSPP	0,1287	0,1586
SSPP	0,1370	0,1692
RBSPP + KRX	0,0973	0,1093
SSPP + KRX	0,1173	0,1176

Tablo 1.10’da, anomali içermeyen veri için, geliştirilen yöntemin hata değerlerinin RBSPP veya SSPP ön-işleme yöntemleri kullanıldığında elde edilen hata değerlerine göre önemli ölçüde kötüleşmediği, hatta bazı durumlarda geliştirilen yöntem ile daha düşük hata değerleri elde edilebildiği görülmektedir. Bununla birlikte RBSPP ve SSPP yöntemlerinin ön-işlemesiz yöntemle göre başarımlarının artışı sağlamadığı da görülmektedir. Bu durumun nedeni, görüntünün içerdiği gürültü veya verinin doğası sonucunda, verideki son elemanların yeterli homojenliğe sahip bölgelerde yer almaması veya RBSPP ve SSPP parametrelerinin yeterince başarılı şekilde tespit edilemesi olabilir. Tablo 1.11’de ise, anomali içeren veride, geliştirilen yöntemin RBSPP veya SSPP kullanmaya oranla SAD hataları azalttığı gözlemlenmektedir. Bu tabloda SSPP+KRX ön-işleme yaklaşımının ön-işlemesiz son eleman çıkarımı yaklaşımına göre daha yüksek hata değerleri vermesi SSPP’nin kötüleştirici etkisi kaynaklıdır.

2.5.4.3. AVIRIS Salinas verisinde deneysel sonuçlar

İkinci bir gerçek hiperspektral veri olarak AVIRIS Salinas verisi kullanılmıştır. Veri 224 spektral banda ve 512×217 piksel boyutuna sahiptir. Salinas verisi hali hazırda bir anomali noktası (verinin orta üst kısmında) ve anomali sayılabilecek bina yapıları içermektedir. Bu veri için sonuçlar sadece görsel olarak, Şekil 1.19’da sunulmuştur, çünkü verideki anomali noktaları veya son elemanlar hakkında bilgi bulunmamaktadır.

Şekil 1.19 (f)’de görülebileceği üzere, verideki anomali noktası ve anomali sayılabilecek bina yapıları başarılı bir şekilde tespit edilmiştir. RBSPP ve SSPP sonrası son eleman çıkarımında, Şekil 1.19 (d)’de ve Şekil 1.19 (e)’de görüldüğü üzere, boyut olarak daha büyük olan bina yapılarından son elemanlar tespit edilmesine rağmen, verideki gerçek anomali noktasına ait son eleman tespit edilememektedir. Ancak, Şekil 1.19 (g)’de ve Şekil 1.19 (h)’de paylaşılan, önerilen yöntemin sonuçlarında, hem anomali son elemanının, hem de anomali olarak kabul edilebilecek bina yapılarından son elemanların tespit edildiği görülmektedir. Ayrıca, önerilen yöntem sonuçlarında, RBSPP ve SSPP ön-işleme yöntemleri sonrası elde edilen sonuçlarda olduğu üzere, diğer son elemanların ön-işlemesiz son eleman çıkarımına göre daha homojen bölgelerden seçildiği görülmektedir.




Şekil 1.19. Salinas verisi için görsel sonuçlar (a) Spektral bant görüntüsü #120 (b) VCA ile bulunan son eleman konumları (c) ISODATA ile elde edilen bölgeler (d) RBSP+VCA ile bulunan son eleman konumları (e) SSPP+VCA ile bulunan son eleman konumları (f) KRX ile bulunan anomali noktaları (g) RBSP+KRX+VCA ile bulunan son eleman konumları (h) SSPP+KRX+VCA ile bulunan son eleman konumları

1.5.5. Vargılar

Bu özgün çalışma kapsamında anomali tespiti ile uzamsal ön-işleme yöntemlerini birleştiren bir ön-işlem yaklaşımı geliştirilmiştir. Bu amaçla RBSPP veya SSPP ile seçilen piksel vektörleri ile KRX ile tespit edilen anomali noktaları son elemanı yöntemlerine girdi olarak verilmektedir. Geliştirilen yöntem son eleman çıkarımını geçiş bölgeleri yerine homojen bölgelere yönlendirmekte, ancak anomali noktalarını da anomali son elemanı adayları olarak tutmaktadır. Sentetik ve gerçek veriler üzerinden deneysel sonuçlar yöntemin başarımını ortaya koymaktadır. Anomali içeren verilerde yöntemin başarımını net olmakla birlikte, anomali içermeyen verilerde, yöntemin sadece RBSPP veya SSPP kullanma yaklaşımına göre sonuçları genellikle kötü etkilemediği gibi, çeşitli durumlarda performans artışına yol açtığı da göz önünde bulundurulmaya değerdir. Geliştirilen yaklaşımdan elde edilen sonuçlar bir ulusal, bir uluslararası etkinlikte bildiri olarak yayınlanmış ve sözlü olarak sunulmuştur. Yöntemin başarımı doğrudan RBSPP veya SSPP ve KRX yöntemlerinin başarımına bağlı olup, ileri bir çalışma olarak yaklaşımın iki ayağındaki yöntemlerin değiştirilmesi başarımı arttırabilir. Olası başka ileri çalışmalar arasında KRX için uyarlanır eşikleme ya da alt-piksel boyutundaki anomalileri hesaba katan bir yaklaşım düşünebilir. Ayrıca, homojen bölgelere yönlendirme ve anomali tespit etme işlemlerini içkin ve tümleşik bir şekilde yapan yeni bir yaklaşım geliştirilmesi de mümkündür.

2. SPEKTRAL KARIŞIM ANALİZİ


Son eleman çıkarımı bölümünde bahsedildiği üzere, yetersiz uzamsal çözünürlük, iç içe karışımlar ve çoklu saçılım sonucu, ölçülen spektrumlar saf materyallerin spektrumlarının karışımı şeklinde olmaktadır [5]. Yetersiz uzamsal çözünürlük sonucu oluşan makroskobik karışım ve yüksek uzamsal çözünürlükte dahi gerçekleşebilen mikroskobik karışım Şekil 2.1’de görselleştirilmiştir.



Şekil 2.1. Makroskobik ve mikroskobik karışım

Spektral karışım analizi, son elemanların hiperspektral veri pikselinin içindeki bolluk oranlarının tespiti olarak tanımlanmaktadır [36]. Bolluk oranı, genel olarak, ilgili son elemanın piksel içinde kapladığı alan yüzdesi ile ilişkilendirilmektedir [37]. Ancak spektral karışım problemi doğrusal olarak ve olmayarak modellenebilmektedir ve alan yüzdesi yaklaşımı daha çok doğrusal karışım modeli için geçerlidir. Doğrusal karışım modelinde bir piksel için gözlenen spektral yanıtın pikselin içerdiği son elemanların spektral imzalarının doğrusal bir birleşimi olduğu kabul edilir. Bu problemi sadeleştiren bir varsayımdır ve gerçekte oldukça yüksek yansımaya sahip küçük bir nesne, düşük yansımaya sahip çok daha büyük bir nesneye baskın gelebilir [5]. Bununla beraber, literatürde hala en çok çalışma doğrusal karışım modeli üzerine gerçekleştirilmekte olup, bunun temel nedeni kullanım kolaylığı ve farklı uygulamalar için esneklik [38] olmakla beraber, elde edilen başarılar modelin değerini göstermektedir.

Doğrusal karışım modelinde makroskobik saf bileşenlerin görüş alanının içinde ayrı parçalarda homojen olarak dağıldığı ve gelen ışığın tek materyal ile etkileşime girdiği varsayılmaktadır. Doğrusal olmayan karışım modelinde ise mikroskobik saf bileşenlerin piksel içinde iç içe dağıldığı ve bu bileşenler arasında çoklu etkileşim olduğu kabul edilmektedir [5]. Bununla birlikte, çoklu saçılımlar, atmosferik karıştırıcılar ve gölge etkileri karışım analizi problemini iki durumda da zorlaştırmaktadır. Karışım modelleri Şekil 2.2’de gösterilmiştir.



Şekil 2.2. Doğrusal karışım ve doğrusal olmayan karışım

Spektral karışım analizi ile son eleman çıkarımı birlikte kullanıldığında veri hakkında bir özet elde edilmektedir. Son eleman çıkarımı ile veriyi oluşturan materyallerin saf hallerinin spektral imzaları tespit edilmekte, spektral karışım analizi ile ise bu saf materyallerin verideki pikselleri hangi oranlarda karışarak oluşturdukları tespit edilmektedir. Başka bir deyişle, spektral karışım analizi ile, her saf materyalin veride piksel-altı seviyesinde hangi oranlarda bulunduğu tespit edilmektedir.

Son eleman çıkarımı ve spektral karışım analizi “kuruyemiş tabağı” benzetimi ile daha temel şekilde açıklanabilir. Şekil 2.3’de paylaşılan kuruyemiş tabağını hiperspektral verideki bir piksel vektörü ile ifade ettiğimizi düşündüğümüzde, farklı kuruyemiş türleri, örneğin badem, fındık, fıstık ve leblebi, son elemanlar olmakta, ilgili son elemanların spektral karışım analizi ile tespit edilen bolluk oranları ise bu kuruyemiş türlerinin tabağın (pikselin) içindeki oranlarını temsil etmektedir.



Şekil 2.3. Son elemanlar ve spektral karışım analizi için “kuruyemiş tabağı” benzetimi

Bu aşamada dikkat edilmesi gereken bir nokta, spektral karışım analizi ile son elemanların piksel içindeki oranlarının tespit edildiği, ancak piksel-altı seviyede uzamsal olarak dağılımlarının tespit edilmediğidir. Piksel-altı uzamsal dağılım konusu Bölüm 3’de daha detaylı olarak incelenecektir.

2.1. Doğrusal Karışım Modeli ve En Küçük Kareler Tabanlı Yöntemler

Doğrusal karışım modelinde farklı son elemanlar arasındaki çoklu saçılımın ihmal edilebilir olduğu ve yüzeyin son elemanlarca bolluk oranlarına göre orantılı olarak paylaşıldığı varsayılmaktadır.

Doğrusal karışım modelinde bir piksel için gözlenen spektral yanıt, pikselin içerdiği son elemanların spektral imzalarının doğrusal bir birleşimi olarak,

$$y_i = \sum_{j=1}^q m_{ij} \alpha_j + n_i \quad (2.1)$$

şeklinde ifade edilmektedir. Bu denklemde y_i spektral bant i ’de ölçülen yansıma değerini, m_{ij} i bandında j son elemanının yansıma değeri, q son eleman sayısı, α_j j elemanının oransal bolluğu ve n_i i bandındaki ölçüme etki eden toplamsal gürültüdür. Bu denklem matris formunda,

$$y = M\alpha + n \quad (2.2)$$

şeklinde yazılabilir. Matris formunda hiperspektral verinin L adet spektral bandı olduğu kabul edilirse $\vec{y}$ L uzunluğundaki spektrum ölçüm vektörü, M $L \times q$ boyutlu saf spektral imzaların yansıma matrisi, α q uzunluğundaki oransal bolluk vektörü ve n L uzunluğundaki gürültü vektörüdür. Doğrusal karışım modeli denkleminin iki kısıtası olup, bunlar bolluk oranlarının negatif olmamaları ve toplamlarının 1 olmasıdır;

$$\alpha \geq 0 \quad (2.3)$$

$$\bar{1}^T \alpha = 1 \quad (2.4)$$

Spektral karışım analizi probleminde y değerleri gözlemlenebilmekte olup, M değerleri son eleman çıkartımı adımı ile elde edilmiştir ve α değerleri elde edilmek istenmektedir. Bu tür bir denklem çözümünde akla ilk gelen yaklaşım en küçük kareler (Least Squares-LS) yaklaşımı olacaktır. En küçük kareler yöntemi, ölçüm sonucu elde edilmiş veri noktalarına en uygun matematiksel ilişkiyi, bir başka deyişle bu noktalara en yakın geçen fonksiyon eğrisini bulmayı hedefleyen standart bir bağlanım yöntemidir. LS ile bolluk oranları,

$$\alpha_{LS} = (M^T M)^{-1} M^T y \quad (2.5)$$

şeklinde elde edilir. LS ile spektral karışım analizi sonucunda elde edilen bolluk oranları negatif olabilmekte ve toplamı 1 olmayabilmektedir. Bu durum, karışım analizindeki iki kısıtasın ihlali anlamına gelmekte olup, istenmeyen durumu ortadan kaldırmak için literatürde koşullu LS yöntemleri geliştirilmiştir.

Ağırlıkların toplamı 1 koşullu en küçük kareler (Sum-to-one Constrained Least Squares-SCLS) ile spektral karışım analizinde [39], elde edilen fonksiyon eğrisinin büyüklüğünün 1 olması kısıtası konulmakta ve bu sayede elde edilen bolluk oranlarının toplamı her piksel için 1 olmaktadır. SCLS denklemi,

$$\alpha_{SCLS} = P_{M,1}^\perp \alpha_{LS} + (M^T M)^{-1} \bar{1} [\bar{1}^T (M^T M)^{-1} \bar{1}]^{-1} \quad (2.6)$$

$$P_{M,1}^\perp = I - (M^T M)^{-1} \bar{1} [\bar{1}^T (M^T M)^{-1} \bar{1}]^{-1} \quad (2.7)$$

$$\bar{1} = (1, 1, \dots, 1)_{1 \times q}^T \quad (2.8)$$

şeklinde elde edilmektedir. SCLS ile elde edilen ve toplamaları bire eşit olan bolluk oranları negatif olmama kistasını sağlamamaktadır. Normalize edilmiş SCLS (NSCLS) [40] yönteminde SCLS yöntemiyle elde edilen bolluk oranları arasından negatif olanlar atılmakta ve bolluk oranları toplamaları tekrar 1 olacak şekilde oranlanmaktadır. Ancak bu durum kistasın işlem bittikten sonra sağlanması anlamına gelmekte ve verimi düşürmektedir.

Negatif olmama koşullu en küçük kareler (Nonnegatively Constrained Least Squares-NCLS) [41] yönteminde ise kistas, bolluk oranlarının toplamının 1 olması değil, hiçbir bolluk oranının negatif olmamasıdır. NCLS yöntemi SCLS yönteminin aksine kapalı-form analitik bir çözüm değildir. Bunun nedeni negatif olmama koşulunun toplam 1 olma koşulunun aksine bir eşitlik koşulu değil eşitsizlik koşulu olmasıdır [41]. NCLS algoritması aşağıdaki şekilde çalışır:

- 1) Pasif küme $P^{(0)} = \{1, 2, \dots, p\}$ ve aktif küme $R^{(0)} = \emptyset$ olarak alınır. $k = 0$.
- 2) α_{LS} hesaplanır, $\alpha_{NCLS}^{(k)} = \alpha_{LS}$
- 3) k . özyinelemede $\alpha_{NCLS}^{(k)}$ 'nin hiçbir bileşeni negatif değilse işlem sonlandırılır; aksi halde devam edilir.
- 4) $k = k + 1$.
- 5) $\alpha_{NCLS}^{(k-1)}$ 'deki negatif bileşenlere tekabül eden $P^{(k-1)}$ 'deki indisler $R^{(k-1)}$ 'e aktarılır. Oluşan matrisler $S^{(k)}$ ve $R^{(k)}$ ile ifade edilir.
- 6) $\alpha_R^{(k)} \alpha_{LS}$ 'in $R^{(k)}$ 'deki bileşenleri olarak alınır.
- 7) $(M^T M)^{-1}$ matrisindeki $P^{(k)}$ ile belirtilen tüm satır ve sütunlar silinerek $\Phi_\alpha^{(k)}$ oluşturulur.
- 8) $\lambda^{(k)} = \left(\Phi_\alpha^{(k)}\right)^{-1} \alpha_R^{(k)}$ şeklinde hesaplanır. $\lambda^{(k)}$ 'deki tüm bileşenler negatif ise 13. adıma gidilir; aksi halde devam edilir.
- 9) $\lambda_{max}^{(k)} = \arg\{max_j \lambda_j^{(k)}\}$ hesaplanır. $R^{(k)}$ 'deki $\lambda_{max}^{(k)}$ 'a tekabül eden bileşen $P^{(k)}$ 'ya aktarılır.
- 10) $(M^T M)^{-1}$ matrisindeki $P^{(k)}$ ile belirtilen tüm sütunlar silinerek $\Psi_\lambda^{(k)}$ oluşturulur.
- 11) $\alpha_S^{(k)} = \alpha_{LS} - \Psi_\lambda^{(k)} \lambda^{(k)}$

12) $\alpha_S^{(k)}$ 'in $S^{(k)}$ 'deki herhangi bir bileşeni negatif ise bu bileşenler $P^{(k)}$ 'den $R^{(k)}$ 'ye alınır ve 6. adıma gidilir.

13) $(M^T M)^{-1}$ matrisindeki $P^{(k)}$ ile belirtilen tüm sütunlar silinerek $\Psi_\lambda^{(k)}$ oluşturulur.

14) $\alpha_{NCLS}^{(k)} = \alpha_{LS} - \Psi_\lambda^{(k)} \lambda^{(k)}$. 3. adıma geçilir.

NCLS yöntemi sonucunda elde edilen bolluk oranları negatif olmamakta, ancak bolluk oranlarının toplamı 1'den farklı olabilir. Sağlanmayan kısıtı sağlamak amacıyla, normalize edilmiş NCLS (NNCLS) yönteminde, NCLS yöntemi ile elde edilen bolluk oranları toplamı 1 olacak şekilde normalize etmektedir.

NSCLS ve NNCLS yöntemleri hem toplamı 1 olan hem de negatif olmayan bolluk oranları vermelerine rağmen, iki yöntem de bu kısıtlardan birini içkin olarak sağlamakta, diğerini ise elde edilen bolluk oranları üzerinden normalizasyon ile gerçekleştirmektedir. Tam koşullu en küçük kareler (Fully Constrained Least Squares-FCLS) yöntemi ise temelde NCLS ile aynı olup, yinelemeli işleme bolluk oranları toplamının 1 olması kısıtını içkin olarak eklemektedir. Bunun için, FCLS yönteminde son eleman imza matrisine toplam 1 olma koşulunu sağlayan, birlerden oluşan, bir yapay son eleman eklenmektedir. Bu ekleme,

$$N = \left[\frac{\delta M}{\mathbf{1}^T} \right] \quad (2.9)$$


$$s = \left[\frac{\delta y}{\mathbf{1}} \right] \quad (2.10)$$

şeklinde yapılmaktadır. δ değişkeni toplamın 1 olması kısıtının negatif olmama kısıtına göre önemini belirlemektedir. FCLS yöntemi NCLS yöntemine giriş olarak M ve y yerine N ve s uygulanarak elde edilir.

2.1.1. En küçük kareler tabanlı yöntemler ile deneysel sonuçlar


Bu deneysel çalışma kapsamında USGS spektral kütüphanesinden 6 adet mineral spektral imzası (*alunite*, *calcite*, *muscovite*, *olivine*, *uralite*, *zoisite*) son eleman olarak alınmıştır. Bu imzalar Şekil 2.4'te sunulmuştur.

Son elemanların karışım oranları negatif olmayacak ve oranların toplamı her piksel için 1 olacak şekilde karışımlı pikseller içeren 400 piksellik sentetik bir veri oluşturulmuştur. LS, SCLS, NSCLS, NCLS, NNCLS ve FCLS yöntemleri için gerçek bolluk oranları ile tespit edilen bolluk oranları arasında RMSE sonuçları çıkartılmıştır. FCLS için δ parametresinin değeri 0,001 olarak alınmıştır. Oluşturulan sentetik veri üzerinden gürültü eklenmeden ve farklı SNR değerlerinde beyaz Gauss gürültüsü eklenerek karışım giderimi uygulanmıştır.




Şekil 2.4. Kullanılan son eleman imzaları

Şekil 2.5'te oluşturulan sentetik verinin piksellerinin son elemanlara göre bolluk oranları dağılımı verilmiştir.



Şekil 2.5. Sentetik veri bolluk oranları

Veriye 30dB SNR gürültü eklendiğinde LS tabanlı yöntemlerle elde edilen bolluk oranları Şekil 2.6'da gösterilmiştir.



Şekil 2.6. 30dB SNR gürültülü veri üzerinden LS tabanlı yöntemlerle elde edilen bolluk oranları (a) Koşulsuz LS ile (b) SCLS ile (c) NSCLS ile (d) NCLS ile (e) NNCLS ile (f) FCLS ile

Gürültü etkisinin en az FCLS yöntemi sonuçlarında olduğu, dolayısıyla FCLS sonuçlarının gürültüye karşı daha gürbüz elde edilmiş olduğu Şekil 2.6'dan görülmektedir.

Farklı gürültü oranlarında elde edilen hatalar Tablo 2.1'de sunulmuştur.

Tablo 2.1. LS tabanlı yöntemlere göre RMSE sonuçları

	LS	SCLS	NSCLS	NCLS	NNCLS	FCLS
Gürültüsüz	9,01e-30	9,92e-30	9,93e-30	2,67e-32	2,54e-32	5,42e-32
50dB SNR Gürültülü	5,83e-06	2,62e-06	2,62e-06	5,76e-06	5,73e-06	2,61e-06
30dB SNR Gürültülü	5,23e-04	2,58e-04	2,46e-04	4,88e-04	4,84e-04	2,39e-04
10dB SNR Gürültülü	0,058	0,025	0,014	0,017	0,017	0,012

Tablo 2.1’de görüldüğü üzere, özellikle yüksek SNR değerlerinde LS tabanlı tüm yöntemler bu sentetik veri için oldukça yüksek başarı göstermiştir. Bununla beraber, özellikle gürültü oranı arttığında, FCLS yönteminin diğer LS tabanlı yöntemlere göre daha başarılı spektral karışım analizi gerçekleştirildiği görülmektedir.


2.1.2. Son eleman çıkarımı ve spektral karışım analizi deneysel sonuçları

Bu bölümde bir önceki bölümde incelenen son eleman sayısı tespiti ve son eleman çıkartımı yöntemleri ile LS tabanlı spektral karışım analizi yöntemleri ardı ardına uygulanmak suretiyle bir karışım analizi zinciri oluşturulmuştur. Bu bölüm kapsamında gerçekleştirilen deneyler literatürdeki benzer son eleman ve/veya spektral karışım analizi başarımları karşılaştırmalardan daha kapsamlıdır. Kullanılan son eleman çıkarımı yöntemleri N-FINDR, VCA, SPEE, MVSA ve SISAL yöntemleridir. Bu şekilde, ilk bölümde bahsedilen üç farklı son eleman çıkarımı yaklaşımı da değerlendirmeye alınmış olmaktadır. Ayrıca, uzamsal ön-işleme yaklaşımının, NFINDR ve VCA yöntemleri ile birlikte kullanılması sonucu elde edilen son elemanlar üzerinden karışım analizi gerçekleştirilmesinin etkisini gözlemlemek için bu yöntemler öncesinde farklı pencere boyutlarında SPP yöntemi de uygulanmıştır. SPP için 8-komşuluk esası kullanılmıştır. Spektral karışım analizi adımı için ise NCLS ve FCLS yöntemleri tercih edilmiştir.

Deneysel sonuçlar sentetik hiperspektral verilerde ve Hyperion uydusundan alınmış gerçek hiperspektral veride çıkartılmış olup, başarımlar veriden çıkartılan son elemanlar ve elde edilen karışım oranları ile tekrar oluşturulan verinin orijinal veriden RMSE cinsinden hesaplanmıştır. Ayrıca, sentetik veriler için, tespit edilen bolluk oranları ile sentetik bolluk oranları arasındaki RMSE değerleri de tablolarda sunulmuştur.

2.1.2.1. Test 1: Saf son eleman içeren sentetik veri

Sentetik hiperspektral veriyi oluşturmak için USGS spektral kütüphanesinden alınan beş adet mineral spektral imzası (*alunite*, *calcite*, *muscovite*, *uralite*, *zoisite*) kullanılmıştır. Bu imzalar Şekil 2.7’de gösterilmiştir.



Şekil 2.7. USGS kütüphanesinden alınan spektral imzalar


Seçilen beş saf son eleman spektral imzalarının her biri için 20×20 boyutlu kümeler oluşturulmuş ve 100×100 boyutlu bir alana, tüm alanı kaplayacak şekilde, rastlantısal olarak yerleştirilmektedir. Oluşturulan 100×100 veri kümesi üzerinde 17×17 boyutlu ortalama çekirdek ile süzgeçleme yapılarak çift-doğrusal (bilinear) katışimli görüntü elemanlarını içeren veri seti oluşturulmaktadır. Çekirdek boyutu saf son eleman içeren bölgelerin boyutlarından küçük olduğundan dolayı veri kümesi son eleman imzalarını saf olarak içermektedir.

Deneysel sonuçlar Tablo 2.2’de sunulmuştur.


Tablo 2.2. Saf son eleman içeren sentetik veride sonuçlar

Son eleman çıkartımı yöntemi	SPP pencere boyutu	RMSE _{veri} NCLS	RMSE _{veri} FCLS	RMSE _{bolluk} NCLS	RMSE _{bolluk} FCLS
N-FINDR	-	2,43e-16	2,72e-16	1,73e-16	5,66e-16
	3	2,43e-16	2,72e-16	1,73e-16	5,66e-16
	7	2,42e-16	2,72e-16	1,69e-16	5,66e-16
	11	2,42e-16	2,72e-16	1,70e-16	5,66e-16
VCA	-	2,42e-16	2,72e-16	1,70e-16	5,66e-16
	3	2,43e-16	2,72e-16	1,77e-16	5,66e-16
	7	2,43e-16	2,72e-16	1,76e-16	5,66e-16
	11	2,43e-16	2,72e-16	1,66e-16	5,66e-16
SPEE	-	2,15e-16	2,71e-16	1,54e-16	5,51e-16
MVSA	-	9,43e-15	1,11e-14	2,43e-16	2,83e-14
SISAL	-	1,58e-07	2,62e-07	2,76e-06	2,81e-06

Tablo 2.2’den görülebileceği üzere, kolay bir problem olan, son elemanları saf olarak içeren gürültüsüz sentetik veri problemi için, beklendiği üzere, tüm yaklaşımlar çok düşük hata değerleri vermektedir. Verideki son elemanların gerçek bolluk oranları ve SPEE+FCLS yöntem zinciri ile tespit edilen edilen bolluk oranları Şekil 2.8 ve Şekil 2.9’da görülmektedir.



Şekil 2.8. Saf son eleman içeren sentetik verideki bolluk oranları



Şekil 2.9. Saf son eleman içeren sentetik veriden SPEE+FCLS ile elde edilen bolluk oranları

2.1.2.2. Test 2: Saf son eleman içermeyen sentetik veri


Bir önceki testte kullanılan sentetik veri, bu sefer 17×17 yerine 25×25 boyutunda bir çekirdek kullanılarak süzgeçlenmiştir. Çekirdek boyutu, 20×20 piksel olan saf son eleman bölge boyutundan büyük olduğundan dolayı, oluşan sentetik veride son elemanlar saf olarak bulunmamakta, karışımli olmaktadır. Oluşan veri için elde edilen hata sonuçları Tablo 2.3’de sunulmuştur.

Tablo 2.3. Saf son eleman içermeyen sentetik veride sonuçlar


Son eleman çıkartımı yöntemi	SPP pencere boyutu	RMSE _{veri} NCLS	RMSE _{veri} FCLS	RMSE _{bolluk} NCLS	RMSE _{bolluk} FCLS
N-FINDR	-	0,0114	0,0164	0,1019	0,0883
	3	0,0091	0,0155	0,0898	0,0783
	7	0,0088	0,0150	0,0891	0,0781
	11	0,0086	0,0145	0,0886	0,0779
VCA	-	0,0064	0,0121	0,0856	0,0731
	3	0,0082	0,0179	0,1065	0,0987
	7	0,0083	0,0179	0,1079	0,1017
	11	0,0083	0,0155	0,0978	0,0943
SPEE	-	0,0093	0,0148	0,0945	0,0834
MVSA	-	6,70e-15	7,28e-15	2,47e-14	2,13e-14
SISAL	-	1,27e-06	1,91e-06	1,02e-04	1,02e-04

Sentetik veri, son elemanları saf olarak içermediği durumda, veride son elemanların saf olarak bulunduğunu varsayan son eleman çıkartımı yöntemlerinin (N-FINDR, SISAL, SPEE) başarımının düştüğü Tablo 2.3’de yükselen hata değerlerinden anlaşılmaktadır. İlgili son eleman çıkarımı yöntemlerini başarımının düşmesi, bu yöntemler sonrası uygulanan spektral karışım analizi başarımını da olumsuz olarak etkilemektedir. En düşük veri geri oluşturma hatası ve en düşük bolluk oranları tespiti hatası, veride son elemanların saf olarak bulunduğu varsayımını yapmayan MVSA yöntemi ve sonrasında kullanılan spektral karışım analizi ile sağlanmıştır. Beş farklı son eleman için sentetik verideki gerçek bolluk oranları, MVSA+FCLS ile ve SPEE+FCLS için elde edilen bolluk oranları haritaları, sırasıyla, Şekil 2.10, Şekil 2.11 ve Şekil 2.12’de görülmektedir. Şekil 2.11 ve Şekil 2.12’deki parlaklık


değerlerinden görülebileceği üzere, SPEE+FCLS yöntem zinciri ile, MVSA+FCLS yöntem zincirine göre daha yüksek bolluk oranları elde edilmiştir. Bunun nedeni, SPEE'nin son elemanları verideki piksel vektörlerinden seçmesi, bir başka deyişle, veride aslında saf durumda olmayan piksel vektörlerini safmış gibi kabul etmesindendir.



Şekil 2.10. Saf son eleman içermeyen sentetik verideki bolluk oranları



Şekil 2.11. Saf son eleman içermeyen sentetik veriden MVSA+FCLS ile elde edilen bolluk oranları



Şekil 2.12. Saf son eleman içermeyen sentetik veriden SPEE+FCLS ile elde edilen bolluk oranları

2.1.2.3. Test 3: Saf son eleman içermeyen gürültülü sentetik veri


Bir önceki testte kullanılmış olan, son eleman imzalarını saf olarak içermeyen, verinin spektral bantlarına 50 dB SNR beyaz toplamalı Gauss gürültüsü uygulanarak yeni bir sentetik veri elde edilmiştir.

Bu veri üzerinden son eleman çıkartımı ve spektral karışım analizi gerçekleştirilmiş olup, hata sonuçları Tablo 2.4'de sunulmuştur.


Tablo 2.4. Saf son eleman içermeyen gürültülü sentetik veride sonuçlar

Son eleman çıkartımı yöntemi	SPP pencere boyutu	RMSE _{veri} NCLS	RMSE _{veri} FCLS	RMSE _{bolluk} NCLS	RMSE _{bolluk} FCLS
N-FINDR	-	0,0087	0,0147	0,0672	0,0742
	3	0,0110	0,0150	0,0670	0,0572
	7	0,0111	0,0153	0,0661	0,0571
	11	0,0112	0,0154	0,0662	0,0574
VCA	-	0,0126	0,0215	0,0804	0,0804
	3	0,0097	0,0153	0,0726	0,0592
	7	0,0106	0,0312	0,1081	0,0986
	11	0,0131	0,0354	0,1041	0,0998
SPEE	-	0,0133	0,0198	0,1130	0,0892
MVSA	-	5,43e-05	5,44e-05	6,57e-05	6,00e-05
SISAL	-	5,44e-05	5,45e-05	7,88e-05	7,58e-05


Eklenen beyaz Gauss gürültü sonucunda gerek veriyi geri oluşturma hataları gerekse verideki içkin bolluk oranlarını bulma hataları Tablo 2.3'e göre, beklendiği üzere, artmıştır. Ancak saf son eleman içermeyen bu gürültülü sentetik veri için, geri oluşturulmuş veride ve tespit edilen bolluk oranlarında en düşük hatayı, Tablo 2.3'deki gibi, MVSA ve SISAL yöntemleri ile elde edilen son elemanlar sağlamıştır. Bunun nedeni, veriyi gerçek anlamda ifade eden son elemanların veride saf olarak bulunmamasıdır. Sentetik verideki gerçek bolluk oranları, MVSA+FCLS yöntem zinciri ile ve SPEE+FCLS yöntem zinciri ile elde edilen bolluk oranları haritaları sırasıyla Şekil 2.13, Şekil 2.14 ve Şekil 2.15'te gösterilmiştir.



Şekil 2.13. Saf son eleman içermeyen gürültülü sentetik verideki bolluk oranları



Şekil 2.14. Saf son eleman içermeyen gürültülü sentetik veriden MVSA+FCLS ile elde edilen bolluk oranları



Şekil 2.15. Saf son eleman içermeyen gürültülü sentetik veriden NFINDR+FCLS ile elde edilen bolluk oranları

2.1.2.4. Test 4: Hyperion verisi


Bu test için, Hyperion uydusundan, 21 Haziran 2012 tarihli, Tuz Gölü bölgesine ait hiperspektral veri edinilerek kullanılmıştır. Verinin uzamsal boyutları 63×63 olup, yüksek atmosferik gürültü etkileri içeren spektral bantların atılmasından sonra 162 adet spektral banda sahip olmaktadır. Verinin uzamsal çözünürlüğü 30m'dir. Verinin ait olan tarihe yakın bir tarihte, bölgede, saha çalışması yapılmış ve bu çalışma sonucu veride 7 son eleman tanımlanmıştır. Bununla birlikte, son eleman sayısı çıkartma yöntemi olan HySime veri üzerinde kullanıldığında toplam 32 adet son eleman tespit etmiştir. Bunun nedeni uydu verilerinin içerdiği yüksek değişimdir. Farklı son eleman çıkartımı yöntemleri ile 32 adet son eleman çıkartılmış ve benzer son elemanlar birleştirilerek açısıl farklılıkların toplamındaki değişime bakılmıştır. Bu analiz sonucu, genel olarak, son eleman sayısı 11 olduğunda grafikte bir kırılma gözlemlenmiş ve bu yüzden yapılan testlerde son eleman sayısı olarak, saha çalışmasında tespit edilen 7 ve deneysel yöntemler ile tespit edilen 11 kullanılmıştır. Verideki gerçek bolluk oranları bilinmediğinden dolayı başarımlar sadece geri oluşturulan verinin orijinal veriden ne kadar farklı olduğu cinsinden ($RMSE_{veri}$) hesaplanabilmektedir. Elde edilen hata oranları Tablo 2.5'de verilmiştir. Hata değerlerinin önceki tablolara göre sayısal olarak çok daha yüksek görünmesi kullanılan Hyperion verisinin 16-bit tamsayı formatında olmasından kaynaklıdır.

Tablo 2.5. Hyperion verisinde sonuçlar

Son eleman çıkartımı yöntemi	Son eleman sayısı	SPP pencere boyutu	RMSE _{veri} NCLS	RMSE _{veri} FCLS
N-FINDR	7	-	71,73	71,77
		3	72,13	72,13
		5	61,78	61,77
		7	67,11	67,09
	11	-	60,24	60,21
		3	59,04	59,03
		5	58,56	58,55
		7	57,30	57,29
VCA	7	-	65,48	65,48
		3	60,95	60,95
		5	60,30	60,30
		7	68,40	68,40
	11	-	62,04	62,03
		3	60,31	60,30
		5	59,88	59,87
		7	56,45	56,44
SPEE	7	-	70,50	70,49
	11	-	71,30	71,31
MVSA	7	-	45,97	45,98
	11	-	40,90	40,91
SISAL	7	-	45,97	45,98
	11	-	40,89	40,91


Hiperspektral Hyperion verisi için en düşük veri geri oluşturma hatasını SISAL+NCLS yöntem zinciri vermiştir. Bu tür gürültü oranı yüksek, uzamsal çözünürlüğü oldukça düşük verilerde son elemanları veride piksel boyutunda saf olarak tespit etmek zorlaşmaktadır. Bu yüzden MVSA ve SISAL gibi yöntemlerin diğer son eleman çıkarımı yöntemlerine göre daha düşük veri oluşturma hatası vermesi beklenmektedir.

Kullanılan Hyperion verisi ile aynı bölgenin yakın tarihli WorldView verisi kullanılarak ve bölgede gerçekleştirilen saha çalışmaları sonucunda çıkartılan yer doğrusu haritası Şekil 2.16’da sunulmuştur. Bununla birlikte, aynı sınıfa ait olduğu belirtilen bölgeler arasında da farklılıklar bulunmaktadır. Örneğin, iki farklı tarlada ekili arpalar boyları, sağlıkları ve ekili oldukları toprak yapısı farklılık göstermektedir.




Şekil 2.16. Hyperion verisi yer doğrusu haritası

Şekil 2.17’de ve Şekil 2.18’de ise Tablo 2.5’teki sırayla ve FCLS ile spektral karışım analizi sonucunda, her pikselin bu pikselde en yüksek bolluk oranı elde edilen son elemana atanması sonucu elde edilen haritalar verilmiştir. Kullanılan her son eleman çıkartımı yöntemi son elemanları farklı konumlarda ve farklı sıralama ile bulduğundan dolayı aynı bölgeler her yöntem için farklı renkte olabilmektedir. Sonuçlar Şekil 2.16’da verilen yer doğrusu haritası ile karşılaştırılarak görsel olarak değerlendirilebilir.




Şekil 2.17. Hyperion verisi en büyük bolluk oranı haritaları (a) N-FINDR 7 son eleman (b) N-FINDR 7 son eleman, $w_{spp} = 3$ (c) N-FINDR 7 son eleman, $w_{spp} = 5$ (d) N-FINDR 7 son eleman, $w_{spp} = 7$ (e) N-FINDR 11 son eleman (f) N-FINDR 11 son eleman, $w_{spp} = 3$ (g) N-FINDR 11 son eleman, $w_{spp} = 5$ (h) N-FINDR 11 son eleman, $w_{spp} = 7$ (i) VCA 7 son eleman (j) VCA 7 son eleman, $w_{spp} = 3$ (k) VCA 7 son eleman, $w_{spp} = 5$ (l) VCA 7 son eleman, $w_{spp} = 7$ (m) VCA 11 son eleman (n) VCA 11 son eleman, $w_{spp} = 3$ (o) VCA 11 son eleman, $w_{spp} = 5$ (p) VCA 11 son eleman, $w_{spp} = 7$




Şekil 2.18. Hyperion verisi en büyük bolluk oranı haritaları - 2 (a) SPEE 7 son eleman (b) SPEE 11 son eleman (c) MVSA 7 son eleman (d) MVSA 11 son eleman (e) SISAL 7 son eleman (f) SISAL 11 son eleman

Şekil 2.17 ve Şekil 2.18 incelendiğinde bazı genel durumlar dikkati çekmektedir. Verideki sınıf içi değişiminin yüksek olması sonucunda, yer doğrusu haritasında tek bir sınıfa atanmış olan bölgeler iki farklı son elemanın baskınlığı altında olabilmektedir. Örneğin, yer doğrusu haritasında toprak olarak etiketlenmiş bölge için iki farklı son eleman baskın olabilmekte, başka bir deyişle iki farklı “toprak” son elemanı elde edilebilmektedir. Yer doğrusu ile en yüksek bolluk oranı haritaları arasında oluşan bu farklılık son eleman çıkarımı ve spektral karışım analizi sonucunun düşük başarımında olduğunu göstermemekte, verideki, saha çalışmasında gözle görülemeyen, sınıf için yüksek değişimliliğe ışık tutmaktadır. Başka bir dikkat çeken nokta, özellikle yer doğru haritasında buğday ve arpa olarak etiketlenmiş bölgelerdeki baskın son elemanların karışımıdır. Bu durumun kaynağı buğday ve arpa spektral imzalarının yüksek benzerliği ve her tarla içindeki spektral açıdan yüksek değişimliliğidir. Özellikle 11 son eleman içeren sonuçlarda görülen önemli bir başka durum ise bazı son elemanların uydu verilerinde sıklıkla oluşan görüntü yapay etkilerini (image artifacts) ifade etmekte olmasıdır. Bu durum kullanıcı tarafından istenmeyen bir durum olabileceği gibi, tespit edilen son eleman ve bolluk oranları kullanılarak, verideki ilgili etkilerin kolaylıkla giderilmesi de mümkün olmaktadır.



Şekil 2.19. Hyperion verisi en büyük bolluk oranı eşiklenmiş haritaları (a) N-FINDR 7 son eleman (b) N-FINDR 7 son eleman, $w_{spp} = 3$ (c) N-FINDR 7 son eleman, $w_{spp} = 5$ (d) N-FINDR 7 son eleman, $w_{spp} = 7$ (e) N-FINDR 11 son eleman (f) N-FINDR 11 son eleman, $w_{spp} = 3$ (g) N-FINDR 11 son eleman, $w_{spp} = 5$ (h) N-FINDR 11 son eleman, $w_{spp} = 7$ (i) VCA 7 son eleman (j) VCA 7 son eleman, $w_{spp} = 3$ (k) VCA 7 son eleman, $w_{spp} = 5$ (l) VCA 7 son eleman, $w_{spp} = 7$ (m) VCA 11 son eleman (n) VCA 11 son eleman, $w_{spp} = 3$ (o) VCA 11 son eleman, $w_{spp} = 5$ (p) VCA 11 son eleman, $w_{spp} = 7$



Şekil 2.20. Hyperion verisi en büyük bolluk oranı eşiklenmiş haritaları - 2 (a) SPEE 7 son eleman (b) SPEE 11 son eleman (c) MVSA 7 son eleman (d) MVSA 11 son eleman (e) SISAL 7 son eleman (f) SISAL 11 son eleman

Şekil 2.19’da ve Şekil 2.20’de ise piksellerin en yüksek bolluk oranı verdikleri son elemana, belirli bir eşik değerinden yüksek bolluk oranı vermek şartıyla, atanmaları sonucunda elde edilen haritalar görülmektedir. En yüksek bolluk oranı eşiği olarak 0,4 kullanılmıştır. Eşik değerini aşamayan pikseller ise siyah renkle temsil edilmişlerdir. Başka bir deyişle, bir piksel içinde son elemanlardan herhangi biri yeterince yüksek oranda değilse, o piksel siyah renk ile temsil edilmektedir.

Verideki yüksek miktardaki karışım ve değişinti Şekil 2.19 ve Şekil 2.20’de daha net olarak anlaşılmaktadır. Sınıflar arasında en çok karışım, verinin orta ve sol tarafında, buğday ve arpa sınıfları arasında gerçekleşmektedir. Ayrıca, Tablo 2.5’te görüldüğü üzere, özellikle MVSA ve SISAL yöntemleri ile veri en düşük hata ile geri elde edilmekte olmasına rağmen, eşiklenmiş bolluk oranları haritalarında siyah etiketlerin çokluğu dikkat çekmektedir. Bu durum, bu yöntemler ile tespit edilen son elemanların veride saf olarak bulunmamasının da etkisi ile, pikseller için tespit edilen bollukların daha düşük olarak bulunması kaynaklıdır. Başka bir deyişle, çıkartılan suni son elemanlar ile piksellerin son elemanlar cinsinden ifadesi daha çok karışıklı şekilde elde edilmektedir. Yöntemlerin karşılaştırması yapılırken, gerçek hiperspektral verilerde oluşmaya meyilli bu durum da dikkate alınmalıdır.

2.2. Doğrusal Spektral Karışım Analizi için Bulanık Mantık Kullanımı:

Spektral karışım analizi zorlu bir problem olup, gerçek verilerde alıcı ve sahne gürültüsü sonucu, elde edilen bolluk oranlarında keskin doğruluk bulunmamaktadır [42]. Bu tür belirsizlik içeren problemler için olasılıksal ve bulanık olmak üzere iki önemli yaklaşım bulunmaktadır. Olasılıksal yaklaşımda, gözlemlenen verinin altta yatan bir rastgelelik içeren dağılımın olası sonuçları arasından biri olduğu kabul edilmektedir. Bulanık mantıkta ise farklı sınıflar (kümeler) için kısmi üyelik kavramı kullanılmaktadır. Bulanık mantık yaklaşımı görüntü işleme alanında birçok uygulamada kendisine yer edinmiştir.

Bulanık mantık yaklaşımı spektral karışım analizi ile birlikte ilk olarak [43]'de kullanılmıştır. Bu çalışmada spektral karışım analizi için c-ortalamlar kümeleme yöntemi kullanılmakta ve farklı karışım oranları kümelerini ifade eden sınıflar için bulanık üyelik yaklaşımı kullanılmaktadır. [44]'de ise benzer bir yaklaşım olasılıksal c-ortalamlar kümeleme yöntemi ile kullanılmaktadır. [42]'de hiperspektral verilerde gözlenen sınıf içi değişinti de dikkate alınmış ve bir karışım spektrumunun saf spektrumların birden fazla doğrusal birleşimi ile elde edilebileceği belirtilerek bulanık üyelikler buna göre düzenlenmiştir. Daha güncel bir çalışma olan [45]'te ise bulanık kümeler ile en küçük kareler arasında bağlantı kurulup, bulanık küme yaklaşımı için analitik bir çözüm geliştirilmiştir.

Spektral karışım analizinde bulanık mantık kullanılması için farklı bir yaklaşım ise verideki uzamsal bilgilerin spektral karışım analizi işlemine dahil edilmesi esasına dayanmaktadır. Spektral karışım analizi için bulanık yerel bilgi c-ortalamlar (Fuzzy Local Information C-Means-FLICM) [46] yöntemi bu amaçla [47] ve [48]'de kullanılmıştır. FLICM orijinal olarak kümeleme uygulamaları için geliştirilmiş olan ve diğer bulanık c-ortalamlar yöntemlerinden farklı olarak ampirik olarak optimize edilmesi gereken değişken barındırmayan bir yaklaşımdır [46].

Bu tez çalışması kapsamında FLICM ile spektral karışım analizi incelenmiş olup, bu yaklaşım üzerine iki özgün yaklaşım geliştirilmiştir. Takip eden bölümlerde önce FLICM ile spektral karışım analizi, daha sonra da bu özgün yaklaşımlar paylaşılacaktır.

2.2.1. FLICM

FLICM, komşu piksellerden elde edilen uzamsal bilgileri optimize edilecek nesnel işleve dahil etmek için bulanık bir G_{ki} faktörü kullanılmaktadır;

$$G_{ki} = \sum_{\substack{j \in N_i \\ j \neq i}} \frac{1}{d_{ij} + 1} (1 - u_{kj})^m \|x_j - v_k\|^2 \quad (2.11)$$

Bu denklemde i yerel pencerenin merkezinde yer alan pikselin indisi, k referans kümesinin indisi, j ise i indisli pikselin etrafındaki pencere içindeki komşu piksellerin indisidir. d_{ij} , i ve j indisli piksellerin arasındaki uzamsal Öklid uzaklığı olup, u_{kj} j indisli pikselin k kümesine bulanık üyelik oranı ve m bulanık üyeliklerin ağırlık katsayısıdır. v_k ise k kümesinin merkez prototipidir. Denklem (2.11)'de görüleceği üzere, G_{ki} optimize edilmesi gereken parametrelerden arınmış bir faktördür.

FLICM görüntü kümeleme amacıyla kullanıldığında, G_{ki} içeren nesnel işlev,

$$I_m = \sum_{i=1}^N \sum_{k=1}^c [u_{ki}^m \|x_i - v_k\|^2 + G_{ki}] \quad (2.12)$$

şeklindedir. J_m 'nin yerel olarak en küçük değerinde bulunması için u_{ki} ve v_k ,

$$u_{ki} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_i - v_k\|^2 + G_{ki}}{\|x_i - v_j\|^2 + G_{ji}} \right)^{1/(m-1)}} \quad (2.13)$$

$$v_k = \frac{\sum_{i=1}^N u_{ki}^m x_i}{\sum_{i=1}^N u_{ki}^m} \quad (2.14)$$

şeklinde olmalıdır. FLICM algoritmasının çalışması şu şekilde özetlenebilir:

Adım 1. Küme sayısı c , bulanıklık parametresi m ve durma koşulu ε belirlenir.

Adım 2. Bulanık kümeleme matrisi rastgele olarak belirlenir.

Adım 3. v_k güncellenir.

Adım 4. G_{ki} ve u_{ki} güncellenir.

Adım 5. $\max \{U_{eski} - U_{yeni}\} < \varepsilon$ ise işlem durur. Aksi halde 3. adıma dönülür.

2.2.2. FLICM ile spektral karışım analizi

Spektral karışım analizi kapsamında doğrusal karışım analizinde kullanılan nesnel işlev,

$$J = \sum_{i=1}^N \|x_i - Mp_i\|_2^2 \quad (2.15)$$

şeklindedir. Bu denklemde M son eleman matrisini, x_i i indisli piksel vektörünü, p_i ise bu piksel vektörünün son elemanlara göre bolluk oranlarını göstermektedir. FLICM ile spektral karışım analizinde orijinal FLICM yöntemine,

$$G_{ik} = \sum_{\substack{j \in N_i \\ i \neq j}} \frac{1}{d_{ij} + 1} (1 - \alpha_{kj})^m \frac{1}{\|x_j - Mp_j\|_2^2 + 1} \quad (2.16)$$

değişikliği yapılmaktadır. G_{ik} denklemde, N_i i piksel vektörünün uzamsal olarak etrafındaki komşuluğu, d_{ij} i ve j piksellerinin uzamsal olarak uzaklığını, α_{kj} j pikselinde k son elemanının bolluk oranını vermektedir. Spektral karışım analizinin nesnel işlevi ise,

$$J = \sum_{i=1}^N (\|x_i - Mp_i\|_2^2 + \gamma G_i^T \alpha_i) \quad (2.17)$$

şeklinde güncellenmektedir. Bu denklemde G_i i pikseli için hesaplanan G değerlerini, γ ise hata terimi ile uzamsal yumuşatma terimi arasındaki ödünleşim parametresini göstermektedir. γ büyüdükçe uzamsal yumuşatmanın etkisi artmakta ve artıklık hatasının önem etkisi azalmaktadır. Denklem (2.17)'deki denklem,

$$J = \sum_{i=1}^N (x_i^T x_i + \alpha_i^T M^T M \alpha_i - \alpha_i^T M^T x_i - x_i^T M \alpha_i + \gamma G_i^T \alpha_i) \quad (2.18)$$

şeklinde açık olarak yazılabilir. Bolluk oranlarını bulmak için türev alındığında,

$$\frac{\partial J}{\partial \alpha_i} = 2 \times \alpha_i^T M^T M - 2 \times M^T x_i + \gamma G_i^T \quad (2.19)$$

elde edilmektedir. Bolluk oranlarını bu denklemden çektiğimizde,

$$\hat{\alpha}_i = (M^T M)^{-1} M^T x_i - \gamma G_i^T \quad (2.20)$$

elde edilmekte olup, Denklem (2.16) ve (2.20) bir arada analitik olarak çözülememektedir. Bu yüzden, yöntem yinelemeli olarak Denklem (2.16) ile G_{ik} terimlerini güncellemekte ve bu terimleri kullanarak Denklem (2.20)'den α_i değerlerini elde etmektedir. Bu işlem yinelemeli olarak tekrarlanmakta olup, α_i için önemli iki kısıtası, negatif olmama ve toplamların bire eşit olma kısıtlarını dikkate aldığımızda Denklem (2.20) bir optimizasyon problemine dönüşmektedir. Bu problemin çözümü için, orijinal çalışmada ve bu tez kapsamında ikinci dereceden programlama kullanılmaktadır.

2.2.3. Özgün çalışma: Spektral uzaklıklı FLICM ile spektral karışım analizi

FLICM ile spektral karışım analizi yaklaşımında, pikselin komşuluğundaki piksellerin bolluk oranları cinsinden gelen uzamsal bilgiler, karışım analizi işlemine G_{ik} terimi ile dahil edilmektedir. G_{ik} teriminin denkleminde yer alan, bolluk oranı hesaplanan piksel vektörü ile komşuluğundaki piksel vektörlerin Öklid uzaklığını betimleyen d_{ij} , komşu piksel vektörlerinin bolluk oranlarının hesaplanan pikselin bolluk oranına etkilerini, piksele uzaklıkları ile ters orantılı olarak, oranlamaktadır.

Ancak bu uzaklık metriğinin sadece uzamsal tabanlı olması, komşu piksellerin bolluklarının etkisinin sadece uzamsal uzaklığa göre belirlenmesi, bu piksellerin spektral yapısının mevcut piksele benzerliğinin veya farklılığının önem taşımaması anlamına gelmektedir.

Bu tez çalışması kapsamında geliştirilen özgün yaklaşım sayesinde, G_{ik} terimindeki uzaklık metriği sadece uzamsal değil, aynı zamanda spektral açı farkı kullanılarak spektral olarak da hesaplanmakta, bir φ değişkeni ile spektral uzaklığın etkisi kontrol edilmektedir. Güncellenen d_{ij} metriği,


$$d'_{ij} = (1 - \lambda) \times d_{ij} + \varphi \times SAD(x_i, x_j) \quad (3.21)$$

şeklinde ifade edilebilir. Bu yaklaşım ile bir piksel vektörünün bolluk oranı hesaplanırken bu piksel vektörü etrafında bir pencere içinde kalan piksel

vektörlerinin bolluk oranlarının etkisi sadece uzamsal uzaklıklarına göre değil, aynı zamanda piksel vektörüne spektral yapı açısından benzerliklerine göre de belirlenmektedir. Bu bilgi bulanık ve yerel olarak spektral karışım analizi işlemine dahil edilmektedir.

Test 1: Beyaz Gauss gürültülü sentetik veri

Sentetik test verisini oluşturmak için USGS kütüphanesinden beş adet mineral imzası (*alunite, calcite, muscovite, uralite, zoisite*) son eleman olarak kullanılmıştır. Bu son eleman imzalarının her biri için bir bölge olacak şekilde 100×100 boyutlu bir alan oluşturulmuştur. Oluşan veri 5×5 Gauss süzgecinden geçirilerek, kenar bölgelerde gerçeğe verilerdekilere uygun karışımlar elde edilmesi sağlanmıştır. Hiperspektral veri alıcılarda veri alımı sırasında oluşan atmosferik gürültü ve ölçüm gürültülerini modellemek amacıyla verinin spektral bantlarına farklı SNR oranlarında toplamsal beyaz Gauss gürültüsü uygulanmıştır. Şekil 2.21’de oluşturulan sentetik verinin spektral bant görseli ve yüksek oranda gürültü uygulanmış bant görseli yer almaktadır.



Şekil 2.21. Spektral bant görselleri (a) sentetik veri için (b) 10dB SNR gürültü uygulanmış veri için

FCLS, FLICM ve geliştirilen özgün FLICM spektral karışım analizi yaklaşımlarının başarımları, elde edilen bolluk oranları ile gerçek bolluk oranları arasındaki hata ve geri oluşturulan veri ile gerçek veri arasındaki hata, RMSE cinsinden, ölçülmüştür. FCLS için gerekli olan δ katsayısı 0.001 alınmış olup, FLICM ve özgün FLICM için γ parametresi [47]’de önerilen 0.1 değerinde, komşuluk pencere boyutu 5×5 olarak, en büyük özyineleme sayısı ise 100 olarak alınmıştır. Özgün FLICM’de gerekli olan ödüneleşim parametresi λ farklı değerlerde alınarak başarımlar ölçülmüştür.

Dikkat edilmesi gereken bir nokta, geri oluşturma hatasının verinin gürültülü hali ile hesaplanmayıp, gürültü uygulanmadan önceki hali ile hesaplanmasıdır. Geri oluşturulma hatasının gürültülü veri üzerinden hesaplanması durumunda, en düşük hata, orijinal veri yerine gürültülü veriye en iyi yakınsayan spektral karışım analizi yöntemi ile elde edilecektir. FLICM ve özgün FLICM ile spektral karışım analizi komşuluk bilgilerini kullanarak gürültü etkisine karşı gürbüzlük kazandırmakta ve gürültülü veriyi en iyi şekilde temsil edecek FCLS'ye göre verinin orijinal haline daha yakın bir sonuç elde etmeyi sağlamaktadır. Bolluk hataları Tablo 2.6'da, veri geri oluşturma hataları ise Tablo 2.7'de sunulmuştur.

Tablo 2.6. Bulanık mantık ile spektral karışım analizinde $RMSE_{\text{bolluk}}$ sonuçları


Spektral Karışım Analizi Yöntemi	10dB SNR	30dB SNR	50dB SNR	70dB SNR
FCLS	0,0262	0,0027	2,71e-04	2,71e-05
FLICM ($\varphi = 0$)	0,0251	5,01e-04	1,63e-04	1,71e-04
Özgün FLICM ($\varphi = 0,5$)	0,0248	3,49e-04	2,31e-04	2,43e-04
Özgün FLICM ($\varphi = 1$)	0,0245	3,05e-04	4,06e-04	4,23e-04

Tablo 2.7. Bulanık mantık ile spektral karışım analizinde $RMSE_{\text{veri}}$ sonuçları

Spektral Karışım Analizi Yöntemi	10dB SNR	30dB SNR	50dB SNR	70dB SNR
FCLS	0,0111	0,0011	1,15e-04	1,13e-05
FLICM ($\varphi = 0$)	0,0108	3,21e-04	1,07e-04	1,13e-04
Özgün FLICM ($\varphi = 0,5$)	0,0107	2,30e-04	1,52e-04	1,60e-04
Özgün FLICM ($\varphi = 1$)	0,0106	2,08e-04	2,77e-04	2,91e-04

Özellikle yüksek gürültü (düşük SNR) durumlarında spektral uzaklığın uzamsal uzaklığa göre komşu piksellerin bolluk oranlarının etkisini daha iyi oranladığı ve dolayısıyla gürültüye karşı daha fazla gürbüzlük kazandırdığı görülmektedir.


Spektral karışım analizi yöntemleri kullanılarak elde edilen bolluk oranlarıyla geri oluşturulmuş verilerin bant görselleri Şekil 2.22'de sunulmuştur.



Şekil 2.22. Spektral bant görselleri (a) Sentetik veri. 10dB SNR uygulanmış veriden (b) FCLS ile geri oluşturulan veri (c) FLICM ile geri oluşturulan veri (d) Özgün FLICM ile geri oluşturulan veri ($\varphi = 0,5$)

Test 2: Gerçek hiperspektral veri: Indian Pine

Bu deneysel çalışmada AVIRIS Indian Pine verisi kullanılmıştır. Veri 145×145 uzamsal boyutlarda olup, gürültülü bantların elenmesi sonrası 200 spektral banda sahiptir. Verinin uzamsal çözünürlüğü 20 metredir. Son eleman sayısı HFC yöntemi ile 8 olarak tespit edilmiştir ve VCA ile son eleman çıkarımı uygulanmıştır. FCLS, FLICM ve özgün FLICM yöntemleri ile spektral karışım analizi uygulanarak her son eleman için elde edilen bolluk oranları haritaları Şekil 2.23’de gösterilmiştir.



Şekil 2.23. AVIRIS Indian Pine verisi için elde edilen bolluk oranları (a) FCLS ile (b) FLICM ile (c) Özgün FLICM ile


Şekil 2.23’den görülebileceği üzere, gerek FLICM gerekse özgün FLICM yaklaşımı ile elde edilen bolluk oranları, FCLS ile elde edilen bolluk oranlarına göre daha yumuşak dağılmış olup, gürültü benzeri ani değişimler büyük oranda azalmıştır. Bu etki özellikle ikinci, altıncı ve sekizinci son elemanlar için net olarak görülmektedir.

Veriden VCA ile birinci son eleman olarak çıkartılmış olan çelik bina için ise, bulanık mantık kullanan iki yöntemde bu imza için bolluk oranları, FCLS'nin aksine, beklendiği ve doğru olduğu üzere, verinin başka yerlerinde elde edilmemiştir. Bununla beraber, bu veri için elde edilen görsel sonuçlarda, geliştirilen spektral uzaklıkları FLICM yaklaşımının standart FLICM ile spektral karışım analizine göre başarımları net bir şekilde görülmektedir.

Test 3: Gerçek hiperspektral veri: ROSIS Pavia University

Bu deneysel çalışmada ROSIS Pavia University verisi kullanılmıştır. Verinin uzamsal boyutları 610×340 pikseldir ve yüksek atmosferik gürültü içeren bantların elenmesi sonrasında 103 spektral banda sahiptir. Verinin uzamsal çözünürlüğü 1,5m'dir. Verinin yer doğrusu haritasında 9 sınıf olduğu için 9 son eleman çıkartılmıştır.

Son eleman çıkarımı için VCA kullanılmıştır. FCLS, FLICM ve özgün FLICM yöntemleri ile spektral karışım analizi uygulanarak elde edilen son eleman bolluk oranları Şekil 2.24'te gösterilmiştir.



Şekil 2.24. ROSIS Pavia University verisi için elde edilen bolluk oranları (a) FCLS ile (b) FLICM ile (c) Özgün FLICM ile

Şekil 2.24'te, özellikle bina ve yol son elemanlarına ait bolluk haritalarında, FLICM tabanlı spektral karışım analizi yöntemlerinin FCLS ile spektral karışım analizine göre daha doğru sonuçlar verdiği görülmektedir. Bu durum özellikle yedinci son eleman için verilen bolluk haritalarında daha net olarak anlaşılmaktadır. Şekil 2.20'ye benzer şekilde, geliştirilen yöntem ile standart FCLS'ye göre görsel açıdan daha iyi sonuçlar elde edilmekte olup, özgün FLICM ile standart FLICM arasındaki farkları ise anlamlandırmak zordur.


Vargılar:

Bulanık mantık ile spektral karışım analizi için bu tez çalışması kapsamında geliştirilen özgün yöntem, bulanık yerel bilgiyi kullanırken sadece uzamsal uzaklığı değil, spektral uzaklığı da dikkate almakta ve pikselin bolluk oranına komşu piksel vektörlerinin etkisini bu yakınlıklara göre oranlamaktadır. Sentetik veride gerçekleştirilen deneyde, özellikle yüksek gürültü oranlarında, geliştirilen yöntemin standart FLICM ile spektral karışım analizine göre daha iyi sonuçlar verdiği gözlemlenmektedir. Bunun nedeni, gürültü arttığında komşu piksellerin mevcut piksele uzamsal uzaklığı değişmezken, gürültüye bağlı olarak spektral uzaklıklarının değişmesidir. Bu sayede, komşu piksellerin bolluk oranlarına etkisini oranlamak için spektral uzaklık kullanılması, gürültü etkisiyle farklılaşan komşu piksellerin bolluk oranına etkisini spektral yapıları değiştiğinden dolayı azaltmaktadır. Gerçek verilerde gerçekleştirilen deneysel çalışmalarda ise, sayısal sonuçlar verinin alıcı ve sahne gürültüsünden arınmış hali bulunmadığı için çıkartılamamaktadır. Görsel sonuçlar incelendiğinde, FCLS ile spektral karışım analizine göre, FLICM tabanlı yöntemler, bolluk haritalarını daha yumuşak geçişlere sahip ve daha az gürültülü şekilde verdiği görülmektedir. Ancak, özgün FLICM ile standart FLICM arasındaki başarımların farkını gerçek verilerden elde edilen sonuçlardan yorumlamak mümkün görünmemektedir.

2.3. Doğrusal Olmayan Spektral Karışım Analizi

Doğrusal karışım modelinde makroskobik saf bileşenlerin piksel içinde ayrı parçalarda homojen olarak dağıldığı ve bolluk oranları ile saf bileşenlere ait alanların büyüklüğünün doğru orantılı olduğu varsayılmaktadır. Bu varsayım her zaman doğruluk taşımasa da, doğrusal karışım modeli, spektral karışım analizi literatüründe hala baskınlığını korumaktadır [49]. Bununla beraber, doğrusal olmayan karışım

analizi üzerine gerçekleştirilen çalışmaların sayısı her geçen gün artmaktadır. Doğrusal olmayan karışım modelinde saf bileşenlerin birbirleri ile iç içe dağılmış durumda olduğu ve/veya farklı bileşenler arasında çoklu saçılım olduğu kabul edilmektedir. Doğrusal olmayan karışım modelinin iki farklı oluşumu Şekil 2.25'te gösterilmiştir.



Şekil 2.25. Doğrusal olmayan spektral karışımlar

2.3.1. Doğrusal olmayan spektral karışım analizi literatür özeti

Doğrusal olmayan karışım modelinde birden çok materyalden dağılan ışınların fiziksel etkileşimini modelleyen bir yapı [50]'de geliştirilmiş olup, bu yapı sonsuz bir yansıma kuvvetleri serisi içermektedir. Ancak genel olarak, ilk birkaç terimi içeren bir yakınsama yeterli olmakta, bu tür bir yaklaşım ise bilinear model ile sonuçlanmaktadır. Doğrusal karışım modeline ek bir ikili etkileşim terimi eklenmesi ile elde edilen bilinear karışım modelleri birçok çalışmada kullanılmıştır [51-55]. Hapke'nin modelinde ise, ışınların fiziksel etkileşimi yansıma seviyesi yerine albedo (aklılık derecesi) seviyesinde modellenmiştir [56]. Bir karışımın albedosu farklı materyallerin albedosunun doğrusal bir ortalaması olup, yansıması ise albedonun doğrusal olmayan bir fonksiyonudur. Bu sayede farklı bir doğrusal olmayan model elde edilmiştir.

Ancak literatürdeki çoğu doğrusal olmayan karışım analizi yaklaşımları, karmaşık modelleri kullanmak yerine uygulaması daha kolay yöntemler kullanmaktadır. [57]

ve [58]'da doğrusal karışım analizinde kullanılan NCLS ve FCLS yöntemlerinin, [59]'da ise ayrıca en küçük kareler OSP (LSOSP) yönteminin, çekirdek versiyonları (KNCLS, KFCLS, KLSOSP) geliştirilmiştir. [60-62]'de farklı çekirdek yapıları ve yaklaşımları spektral karışım analizi için kullanılmıştır.

Karışım analizi işlemini otomatikleştirmek ve son elemanların bilinmediği durumlara karşı gürbüzlük sağlamak gibi amaçlarla yapay sinir ağları yaklaşımları da doğrusal olmayan karışım analizi için sık kullanım bulmaktadır [63-67]. Son eleman çıkartımı ve doğrusal olmayan karışım analizini eğitimsiz bir şekilde bir ara gerçekleştiren yaklaşımlar ise literatürde az sayıda olmakla beraber, bu alanda [68-69] dikkat çekmektedir.

2.3.2. Özgün çalışma: Çekirdek FLICM ile spektral karışım analizi

Bu tez çalışması kapsamında, doğrusal spektral karışım analizi için kullanılan, piksellerin komşuluğundaki piksellerin bolluk oranlarının etkisini karışım analizi hesabına dahil eden, FLICM ile spektral karışım analizi yaklaşımı, doğrusal olmayan spektral karışım analizi için özgün olarak çekirdek uzayında geliştirilmiştir. Bu amaçla öncelikle literatürde yer alan KNCLS ve KFCLS yöntemleri incelenerek açıklanacak, daha sonra bu tez kapsamında özgün olarak geliştirilen çekirdek FLICM (Kernel FLICM-KFLICM) yöntemi açıklanacak ve deneysel sonuçlar sunulacaktır.

2.3.2.1. KNCLS ve KFCLS

KRX bölümünde de bahsedildiği üzere, “çekirdek numarası” ile veriyi üst-seviye öznitelik uzayına taşıyacak fonksiyonu, bu fonksiyon bilinmeden, çekirdek fonksiyonların içsel çarpımı ile hesaplamak mümkün olmaktadır.

NCLS yöntemi için yinelemeli algoritma daha önceki bölümlerde paylaşılmış olup, bu algoritma,

$$\hat{\alpha}_{NCLS}(r) = (M^T M)^{-1} M^T r - (M^T M)^{-1} \lambda \quad (2.22)$$

$$\lambda = M^T r - M^T M \hat{\alpha}_{NCLS}(r) \quad (2.23)$$

ifadelerinin, bolluk kıstasları sağlanırken, yinelemeli olarak çözülmesi içindir: “Çekirdek numarası” kullanılarak, çekirdek uzayındaki KNCLS,

$$\hat{\alpha}_{KNCLS}(r) = (K(M, M))^{-1}K(Mr) - (K(M, M))^{-1}\lambda \quad (2.24)$$

$$\lambda = K(M, r) - K(M, M)\hat{\alpha}_{KNCLS}(r) \quad (2.25)$$

şeklinde elde edilmektedir.

KFCLS'yi elde etmek için ise NCLS ve FCLS arasındaki ilişki Denklem (2.24) ve (2.25)'de kullanılır;

$$\hat{\alpha}_{KFCLS}(r) = (K(N, N))^{-1}K(Ns) - (K(N, N))^{-1}\lambda \quad (2.26)$$

$$\lambda = K(N, s) - K(N, N)\hat{\alpha}_{KFCLS}(r) \quad (2.27)$$

KNCLS ve KFCLS yöntemleri ile spektral karışım analizi, NCLS ve FCLS yöntemlerine göre başarımları genel olarak yükseltmektedir. Spektral bantlar arasındaki doğrusal olmayan ilişkiler çekirdek uzayında daha verimli olarak kullanılmakta, bu sayede tespit edilen bolluk oranları daha doğru ve gürültüye karşı daha gürbüz olmaktadır.

Ancak [59] ve [70]'de HYDICE uydusundan alınan hiperspektral verilerde başarımın standart yöntemlere göre daha düşük elde edildiği gözlemlenmiştir. Bunun nedeni olarak çekirdek tabanlı yaklaşımların düşük uzamsal veya düşük spektral çözünürlük verilerde daha etkili olduğu, HYDICE gibi yüksek uzamsal ve yüksek spektral çözünürlük verilerde başarımları açısından yeterli kazanç sağlamadığı belirtilmiştir [59]. Ayrıca, çekirdek yaklaşımlarının verinin örnekleri yüksek oranda karışmışken standart yöntemlere göre daha iyi sonuç vereceği de belirtilmiştir [59].

2.3.2.2. KFLICM

Bu tez kapsamında geliştirilen çekirdek uzayında FLICM ile spektral karışım analizi ile bolluk oranları, KNCLS ve KFCLS'a benzer şekilde, Denklem (2.16) ve (2.20) kullanılarak ve özgün olarak,

$$\hat{\alpha}_i = (K(M, M))^{-1}K(M, x_i) - \gamma K(G_i^T) \quad (2.28)$$

şeklinde elde edilmektedir. Matris gösterimiyle ise bu ifade,

$$\hat{\alpha}_i = K_M^{-1} K_{xM} - \gamma K_G \quad (2.29)$$

şeklinde olmaktadır.

Bu tez kapsamında geliştirilen özgün KFLICM yönteminde, çekirdek yapısı olarak RBF çekirdek kullanılmış olup, bu çekirdek yapısı kullanıldığında Denklem (2.29)'daki terimler,

$$K_M(j, k) = \exp\left(-\frac{\sum_{b=1}^S (M(b, j) - M(b, k))^2}{\sigma^2}\right), \quad j, k = 1, \dots, m \quad (2.30)$$

$$K_{xM}(j) = \exp\left(-\frac{\sum_{b=1}^S (x_i(b) - M(b, j))^2}{\sigma^2}\right), \quad j = 1, \dots, m \quad (2.31)$$

$$K_G(i) = \sum_{\substack{j \in N_i \\ i \neq j}} \frac{1}{d_{ij} + 1} (1 - p_{kj})^m \frac{1}{3 - 2 \exp\left(-\frac{\sum_{b=1}^S (x_i(b) - E_b p)^2}{\sigma^2}\right)} \quad (2.32)$$

şeklinde ifade edilmektedir. Bu denklemlerde m son eleman sayısını, S ise verideki spektral bant sayısını betimlemektedir.

KFLICM ile spektral karışım analizi için Denklem (2.29) ve (2.32)'nin bir arada analitik olarak çözülmesi mümkün olmayıp, bu iki denklemin yinelemeli olarak çözülmesi gerekmektedir. Bu amaçla ilk aşamada bolluk oranları için başlangıç değerleri kullanılarak (2.32) ile K_G elde edilmekte, daha sonra elde edilen K_G (2.29)'da kullanılarak bolluk oranları güncellenmektedir. Güncellenen bolluk oranları (2.32)'de kullanılarak K_G 'nin yeni değeri tespit edilmekte ve bu işlem yinelemeli olarak, durma koşulu sağlanıncaya dek, devam etmektedir. Bolluk oranlarının başlangıç değerleri için bu tez kapsamında FCLS ile spektral karışım analizi ile elde edilen bolluk oranları kullanılmıştır.


Bu aşamada dikkat edilmesi gereken bir nokta, yinelemeler sırasında Denklem (2.29) doğrudan kullanıldığında bolluk oranlarının negatif olmama ve toplamalarının bire eşit olma kısıtlarının sağlanmamış olacak olmasıdır. Bu yüzden, Denklem (2.29) bu kısıtları da sağlayacak şekilde bir optimizasyon problemine dönüştürülmektedir ve bu özgün çalışmada da standart FLICM ile spektral karışım analizinde olduğu üzere,

bu amaçla ikinci dereceden programlama kullanılmaktadır. FLICM ile spektral karışım analizi yaklaşımı, komşu piksellerden gelen bilgileri de karışım analizi işlemine dahil ettiği için uzamsal işlemenin başarımlı artırıcı özelliklerinden faydalanmaktadır. KFLICM ile bu özelliklerin daha verimli olarak kullanılması ve karışım analizinin çekirdek uzayında daha başarılı ve gürbüz şekilde gerçekleştirilmesi amaçlanmıştır.


2.3.2.3. Deneysel sonuçlar

A. Sentetik veride deneysel sonuçlar

Yöntemin başarımlı test etmek için iki son elemanı saf olarak içeren 100 x 100 piksel uzamsal boyutlarında bir sentetik veri oluşturulmuştur. Daha sonra bu veri üzerinde uzamsal düzlemde 5 × 5 boyutlarında Gauss süzgeci gezdirilerek, karışım oluşturulmuş ve karışımli veriye farklı SNR oranlarında toplamsal beyaz Gauss gürültüsü uygulanmıştır. FLICM ve KFLICM için pencere boyutu 5 × 5, en büyük yineme sayısı 100, γ parametresi 0,1 olarak alınmış olup, KFLICM’de RBF çekirdek yapısı için $\sigma^2 = 100$ değeri kullanılmıştır. Şekil 2.26’da 30db SNR gürültülü veri için sentetik bolluk oranları, FCLS ile, FLICM ile ve KFLICM ile elde edilen bolluk oranları sunulmuştur. Şekil 2.27’de ise 10db SNR gürültülü veri için sonuçlar sunulmuştur.




Şekil 2.26. 30dB SNR için bolluk haritaları (a) Gerçek bolluk haritaları (b) FCLS ile (c) FLICM ile (d) KFLICM ile



Şekil 2.27. 10dB SNR için bolluk haritaları (a) Gerçek bolluk haritaları (b) FCLS ile (c) FLICM ile (d) KFLICM ile

Görsel sonuçlardan da gözlemlenebileceği üzere, KFLICM sonuçları gürültüye karşı FCLS ve FLICM yaklaşımlarına göre çok daha gürbüz çalışmaktadır. Bu gürbüzlük spektral karışım analizi işleminin çekirdek uzayına taşınması kaynaklıdır.

KFLICM için $\sigma^2 = 100$ parametresi deneme üzerine tespit edilmiştir. Bu sentetik veri için daha düşük σ^2 değerleri yüksek hatalara, daha yüksek σ^2 değerleri ise aşırı yumuşatmaya neden olmaktadır. 10dB SNR'da aynı veri için KFLICM $\sigma^2 = 10$ ve KFLICM $\sigma^2 = 1000$ sonuçları Şekil 2.28'de sunulmuştur.




Şekil 2.28. KFLICM ile 10dB SNR'da elde edilen bolluk oranları (a) $\sigma^2 = 10$ (b) $\sigma^2 = 1000$

Şekil 2.29 (a)'da 10 dB SNR için, (b)'de ise 30dB SNR için soldan sağa sırasıyla FCLS, FLICM ve KFLICM ile elde edilen bolluk oranları hataları gösterilmiştir. Geliştirilen özgün KFLICM ile spektral karışım analizi yöntemi ile verinin genelinde gürültüye karşı yüksek gürbüzlük elde edilmiş olmasına rağmen, KFLICM sonuçlarında geçiş bölgelerindeki hatanın daha fazla olabildiği gözlemlenmiştir. 10

dB SNR durumunda KFLICM ile kenar bölgelerindeki hatalar giderilebilecek olsa da iki gürültü oranında da KFLICM sonuçlarında geçiş bölgesindeki yüksek hata dikkat çekmektedir.

Geçiş bölgesindeki yüksek hatanın nedeninin çekirdek yapısının sebep olduğu yumuşak geçişlerin geçiş bölgelerindeki hızlı değişimi yeterince doğru şekilde ifade edememesi olduğu düşünülmektedir.



Şekil 2.29. Soldan sağa FLCS, FLICM ve KFLICM hata oranları (a) 10dB SNR (b) 30 dB SNR

Bu veri için elde edilen sayısal sonuçlar Tablo 2.8 ve Tablo 2.9’da sunulmuştur. Geliştirilen KFLICM yönteminin gürültüye karşı gürbüzlük taşıdığı görülmekle beraber, bu veri için yöntemin başarımı tatmin edici bulunmamıştır. KFLICM yöntemi sonucu geçiş bölgelerinde oluşan hataların giderilmesi halinde çok daha yüksek başarımlar elde edilebilecektir.

Tablo 2.8. Sentetik veri için $RMSE_{\text{bolluk}}$ sonuçları

Spektral Karışım Analizi Yöntemi	10dB SNR	30dB SNR	50dB SNR	70dB SNR
FCLS	0,0225	0,0023	2,49e-04	2,69e-05
FLICM	0,0225	0,0015	0,0012	0,0012
KFLICM	0,0143	0,0225	0,0226	0,0226

Tablo 2.9. Sentetik veri için $RMSE_{veri}$ sonuçları


Spektral Karışım Analizi Yöntemi	10dB SNR	30dB SNR	50dB SNR	70dB SNR
FCLS	0,2524	0,0252	0,0025	2,52e-04
FLICM	0,2524	0,0252	0,0026	5,19e-04
KFLICM	0,2526	0,0281	0,0082	0,0065

B. Gerçek veride deneysel sonuçlar

Bu deneyde AVIRIS Indian Pine verisi kullanılmış olup, veriden sekiz adet son eleman VCA yöntemiyle çıkartılmıştır. Daha sonra, bu son elemanlar üzerinden FCLS ile, FLICM ile ve KFLICM ile spektral karışım analizi gerçekleştirilmiştir.

FLICM ve KFLICM için pencere boyutu 5×5 , en büyük yineleme sayısı 100, γ parametresi 0,1 olarak alınmıştır. KFLICM’de RBF çekirdek yapısı için $\sigma^2 = 1$ değeri deneysel olarak belirlenerek kullanılmıştır. Elde edilen bolluk haritası sonuçları Şekil 2.30’da sunulmuştur.

KFLICM ve standart FLICM yöntemleri ile benzer sonuçlar elde edilmiş olup, KFLICM ile elde edilen sonuçlar FLICM ile elde edilen sonuçlara göre daha başarılı görünmekle beraber, başarımları nesnel bir şekilde değerlendirmek mümkün görünmemektedir.



Şekil 2.30. Indian Pine verisi için bolluk haritaları (a) FCLS ile (b) FLICM ile (c) KFLICM ile

2.3.2.4. Vargılar

Bu tez kapsamında, özgün olarak, spektral karışım analizi için KFLICM yaklaşımı geliştirilmiş olup, yaklaşım KNCLS ve KFCLS yöntemleri ile benzer şekilde, çekirdek kullanımı ile elde edilmektedir. Yöntem gürültüye karşı yüksek gürbüzlük sağlamaktadır. Ancak FLICM yaklaşımının hali hazırda uzamsal bilgiyi spektral karışım analizi sürecine dahil ediyor olması veya kullanılan verilerin çekirdek yapısının avantajları ortaya çıkarmayacak veriler olmaları gibi nedenlerden dolayı, geliştirilen KFLICM yaklaşımının FLICM ile spektral karışım analizi yaklaşımına göre başarımlarının sınırlı olduğu gözlemlenmektedir. İleride yapılabilecek çalışmalar arasında daha karışıklı veya gürültülü ve uzamsal veya spektral çözünürlüğü düşük veriler üzerinde KFLICM yaklaşımının başarımlarının ölçülmesi sayılabilir.

3. UZAMSAL BAĞIMLILIK ESASINA GÖRE ÇÖZÜNÜRLÜK ARTIRIMI


Spektral karışım analizi ile hiperspektral verideki pikseller son elemanların bolluk oranları cinsinden ifade edilebilmekte, böylece piksel-altı seviyesinde bilgi sağlamaktadır. Ancak, spektral karışım analizi, piksel içindeki uzamsal dağılım bilgisi sağlamamakta, dolayısıyla da uzamsal çözünürlüğü gerçek anlamda arttırmamaktadır. Bu durum, Bölüm 2’de paylaşılan “kuruyemiş tabağı” benzetmesi kullanılarak, son eleman çıkarımı ile tespit edilen kuruyemiş türlerinin spektral karışım analizi ile tabak içindeki oranlarının tespit edildiği, ancak bu kuruyemiş türlerinin tabak içindeki konum dağılımları hakkında bilgi edinilmediği şeklinde ifade edilebilir.

Uzamsal çözünürlüğün arttırılması için hiperspektral veri ile yüksek uzamsal çözünürlüklü bir görüntünün kaynaştırılması yaklaşımı ise hiperspektral görüntü ile aynı bölgeden aynı zamanda/koşullarda elde edilmiş yüksek uzamsal çözünürlüklü ayrı bir görüntü gereksiniminden dolayı sınırlı kullanıma sahiptir.

Bu durumdan yola çıkan ve tek görüntü üzerinden uzamsal çözünürlük artırımı gerçekleştiren bir yaklaşım [71]’de geliştirilmiştir. Bu tek imge üzerinden çözünürlük arttırma yaklaşımı literatürde süper-çözünürlük eşleme olarak anılmakta olmasına rağmen, bu ifade süper-çözünürlüğün genel olarak ifade ettiği şekilde düşük çözünürlüklü birden fazla görüntünün birleştirilmesi anlamında kullanılmamaktadır. Aksine kastedilen, piksel içinde, bolluk oranlarında bulunan son elemanların, uzamsal bağımlılık esasına dayanarak, nasıl bir dağılımda olmalarının daha olası olduğunun tespit edilmesidir. Literatürde bu yaklaşımı kullanan birden fazla yöntem geliştirilmiştir. [72]’de piksel altı per-field sınıflandırması, [73]’de doğrusal optimizasyon teknikleri, [74]’te Hopfield yapay sinir ağları, [75]’te iki noktalı histogram optimizasyonu, [76]’da genetik algoritma, [77]’de ileri-beslemeli yapay sinir ağları, daha yakın tarihli [78]’de ise Fletcher-Reeves geri-izdüşümlü yapay sinir ağları kullanılmıştır. Yakın bir zamanda, aynı amaçla, benzetimli tavlama kullanım bulmuş [79] ve sınıflandırma uygulaması için de [80] ve [81]’de kullanılmıştır.

Bu süper-çözünürlük eşleme veya uzamsal düzenleştirme yöntemleri ile elde edilebilecek detay ve başarımlar, bolluk oranları bilgisine ve karışım analizi başarısına bağlı ve uzamsal bağımlılık varsayımı ile sınırlı olsa da, literatürde bu yaklaşımı kullanan yöntemlerin her biri uzamsal çözünürlüğü ve dolayısıyla verideki detay ve sınıflandırma başarımlarını arttırmaktadır [82].

Uzamsal bağımlılık mantığı Şekil 3.1’de görselleştirilmiştir. Şekil 3.1’de bir veride bulunan iki son eleman için örnek bolluk oranları verilmiş ve bu bolluk oranlarına göre uzamsal çözünürlük 2×2 oranında arttırıldığında alt-piksel seviyesinde iki olası son eleman dağılımı verilmiştir.



Şekil 3.1. Uzamsal bağımlılık (a) Bolluk oranları (b) Olası bir piksel altı dağılımı (c) Uzamsal bağımlılık esasına göre en olası piksel altı dağılımı


Uzamsal bağımlılık esasına göre çözünürlük artırımı için, öncelikle verideki son elemanlar tespit edilmekte ve spektral karışım analizi ile her pikselin bolluk oranları çıkartılmaktadır. Bu aşamalardan sonra, uzamsal çözünürlük artırımı şu şekilde gerçekleştirilmektedir:

İlk adımda her piksel, istenen çözünürlük artırımına göre, sabit bir alt-piksel sayısına bölünmektedir. Pikselin içerdiği alt-pikseller, son elemanlara, bu son elemanların piksel içindeki bolluk oranlarıyla orantılı sayıda paylaştırılmaktadır. Bu aşamada, bir piksel, bir son eleman için, belirli bir eşik değerinin üstünde bolluk oranına sahip ise saf olarak kabul edilip tüm piksel o son elemana atanabilir. Başka bir yaklaşım ise saflık için bolluk oranları arasındaki farka bakmaktır. Bu yaklaşımda piksel için elde edilen en büyük bolluk oranı pikseldeki diğer tüm bolluk oranlarından yüksekse o piksel saf kabul edilmektedir. Saf olmayan pikseller için son elemanlara atanacak alt-piksel sayısı,

$$n_k = \text{round}(abund_k \times r^2) \quad (3.1)$$

şeklinde tespit edilebilir. Bu denklemde n_k k . son elemana atanan alt-piksel sayısı, $abund_k$ k . son elemanı pikseldeki bolluk oranı, r ise uzamsal çözünürlük artırım oranıdır. Örneğin her piksel 3×3 alt-piksele bölünecek ise $r = 3$ olmaktadır. Bu denklem [79] ve [80]'de r^2 yerine r olacak şekilde yanlış yazılmış olmasına rağmen, [81]'de düzeltilmiştir. *round* işlevi ise parantez içindeki sayıyı en yakın tamsayıya yuvarlanmaktadır.

Örneğin, 3×3 oranında büyütülecek bir veride, 0,45, 0,35 ve 0,2 bolluk oranlarına sahip bir karışıklı piksel için, alt-piksel etiketi sayıları, sırasıyla 4, 3 ve 2 olarak elde edilecektir. Ancak bu aşamada bu etiketlerin uzamsal uzayda ne şekilde dağıldıkları bilgisi elde edilmemektedir. Bu örnekteki piksel için 4 etikete sahip son eleman kırmızı, 3 etikete sahip son eleman yeşil ve 2 etikete sahip son eleman mavi renk ile temsil edildiğinde, iki olası etiket dağılımı Şekil 3.2'de sunulmuştur.



Şekil 3.2. Verilen örnek için alt-piksel seviyesinde iki olası etiket dağılımı

Dikkat edilmesi gereken bir nokta, yuvarlama işlemlerinden dolayı, Denklem (3.1) ile elde edilen n_k 'ların toplamının r^2 'ye eşit olmayabileceğidir. Başka bir deyişle, örneğin, 3×3 alt-piksel içeren bir piksel için son elemanlara atanan alt-piksel sayılarının toplamı 9'dan farklı olabilmektedir. [79-81]'de bu durumla alakalı bir bilgi verilmemiştir. Bu tez çalışması kapsamında, bu sorunu çözmek için, her piksele atanan alt-piksel etiketi sayısı kontrol edilmekte ve gerektiği şekilde en yüksek

sayıya sahip son elemana alt-piksel sayısı eklenmekte veya en düşük sayıda alt-piksele sahip son elemandan çıkarılmaktadır.

Piksellerin içerdikleri son elemanlar ve bu son elemanlara atanacak alt-piksel sayıları belirlendikten sonra, alt-piksel etiketlerinin konumları uzamsal bağımlılık esasına göre optimize edilmektedir. Uzamsal bağımlılık prensibine göre, pikselin içindeki bir son elemana ait her alt-pikselin komşu piksellerdeki aynı son elemana ait alt-piksellere uzamsal olarak yakın bulunması gerekmektedir. Bu yüzden, bu tez kapsamında, maliyet fonksiyonu olarak tüm görüntüde son elemanlara ait olan alanların çevrelerinin toplamı en küçüklenmek istenmiştir. Bu sayede, aynı son eleman etiketine atanan alt-piksellerin veride mümkün olduğunca bütün oluşturması ve daha pürüzsüz bir dağılımda olması sağlanmaktadır. Maliyet fonksiyonu,

$$C = \sum_{i=1}^q \sum_{j=1}^{N_i} \zeta_{ij} \quad (3.2)$$

şeklinde ifade edilebilir. Bu denklemde q son eleman sayısı, N_i görüntüde bu son elemana ait bağlantılı bileşken sayısı, ζ_{ij} ise bağlantılı bileşkenden 8-komşuluk esasına göre elde edilen çevre değeridir.

3.1. Benzetimli Tavlama ile Uzamsal Bağımlılık Esasına Göre Çözünürlük Artırımı

Bu tez çalışmasında hiperspektral verilerin uzamsal çözünürlüklerini artırmak amacıyla uzamsal bağımlılık esasına dayalı özgün bir yaklaşım geliştirilmiş olup, geliştirilen özgün yöntemi karşılaştırma amacıyla en güncel uzamsal düzenleme yaklaşımı olan benzetimli tavlama ile uzamsal çözünürlük artırımı yaklaşımı detaylı şekilde incelenmiş ve gerçekleştirilmiştir.

3.1.1. Yöntemin açıklaması

Benzetimli tavlama, metalürjideki tavlama işleminden esinlenmiş olan, kristalleşme işlemini modelleyen olasılıksal bir yöntemdir [83]. Metalürji veya termodinamikteki tavlama işleminde kristallerin boyutunu arttırmak ve bozukluklarını azaltmak için materyal ısıtılmakta ve kontrollü olarak soğutulmaktadır. Isınma ile atomlar


konumlarından kurtulmakta, kontrollü soğutulma ile ise daha az enerjili konumlar bulma ihtimali oluşmaktadır. Bu şekilde en az enerji durumunu bulmak hedeflenmektedir. Benzetimli tavlama, optimizasyon problemlerini çözmek için [84]'te önerilmiştir. Yöntemin temel mantığı, maliyet fonksiyonunda yerel en küçük noktalara takılmanın engellenmesi için yokuş yukarı çıkışlara izin verilmesi, başka bir deyişle, daha düşük maliyetli bir çözüm olmadığında daha yüksek maliyet veren çözümlerin bazı durumlarda kabul edilebilmesidir. Daha kötü çözümlerin kabul edilme olasılığı maliyet fonksiyonu değerinin kötüleşmesi ile ters orantılı olup, ayrıca bir eşik değerine bağlıdır. Bu eşik değeri, sıcaklık olarak adlandırılmakta olup, yinelemeli olarak azalmakta, dolayısıyla daha kötü çözümlerin kabul edilme olasılığı yineleme sayısı arttıkça azalmaktadır. Bunun nedeni işlevin işlem devam ettikçe bir süre sonra global çözüme yakınsadığı varsayımdır.

Son eleman çıkarımı, spektral karışım analizi ve alt-piksel etiket sayıları dağılımları belirlendikten sonra, benzetimli tavlama ile uzamsal çözünürlük artırımı şu şekilde çalışmaktadır: Karışıklı bir pikselde iki farklı etikete sahip iki alt-piksel yer değiştirilmekte ve maliyet fonksiyonunun aldığı değer hesaplanmaktadır. Yer değiştirilen iki alt-piksel ile maliyet değeri azalıyorsa bu yer değişikliği kabul edilmektedir. Eğer maliyet değeri azalmıyorsa, maliyetteki kötüleşme ve yineleme sayısına bağlı bir olasılıksal eşığe göre değişimin kabul edilme ihtimali vardır. Bu işlem her karışıklı piksel için tekrarlanır. Verideki her karışıklı piksel için bu işlem gerçekleştirildikten sonra, yöntem durma koşulu sağlanana kadar özyinelemeli olarak devam eder.

3.1.2. Deneysel sonuçlar

Bu bölümde bu tez çalışmasında gerçekleştirilen benzetimli tavlama ile uzamsal çözünürlük artırımının çalışmasını denetlemek amacıyla yapılan deneyler paylaşılacaktır. Gerçekleştirilen üç deneyden ilk ikisi literatürde yer alan deneylerle paralellik taşımakta olup, üçüncü deney ise uydu görüntüsünden alınmış gürültülü bir hiperspektral veride başarımlı ölçmek içindir. Deneylerde sıcaklık değişim katsayısı değişkeni 0,8 alınmış olup, algoritma etiket değişimleri için ardı ardına 10000 ret sonucu aldığına sona ermektedir.

Sentetik veriler için deneysel süreç Şekil 3.3’de gösterilmiştir. Şekil 3.3’de görülen uzamsal çözünürlük azaltımı adımı, verinin uzamsal düzleminde gezdirilen ortalama süzgeci ile gerçekleştirilmektedir. Bu adım çözünürlük artırma yaklaşımının bir parçası olmayıp, deneysel çalışmalarda başarımlı ölçümü için gerekli olmaktadır. Uzamsal çözünürlük artırımı için ise, benzetimli tavlama veya sonraki bölümde önerilen özgün yöntem ile uzamsal bağımlılık esasına göre çözünürlük artırımı yaklaşımı kullanılmaktadır. Benzetimli tavlama ile uzamsal çözünürlük artırımı ve sonraki bölümde paylaşılacak özgün uzamsal çözünürlük artırımı yöntemi düşük uzamsal çözünürlüklü veriden yüksek uzamsal çözünürlük veri elde etmek için kullanılmaktadır.



Şekil 3.3. Uzamsal çözünürlük artırımı deneylerinde kullanılacak yaklaşım


3.1.2.1. Sentetik veride deneysel sonuçlar

Bu deneysel çalışmada hiperspektral görüntü işleme alanında literatürde sıkça kullanım bulan AVIRIS Indian Pine verisi yer doğrusuna USGS spektral kütüphanesinden elde edilen 6 adet spektral imzanın enjekte edilmesi ile elde edilen veri kullanılmıştır. Kullanılan spektral imzalar Şekil 3.4’te sunulmuştur.


Gerçekleştirilen deneyin aşamaları şu şekildedir:

1) Indian Pine verisi yer doğrusunda en fazla noktaya sahip 6 sınıf alınarak diğer sınıflar atılmıştır. Bu konumlara USGS kütüphanesinden alınan 6 adet imza uygulanmıştır. Oluşan yer doğrusu haritası Şekil 3.5 (a)'da sunulmuştur.

2) Oluşturulan sentetik veri 3×3 oranında uzamsal olarak küçültülmüştür. Oluşan yer doğrusu haritası Şekil 3.5 (b)'de sunulmuştur.



Şekil 3.4. Sentetik son eleman imzaları




Şekil 3.5. (a) Yer doğrusu verisi (b) 3×3 oranında küçültülmüş yer doğrusu verisi

3) FCLS yöntemiyle spektral karışım analizi yapılmaktadır. Başarımın son eleman çıkarımı yönteminden etkilenmemesi için spektral karışım analizinde gerçek son elemanlar kullanılmıştır.

4) Pikseller 3×3 alt-piksel kümelerine, bolluk oranlarına göre konumsal olarak rastgele olarak atanmıştır. Bu rastgele dağılım sonucu Şekil 3.6 (a)'da görülmektedir.


5) Benzetimli tavlama ile süper-çözünürlük yaklaşımı kullanılarak en olası uzamsal dağılımın bulunması amaçlanmıştır. Bu dağılım sonucu Şekil 3.6 (b)'de görülmektedir. Benzetimli tavlama sonrası elde edilen alt-piksel seviyesinde son eleman dağılımın, rastgele dağılıma göre, çok daha mantıklı ve olası olduğu gerek sezgisel olarak, gerekse yer doğrusu haritası ile karşılaştırılarak anlaşılmaktadır.



Şekil 3.6. Sentetik veri için (a) benzetimli tavlama öncesi dağılım (b) benzetimli tavlama sonrası dağılım


3.1.2.2. Gerçek veride deneysel sonuçlar

Bu deneysel çalışmada 145×145 uzamsal boyutlardaki AVIRIS Indian Pine verisi, ortalama alımı ile 2 kat küçültülerek 73×73 uzamsal boyutlarda yeni bir hiperspektral veri elde edilmiştir. Yer doğrusu haritası ve alt-örneklenmiş veri yer doğrusu haritası Şekil 3.7'de verilmiştir.




Şekil 3.7. AVIRIS Indian Pine verisi (a) yer doğrusu (b) alt-örneklenmiş yer doğrusu

1) Bu veri üzerinden olasılıksal destek vektör makineleri (ODVM) (probabilistic support vector machines-PSVM) ile sınıflandırma gerçekleştirilmiştir. Sınıflandırıcı, düşük uzamsal boyuttaki verideki, yer doğrusu bulunan veri noktalarından %15 oranında veri kullanılarak eğitilmiş ve diğer yer doğrusu bulunan veri noktaları test kümesi olarak alınarak sınıflandırıcıya sokulmuştur. Sınıflandırma haritaları Şekil 3.8’de verilmiştir.




Şekil 3.8. Sınıflandırma haritası (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için

- 2) Belirli bir eşik değerinden yüksek olasılıkla sınıflara atanan pikseller bir sonraki adım için saf olarak kabul edilmiş ve eğitim kümesine katılmıştır.
- 3) Sınıflandırma sonrası adımda eğitim kümesinde olmayan her piksel için, eğitim kümesinde piksele en yakın konumda bulunan 10 pikselin imzası son eleman imzaları olarak kabul edilerek spektral karışım analizi yapılmıştır.
- 4) Pikseller 2×2 alt-piksel kümelerine, son elemanlara ait elde edilen bolluk oranlarına göre konumsal olarak rastgele olarak atanmıştır. Sonuçlar Şekil 3.9’da paylaşılmıştır.
- 5) Benzetimli tavlama ile alt-piksel uzayında sınıf etiketleri için en olası uzamsal dağılım bulunmak hedeflenmektedir. Elde edilen sonuçlar Şekil 3.10’da sunulmuştur.



Şekil 3.9. Bolluk oranları ile orantılı olarak uzamsal olarak rastgele dağıtılmış alt-pikseller (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için




Şekil 3.10. FCLS ve benzetimli tavlama sonucunda elde edilen alt-piksel dağılımı (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için

Tablo 3.1’de rastgele seçilmiş bir eğitim verisi kümesi için başlangıçtaki sınıflandırma başarımı ve FCLS ve benzetimli tavlama sonucunda elde edilen sınıflandırma başarımı verilmiştir. Tablo 3.1’den de görülebileceği üzere uzamsal çözünürlüğün 2 kat arttırılmasına rağmen, sınıflandırma başarımı azalmamış, aksine arttırılmıştır.

Tablo 3.1. Sınıflandırma başarımları

Spektral Karışım Analizi	Alt-örnekleşmiş veride	Alt-piksellerin uzamsal olarak rastgele dağıtıldığı veride	Benzetimli tavlama sonrası çözünürlüğü arttırılmış veride
FCLS ile	% 80,5132	% 92,0316	% 93,2857
FLICM ile	-	% 92,8806	% 93,6041

6) Ek bir yaklaşım olarak, FCLS ile bolluk oranları elde edildikten sonra bu oranları ön tahmin olarak FLICM ile spektral karışım analizi gerçekleştirilmiş ve benzetimli tavlama ile uzamsal çözünürlük artırımı FLICM ile elde edilen bolluk oranları için uygulanmıştır. FLICM ile benzetimli tavlama ilk kez bu tez kapsamında bir arada kullanılmış olup, görsel sonuçlar Şekil 3.11’de, sayısal sonuçlar ise Tablo 3.1’de sunulmuştur. FLICM’in uzamsal bilgiyi kullanması sonucu hataların noktasal yerine daha toplu yapıda olduğu ve sınıflandırma başarımının arttığı gözlemlenmiştir.




Şekil 3.11. FLICM ve benzetimli tavlama sonucunda elde edilen alt-piksel dağılımı (a) tüm pikseller için (b) sadece yer doğrusu verisi bulunan pikseller için

3.1.2.3. Hyperion verisinde deneysel sonuçlar


2.1.2.4. bölümünde gerçekleştirilen testin devamı olarak, son elemanlara göre bolluk oranları elde edilen Hyperion piksel vektörleri, alt-piksel boyutunda son elemanlara bolluk oranlarına göre ve uzamsal olarak rastgele, dağıtılmışlardır. Bu sayede verinin 30m uzamsal çözünürlükten 6m uzamsal çözünürlüğe çıkılması, yani orijinal verideki her pikselin artık 5×5 piksellik bir alan ile ifade edilmesi sağlanmıştır.

SPEE son eleman çıkartımı ile elde edilen 11 son eleman ve FCLS ile gerçekleştirilen spektral karışım analizi sonrası alt-piksel seviyesinde elde edilen rastgele dağılım Şekil 3.12’de gösterilmektedir.

Deneysel sonuçların daha net gözlemlenebilmesi için bu verinin sol üst köşesinden bir kesit için alınarak kullanılmıştır. Uzamsal olarak rastgele dağılım Şekil 3.13 (a)’da gösterilmiştir.



Şekil 3.12. Hyperion verisi için alt-pikselde son eleman dağılımı



Şekil 3.13. Hyperion verisi parçası için alt-piksel seviyesinde uzamsal olarak rastgele dağılım ve benzetimli tavlama sonrası dağılım

Veride yüksek karışıklık dolayısıyla, bu örnek için benzetimli tavlama her çalışmada aynı sonuca yakınsamamakta ve farklı sonuçlar verebilmektedir. Benzetimli tavlama sonrası elde edilmiş örnek bir dağılım Şekil 3.13 (b)'de gösterilmektedir. Şekil 3.13 (a)'daki rastgele dağılım teorik olarak mümkün olmakla birlikte, Şekil 3.13 (b)'deki dağılım uzamsal bağımlılık ilkesi açısından çok daha olasıdır.

3.2. Özgün Çalışma: Parçacık Sürü Optimizasyonu ile Uzamsal Bağımlılık Esasına Göre Çözünürlük Artırımı

Bu tez kapsamında özgün olarak, parçacık sürü optimizasyonu (PSO) [85] tabanlı bir uzamsal bağımlılık esasına dayanan çözünürlük artırımı yaklaşımı geliştirilmiştir. PSO literatürde hiperspektral görüntüler için son eleman çıkarımında [86] ve karışım giderilmesinde [87] kullanılmış olmasına rağmen bu tez kapsamında kullanıldığı şekilde kullanılmamıştır. Geliştirilen yöntem literatürdeki benzerlerine göre paralelleştirilmeye çok daha yatkın bir yöntemdir. Ayrıca, bit-temelli işlemler kullanıldığı için programlanabilir alan kapı dizilerine (Field Programmable Gate Array-FPGA) kolay uyumlandırılma potansiyeline sahiptir.

Bu bölümde, geliştirilen özgün yöntem paylaşılacak ve deneysel sonuçlar ile yöntemin başarımı benzetimli tavlama yaklaşımı ile karşılaştırılacaktır.

3.2.1. Parçacık sürü optimizasyonu

PSO balık ve kuş sürülerinden esinlenerek geliştirilmiş, evrim tabanlı, rastgeleliğe dayalı bir optimizasyon algoritmasıdır. Sürüdeki parçacıklar problem uzayındaki bir sonraki konumlarını, mevcut hız vektörü, parçacığın tecrübesi ve sürünün genel gidişatına göre ayarlar. PSO'nun başarımının yüksek olması, gerçekleştirilebilirliğinin fazla olması ve daha az parametre kontrolü gerektirmesi nedeniyle, genetik algoritmanın kullanıldığı birçok problemin çözümünde artık PSO kullanılmaktadır [88]. Parçacık sürü optimizasyonu algoritması şu şekilde özetlenebilir:

- 1) Çözüm kümesi üzerinde rastgele dağılımlı bir parçacık popülasyonu yaratılır.
- 2) Parçacıkların konumları optimize edilmesi istenen nesnel fonksiyona göre değerlendirilir.
- 3) Değerlendirilen nesnel fonksiyona göre her parçacığın o zamana kadar olan en iyi konumu p_i ve tüm parçacıklar için en iyi konum p_g güncellenir.
- 4) Parçacıkların hızları kişisel en iyi konum ve en iyi parçacığın konumuna bağlı olarak güncellenir;

$$v_i(t+1) = w \times v_i(t) + c_1 \times \varphi_1 \times (p_i - x_i(t)) + c_2 \times \varphi_2 \times (p_g - x_i(t)) \quad (3.3)$$

Bu denklemde c_1 ve c_2 öğrenme faktörü ismi verilen pozitif sabitler, φ_1 ve φ_2 0-1 aralığında üniform dağılımdan alınmış rastgele sayılar, w ise önceki hız vektörünün yeni hız vektörüne etkisini kontrol eden atalet katsayısıdır.

5) Parçacıklar yeni konumlarına hareket ettirilir;

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3.4)$$

6) Durma koşulu kontrol edilir. Koşul sağlanmıyorsa ikinci adıma dönülür.

PSO ile uzamsal bağımlılık esasına göre uzamsal çözünürlük artırımı için özgün olarak geliştirilen yaklaşımımızda ilk olarak parçacıkların piksel içindeki son eleman etiketlerini ifade etmesi düşünülmüştür. Ancak standart PSO bu probleme doğrudan uygulanmaya uygun değildir. Bu durumun nedenleri arasında parçacıkların konumlarının ve konum değiştirme hız vektörlerinin tamsayı olma zorunluluğu, bir alt-piksel konumunda birden fazla parçacığın yer alamaması, bir parçacık yer değiştirdiğinde eski konumunun etiketsiz kalması ve yeni konumundaki parçacığın hareket etmesi zorunluluğu (bir alt-pikselde birden fazla etiket olamadığından dolayı) gibi nedenler sayılabilir.

3.2.2. İkili parçacık sürü optimizasyonu

[89]'da ikili PSO (Binary PSO-BPSO) önerilmiştir. BPSO'da parçacıkların konumları ikili değerlerin bir vektörü olarak tanımlanmıştır. Bu tanım kapsamında BPSO'da hız vektörü standart PSO ile aynı şekilde güncelleniyor olsa da, standart PSO'nun aksine, hız vektörü parçacıkların konumlarının güncellenmesinde doğrudan kullanılmamaktadır. Bunun yerine bir sigmoid işlevi ile rastgelelik aşağıdaki şekilde kullanılarak parçacığın durumunu 0'dan 1'e dönüştürme olasılığı cinsinden ifade edilmektedir;

$$\bar{s} = \frac{1}{(1 + e^{-v})} \quad (3.5)$$

$$\text{Eğer } r < \bar{s}_d, \quad x_{id} = 1, \quad (3.6a)$$

$$\text{aksi halde } , \quad x_{id} = 0 \quad (3.6b)$$


Bu denklemde x_{id} i parçacığının d numaralı bitini, r ise rastgele olarak bir-biçimsel dağılımdan seçilmiş, 0 ile 1 arasındaki bir sayıyı betimlemektedir. s değişkenin 0 ya da 1'e çok yaklaşmaması için hız değişkeni ± 4 ile sınırlandırılmaktadır.

BPSO hiperspektral görüntü işleme literatüründe özellikle bant seçimi konusunda kullanım bulmuş olup, bant sayısı boyutundaki bir vektörde 1 değerleri seçilecek bantları betimlemektedir.

BPSO yöntemi ayırık problemlerde standart PSO'ya göre başarımını kanıtlamış olmakla birlikte, standart PSO ile arasında önemli farklar bulunmaktadır. Bu önemli farklardan biri sigmoid fonksiyonu ile ilgilidir. Bu sigmoid fonksiyonu problemi doğrusal olmayan probleme dönüştürmektedir [90]. Ayrıca standart PSO'da hız limitinin arttırılması iyi bir konum bulunmuşsa bile farklı konumlar aramayı özendirirken, BPSO'da bu durum tam tersi şeklinde olmakta ve yüksek hız limitleri aramayı kısıtlamaktadır [91]. Başka bir çekince ise BPSO'da bir bitin bir sonraki değerinin önceki değeri ile bağıntısı olmamasıdır [91].

Bu sebeplerden dolayı literatürde farklı BPSO yaklaşımları geliştirilmiştir [90-93]. [91]'de hız vektörü tanımı değiştirilerek bir bitin değerinin tersine dönüşmesi (eski değer 0 ise 1, eski değer 1 ise 0) olasılığı olarak tanımlanmıştır. [92]'de BPSO ile benzetimli tavlama ve genetik algoritmanın birleştirilmesi üzerinde durulmuştur. [93]'te ise parçacığın bileşenin 0 veya 1 değeri alma olasılığı bileşenin mevcut değeri, parçacığın o ana kadarki en iyi konumunda bileşenin değeri ve tüm sürünün en iyi konumunda bileşenin aldığı değer ile doğru orantılı, parçacığın eski konumlarında bileşenin aldığı değerler ile ters orantılıdır. Hangi yaklaşımın daha başarılı olduğunun belirlenmesi bu tezin kapsamında değildir. Kullanılacak BPSO yaklaşımı [90]'da önerilen yaklaşım olup, bu yaklaşımın detayları ve neden tercih edildiği açıklanacaktır.

[90]'da önerilen BPSO yaklaşımı Şekil 3.14 ile özetlenebilir.



Şekil 3.14. BPSO süreci

Öncelikle, her parçacık için, parçacığın konumu ve o ana kadarki en iyi konumu arasında bir “dışlamalı veya” bit operatörü kullanılmakta, böylece farklı olan bitler tespit edilmektedir. Elde edilen vektör fark vektörü ile rastgele bir ikili vektör arasında “ve” operatörü kullanılarak değişim vektörü elde edilir. Bu “ve” operatörü ile sadece fark vektöründe değeri 1 olan bitlerin değişim vektöründe 1 değerini alabileceği garanti edilmiş olur ve işleme bu bitlerden hangilerinin 1 değerini alacağını seçecek bir rastgelelik katılmış olur. Bu adımlara paralel olarak, parçacığın konumu ve tüm sürü içinde en iyi parçacık konumu arasında da fark vektörü ve bir rastgele vektör sayesinde değişim vektörü tespit edilir. Bu iki değişim vektörünün “veya” operatörüne verilmesi ile son değişim vektörü bu iki birleşimden elde edilmiş olur. Elde edilen değişim vektörü ile parçacığın mevcut konumu arasında “dışlayan veya” operatörü kullanılarak, mevcut parçacık konumunda, değişim vektöründe 1 değerini alan bit konumlarının değiştirilmesi sağlanır. Bu işlemler;

$$d_{1,n}(t) = p_{en_iyi,n} \oplus X_n(t) \quad (3.7)$$

$$d_{2,n}(t) = g_{en_iyi,n} \oplus X_n(t) \quad (3.8)$$

$$V_n(t+1) = \bar{r}_1 \otimes d_{1,n}(t) + \bar{r}_2 \otimes d_{2,n}(t) \quad (3.9)$$

$$X_n(t+1) = X_n(t) \oplus V_n(t+1) \quad (3.10)$$

ile ifade edilebilir. Bu denklemlerde t yineleme sayısı, $\bar{r}$ rastgele ikili vektörü, X_n n . parçacığı, p_{en_iyi} ve g_{en_iyi} ise sırasıyla parçacığın ve tüm sürünün en iyi konumlarını göstermektedir.

Bu yaklaşım standart BPSO için belirtilen çekincelerden arınmış bir yaklaşım olup, tamamen ikili sistemde vektörler ve bit tabanlı işlemlere dayanmaktadır. Yöntem bu yüzden paralel işlemeye ve mantık işlemleri ile FPGA mimarisinde kullanıma uygundur.

3.2.3. Özgün yöntemin açıklaması

Geliştirilen özgün yaklaşım ile uzamsal bağımlılık esasına göre çözünürlük artırımı yapılmadan önce veriden son elemanların çıkartılması ve bolluk oranlarının tespit edilmesi gerekmektedir. Bu çalışma kapsamında bu amaçla, sırasıyla HFC, VCA ve FCLS yöntemleri kullanılmıştır.

Her piksel için en yüksek bolluk oranı bir eşik değerinden geçirilerek, hangi piksellerin saf olarak kabul edilebileceği tespit edilmektedir. Geriye kalan karışıklı pikseller için, istenen çözünürlük artırımı oranına göre, alt-pikseller Denklem (3.1) ile son elemanlara bölüştürülmektedir. Eğer gerekirse, son elemanlara atanan alt-piksel sayılarının toplamının toplam alt-piksel sayısına eşit olması ekleme ve silme işlemleriyle garanti edilir.

Bu adımdan sonra, değiştirilmiş BPSO ile uzamsal çözünürlük artırımı gerçekleştirilmiştir. Her karışıklı piksel için, belirli bir sayıda parçacık atanmaktadır. Bu parçacıkların her biri bir bit dizisi olup, her parçacık 0 ve 1 değerleri içeren $m - 1$ satır ve r^2 sütundan oluşmaktadır. Burada m karışıklı pikselin alt-piksellerinin atandığı son eleman sayısı, r ise çözünürlük artırımı oranıdır. Bu 1 ve 0 değerleri alt-pikselin son elemana atanıp atanmadığını belirlemektedir. Başka bir deyişle, parçacığın her satırı pikselin içerdiği elemanları, her sütunu ise o piksel için bir alt-piksel konumunu betimlemektedir.

Örneğin, 3×3 oranında büyütülecek bir veride, 0,45, 0,35 ve 0,2 bolluk oranlarına sahip bir karışıklı piksel için, alt-piksel etiketi sayıları, sırasıyla 4, 3 ve 2 olarak elde edilecektir. Bu piksel için iki olası parçacık Şekil 3.15'te gösterilmiştir. İlk satır en

yüksek bolluk oranına, dolayısıyla en çok alt-piksel etiketine, sahip olan son elemanı, ikinci satır ikinci en yüksek bolluk oranına sahip olan son elemanı betimlemekte olup, en düşük bolluk oranına sahip olan son elemana ait alt-piksel etiketleri ise iki satır için de 0 değerini taşıyan sütunlardır. Bu iki parçacığa ait alt-piksel etiket dağılımları Şekil 3.16'da gösterilmiştir.

1	1	0	1	1	0	0	0	0
0	0	1	0	0	1	1	0	0


(a)

0	1	0	0	0	1	1	1	0
0	0	1	1	1	0	0	0	0

(b)

Şekil 3.15. Örnek parçacıklar

Bu aşamada gerekli bir kıstas, her satırdaki değeri 1 olan bit sayısının tam olarak n_k , ya da bu örnek için birinci satır için 4 ve ikinci satır için 3, olmasıdır. Ancak standart BPSO'da olduğu gibi bir önceki bölümde aktarılan geliştirilmiş BPSO'da parçacıkların içinde değeri 1 olan bit sayısı sabit değildir ve değişmeye yatkındır. Bu yüzden, bu özgün çalışmada, parçacıkların konumları güncellendikten sonra her satırdaki değeri 1 olan bit sayısı kontrol edilmekte ve sayı doğru olacak şekilde konum olarak rastgele 0'dan 1'e veya 1'den 0'a dönüştürme işlemi yapılmaktadır.



Şekil 3.16. Şekil 3.15'teki örnek parçacıklar için alt-piksel etiket dağılımları

Diğer bir kıstas ise her alt-piksel konumunun bir ve yalnız bir etiket içermesi, dolayısıyla parçacıkların her sütununda sadece bir adet 1 biti bulunması kıstasıdır. Parçacıkların güncellenmesi sonucunda sütunlarda çakışan 1-bitleri oluştuğunda, bu kıstas daha düşük bolluk oranına sahip son elemana ait çakışan 1 bitini boş sütuna taşıyarak sağlanmaktadır. Çakışan 1-bitleri durumunda boş sütunun oluşması ise diğer kıstasın önce sağlanmasından dolayıdır.

Maliyet fonksiyonu benzetimli tavlama bölümünde paylaşılan çevre hesabı olarak alınmıştır. Her karışımli piksele atanan parçacık kümesi bağımsız olarak değerlendirilmekte, dolayısıyla her karışımli piksel için ayrı bir global en iyi parçacık konumu tespit edilmektedir. Karışımli pikseldeki her parçacık için maliyet fonksiyonu hesaplanırken diğer karışımli pikseller ilgili piksellere ait global en iyi parçacık konumları ile ifade edilirler. İşlem bir sonraki karışımli pikselle devam ederken bir önceki piksel güncellenen global en iyi parçacık konumu ile ifade edilmektedir.


İşlem yükünün çoğunluğu karışımli piksellerdeki parçacıkların maliyet hesabında olup, bu işlem yüksek oranda paralellik içermektedir. Kullanılan BPSO yaklaşımının da ikili dizilerden ve bit operatörlerinden oluştuğu göz önüne alındığında, geliştirilen özgün yaklaşım paralel işlemeye yüksek oranda yatkındır.

3.2.4. Deneysel sonuçlar

Geliştirilen özgün yaklaşımının başarımı üç farklı deneyde test edilmiş ve benzetimli tavlama yaklaşımı ile karşılaştırılmıştır.

3.2.4.1. Sentetik veride deneysel sonuçlar

Bu deneyde, geliştirilen yaklaşımın başarımını ölçmek için, alt-piksel seviyesinde önceden tamamen bilgi sahibi olunan bir sentetik veri kullanılmıştır. USGS spektral kütüphanesinden alınan üç spektral imza ve bu imzalar ile oluşturan sentetik verinin yer doğrusu Şekil 3.17’de sunulmuştur.




Şekil 3.17. (a) Sentetik yer doğrusu (b) Son eleman imzaları

Oluşturulan veri daha sonra 3×3 oranında alt-örneklemekte, böylece 3×3 boyutunda pencerelerdeki pikseller ortalama değerleri ile değiştirilmektedir. Oluşan düşük uzamsal çözünürlüklü ve karışıklı pikseller içeren veri yönteme girdi olarak verilmektedir. Geliştirilen özgün yöntemde her karışıklı piksel için 50 parçacık kullanılmıştır. Karşılaştırma için benzetimli tavlama yaklaşımı kullanılmış olup, yöntemlerin beş koşusu için elde edilen ortalama ardışık işlem süreleri ve yineleme sayıları Tablo 3.2’de verilmiştir.

Tablo 3.2. Sentetik veri için ortalama hesaplar, 3×3

	Ardışık Süre	Yineleme Sayısı
Benzetimli Tavlama	160s	4512
Özgün Yaklaşım	530s	7

Yöntemlerin bir koşusu için elde edilen sonuçlar ve yineleme sayısına göre maliyet değerleri grafikleri Şekil 3.18’de paylaşılmıştır.



Şekil 3.18. Sentetik veri için 3×3 alt-örneklemede sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği

İki yöntemin bu veri için benzer ve rastgele dağılımdan çok daha iyi görsel sonuçlar verdiği görülmektedir. Geliştirilen özgün yaklaşım benzetimi tavlama yaklaşımına göre daha yüksek ardışık işlem yüküne sahip olsa da, sonuca çok daha az yineleme sayısında ulaşmaktadır.

Geliştirilen yaklaşım aynı zamanda her karışımli pikselde yürütülen hesaplamalar için yüksek oranda paralelleştirilebilir. Bunun nedeni karışımli pikselin içindeki her parçacığın, önceki yinelemenin global en iyi konumu dikkate almaları dışında, bağımsız olarak çalışmaktadır. Benzetimli tavlama yaklaşımında ise her karışımli piksel için basit ve hızlı bir yer değiştirme yapılmakla birlikte, global çözüme yakınsamak için oldukça yüksek bir sayıda yineleme gerekmektedir. Bu gerçekler dikkate alındığında, önerilen yöntemde paralel işleme ile daha düşük bir işleme zamanı elde edilebileceği görülmektedir. Paralel işleme için optimize edilmiş bir mimari olmadan bile, karışımli pikseller içindeki parçacıkların maliyet hesapları, konum güncellenmesi ve parçacıklar için kişisel ve global en iyi konumların tespiti işlemleri paralelleştirildiğinde bu örnek için ortalama işlem yükü 530 saniyeden 13 saniye civarına inmesi beklenmektedir. Bu sürenin hesabında paralel gerçekleştirilebilecek işlemlerin toplam süresi parçacık sayısına bölünmüş ve sıradüzensel ve paralel işleme arasında değişken ve parametre aktarımı için gerekecek süre için eğitilmiş bir tahmin yapılmıştır. Dolayısıyla, bu süre azaltımı miktarı, paralelleştirme için mimari tabanlı detaylı bir inceleme yapılmadan garanti olmamakta, ancak olası iyileştirme açısından eğitilmiş bir tahmin sunmaktadır.


5×5 alt-örnekleme kullanıldığında ise, özgün yöntem hem 50 hem de 150 parçacık için çalıştırılmıştır. Yöntemleri 5 kere çalışmasından elde edilen ortalama yineleme sayıları ve ardışık işleme süreleri Tablo 3.3’de verilmiştir.

Tablo 3.3. Sentetik veri için ortalama hesaplar, 5×5


	Ardışık Süre	Yineleme Sayısı
Benzetimli Tavlama	270s	14480
Özgün Yaklaşım (50 parçacık)	930s	20
Özgün Yaklaşım (150 parçacık)	1950s	14

Bu örnek için paralel işleme kullanıldığında süre 50 parçacık için 930 saniyeden 25 saniye civarına, 150 parçacık için ise 1950 saniyeden 19 saniye civarına inmesi beklenmektedir.

Yöntemlerin bir sefer çalışmasından elde edilen alt-piksel dağılımı haritaları Şekil 3.19’da, maliyet-yineleme sayısı grafikleri ise Şekil 3.20’de sunulmuştur. Bu durumda 50 parçacık kullanmanın yerel bir en küçük çözüme takılma ile sonuçlandığı görülmektedir. 150 parçacık kullanımı hem başarıyı arttırmakta, hem de yineleme sayısını azaltmaktadır.



Şekil 3.19. Sentetik veri için 5×5 alt-örneklemede sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (50 parçacık) (d) Özgün yöntem sonucu (150 parçacık)



Şekil 3.20. Sentetik veri için 5×5 alt-örneklemede maliyet-yineleme grafikleri (a) Benzetimli tavlama ile (b) Özgün yöntem ile (50 parçacık) (c) Özgün yöntem ile (150 parçacık)

Sentetik veri için elde edilen sayısal başarımlar Tablo 3.4'te paylaşılmıştır. Sayısal başarımlar için spektral karışım analizi sonrası uzamsal çözünürlüğü artırılmış verideki etiket bilgisi, orijinal yer doğrusu haritasının (çözünürlük deney için azaltılmadan önce) etiket bilgisi ile karşılaştırılarak etiketlerdeki doğruluk oranı tespit edilmektedir.


Tablo 3.4. Sentetik veri için sayısal sonuçlar

	3×3	5×5
Rastgele Dağılım	% 98,76	% 97,67
Benzetimli Tavlama	% 99,97	% 99,61
Özgün Yaklaşım (50 parçacık)	% 99,97	% 99,43
Özgün Yaklaşım (150 parçacık)	-	% 99,61

Geliştirilen özgün yaklaşım ve benzetimli tavlama yaklaşımlarının yaklaşık değerler verdiği gözlemlenmektedir. Ayrıca, bu değerlerin rastgele dağılımının başarımından, beklendiği üzere, yüksek olduğu görülmektedir.

3.2.4.2. Indian Pine ile oluşturulan sentetik veride deneysel sonuçlar

Bu deney için AVIRIS Indian Pine verisinin yer doğrusu haritasının bir alt-kümesi kullanılmıştır. USGS spektral kütüphanesinden seçilmiş dört spektral imza ile her imza atandığı yer doğrusu etiketine göre denk gelecek şekilde bir sentetik veri oluşturulmuştur. Oluşan veri 3×3 ile alt-örneklenmiş ve yöntemlere girdi olarak verilmiştir. Yöntemlerin tek koşu için sonuçları Şekil 3.21’de verilmiştir.



Şekil 3.21. Indian Pine ile oluşturulan sentetik veri için sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği

Önerilen yaklaşımın görsel olarak benzetimli tavlama ile çözünürlük artırımı yaklaşımına benzer sonuç verdiği görülmektedir. Alt-piksel etiketi dağılımı haritaları ile yer doğrusu haritası arasındaki hatalar genel olarak yer doğrusunda etiketin

bulunan alanların arasındaki ince çizgilerde olup, bu durum maliyet fonksiyonun etiketlere atanan alt-piksel kümelerinin toplam çevresini küçüklemeyi amaçlamasından kaynaklanmaktadır. Yöntemleri 5 kere çalışmasından elde edilen ortalama yineleme sayıları ve ardışık işleme süreleri Tablo 3.5'te verilmiştir.

Tablo 3.5. Indian Pine ile oluşturulan sentetik veri için ortalama hesaplar

	Ardışık Süre	Yineleme Sayısı
Benzetimli Tavlama	750s	22250
Özgün Yaklaşım	6200s	12

Geliştirilen özgün yaklaşımın ardışık işlem süresi yüksek olmakla birlikte, çok daha az yineleme sayısında sonuca ulaştığı Tablo 3.5'ten ve Şekil 3.21'den görülmektedir. Bu örnekte de paralel işlemenin geliştirilen özgün yaklaşıma katkısı büyük olacak olup, işlem yükü 6200 saniyeden ortalama 64 saniye civarına inecektir.

3.2.4.3. Gerçek veride deneysel sonuçlar

Gerçek veride deneysel sonuçlar için ROSIS Pavia Üniversitesi verisi kullanılmıştır. Bu veri 103 spektral bant içermekte olup, 1,3 metre uzamsal çözünürlüğe sahiptir. Deneyde verinin 120×90 piksel boyutlarında bir alt kümesi kullanılmıştır. Orijinal veride 3×3 piksellik alan bir pikselle ifade edilecek şekilde, verinin uzamsal çözünürlüğü 3 kat azaltılmış ve 3,9 metreye indirilmiştir.

Verideki son eleman sayısı HFC yöntemi ile 5 olarak tespit edilmiştir. Bu örnekte bolluk oranları tespit edildikten sonra kullanılan eşik değeri mutlak değil, göreceli olarak ve 0,4 değerinde alınmıştır. Başka bir deyişle, her piksel için en yüksek bolluk oranı diğer tüm bolluk oranlarından 0,4 yüksekse o piksel saf olarak kabul edilmiştir.


Özgün yöntem için 150 parçacık kullanılmıştır. Yöntemlerin bir koşusu için elde edilen görsel sonuçlar ve maliyet grafikleri Şekil 3.22'de verilmiştir. Özgün yaklaşım 12 yinelemede çözüme yakınsarken, benzetimli tavlama yaklaşımında bu sayı 170000 civarında olmaktadır.

Görüntünün ortasında yer alan büyük yapı olan, yer doğrusu haritasındaki metal levha sınıfına ait etiket, sayısal sonuçlar çıkartılmasında kullanılmıştır. Yaklaşımların

verdikleri etiket dağılımları ile orijinal yer doğrusu (çözünürlük deney için azaltılmadan önceki) haritasındaki metal levha etiketleri karşılaştırılmış ve doğruluk oranları çıkartılmıştır. Sonuçlar Tablo 3.6’da paylaşılmıştır. Geliştirilen yaklaşımın gerek rastgele dağılıma, gerek ise benzetimli tavlama yaklaşımına başarımlı üstünlüğü göze çarpmaktadır.

Tablo 3.6. Pavia Üniversitesi verisi için sayısal sonuçlar


	Sınıflandırma Başarısı
Rastgele Dağılım	% 96,7286
Benzetimli Tavlama	% 99,1078
Özgün Yaklaşım	% 99,6283




(a)

(b)

(c)



(d)



(e)

Şekil 3.22. Pavia Üniversitesi verisi için sonuçlar (a) Alt-piksel etiketlerinin uzamsal olarak rastgele dağıtılması (b) Benzetimli tavlama sonucu (c) Özgün yöntem sonucu (d) Benzetimli tavlama için maliyet-yineleme grafiği (e) Özgün yöntem için maliyet-yineleme grafiği

3.2.5. Vargılar

Bu çalışma kapsamında hiperspektral verilerde uzamsal çözünürlük artırımı için özgün bir yöntem geliştirilmiştir. Geliştirilen yöntem son eleman çıkarımı ve spektral karışım analizi sonrası, uzamsal bağımlılık esası ve BPSO kullanarak, ek bir görüntü olmadan, verinin uzamsal çözünürlüğünü arttırmaktadır. Geliştirilen yöntem literatürde yer alan diğer yöntemlere göre daha yüksek paralel işleme yatkınlığına sahiptir ve bu sayede çok daha düşük hesap yükü elde etme imkanı sağlayacaktır. Sentetik ve gerçek veriler üzerinde çıkartılan deneysel sonuçlar yöntemin başarımını göstermektedir.

Olası ileri çalışmalar arasında farklı maliyet fonksiyonlarının geliştirilmesi ve yöntem için paralel işleme mimarisi geliştirilmesi sayılabilir. İleri çalışmalar için başka bir olası yön ise BPSO sürecinin içerdiği iki parçacık kıstasına yöntem içinde içkin bir çözüm geliştirilmesidir. Bunun yanında parçacıkların ilk dağılımları ve parçacık konumları güncelleme süreci de detaylı olarak incelenerek global çözüme yaklaşımı hızlandıran bir geliştirme de mümkündür.

4. UZAMSAL BİLGİ KULLANARAK SINIFLANDIRMA BAŞARIMININ ARTIRILMASI

Hiperspektral verilerin sınıflandırılması için kullanılan piksel-tabanlı yöntemler literatürde yaygın ve çok çeşitlidir. Bu yöntemler arasında maksimum olabilirlik veya Bayes kestirim yöntemleri [1], karar ağaçları [94], yapay sinir ağları, genetik algoritmalar [95] ve çekirdek tabanlı yöntemler [96] sadece birkaçıdır. Özellikle DVM, hiperspektral görüntü sınıflandırması uygulamalarında sıkça kullanım bulmakta ve eğitim örneği sayısı az olduğu durumlarda diğer yöntemlere göre üstün başarımlar göstermektedir. [97-99].

Bununla birlikte, uzamsal bilgilerin sınıflandırma işlemine dahil edilmesinin sadece spektral özellikleri kullanan piksel tabanlı sınıflandırmaya göre başarımları arttırdığı bilinmektedir. Bu tür yaklaşımlarda, pikselden elde edilen öznitelik vektörü, sadece hiperspektral piksel vektörünün kendisi olmamakta, aynı zamanda başka piksel vektörlerinden de bilgiler içermektedir.

Uzamsal bilginin sınıflandırma işlemine dahil edilmesi için kullanılan yaklaşımlarından biri sabit pencere boyutu kullanılarak komşu piksellerden de bilgi alınması yaklaşımıdır. Bu yaklaşımı kullanan yöntemler arasında morfolojik süzgeçlerin kullanılması [3] veya Markov rastsal alanlar [100] sayılabilir.

Başka bir yaklaşım ise uzamsal bilginin kümeleme yaklaşımları ile sınıflandırma işlemine dahil edilmesidir [101]. Kümeleme ile belirli bir kıstasa göre homojenlik gösteren piksel vektörleri sınıflandırma öncesi gruplanmaktadır.

Uzamsal bilginin sınıflandırma işlemine dahil edilmesi yaklaşımlarından başka bir tanesi ise veriyi, uzamsal bilgileri vurgulayan bir öznitelik uzayına taşıyarak, spektral tabanlı sınıflandırma işlemini bu öznitelik uzayında gerçekleştirmektir. Çekirdek tabanlı yöntemlere benzer bir yaklaşım olan bu yaklaşımda, çekirdek uzayına geçişte olduğu gibi pencereler kullanılabileceği gibi, tüm veri de öznitelik uzayına aktarılabilir. Bu tez kapsamında uzamsal bilgi kullanılarak hiperspektral verilerde sınıflandırma başarımının artırılması üzerine bu yaklaşım altında çalışmalar

yürütülmüş olup, bu çalışmalar sonucunda elde edilen ampirik kip ayrışımı (AKA) [102] tabanlı özgün yöntem bu bölümde aktarılacaktır.

4.1. Özgün Çalışma: Spektral Gradyan Geliştirmeli AKA

Bu çalışma kapsamında hiperspektral verilerin destek vektör makineleri ile sınıflandırma başarımının artırılması için spektral gradyan geliştirmeli AKA yöntemi özgün olarak geliştirilmiştir.

Yakın zamanda, hiperspektral verilerin her spektral bandına ayrı ayrı iki boyutlu AKA uygulanarak elde edilen içkin kip fonksiyonları (İKF) (Intrinsic Mode Functions-IMF) DVM için öznitelik verisi olarak kullanıldığında sınıflandırma başarımının arttırılabileceği gösterilmiştir [103-105]. [103-105]'te İKF'ler eşit ağırlıklarla toplanmış ve elde edilen temsili veri üzerinden yüksek sınıflandırma başarımı elde edilmiştir.

Bu tez kapsamında geliştirilen özgün çalışmada ise İKF'lerin ağırlıklarının optimize edilmesi ile sınıflandırma başarımının önemli derecede arttırılabildiği gösterilmektedir. Bu çalışmada, İKF ağırlıkları, ağırlıklı İKF toplamı ile elde edilen temsili verinin toplam mutlak spektral gradyanını en büyükleyecek şekilde, genetik algoritma tabanlı bir optimizasyon yöntemi ile belirlenmektedir. İki boyutlu AKA uzamsal işleme sağlarken, geliştirilen bu özgün yöntem ile öznitelik uzayı çıkarımına spektral geliştirme dahil edilmektedir. Bu sayede gerek veri üzerinden, gerekse eşit ağırlıklı İKF toplamı ile elde edilen temsili veri üzerinden elde edilen başarımlara göre daha yüksek sınıflandırma başarımı elde edilmektedir.

Türevsel analizlerin spektral detayları vurguladıkları ve ışıklılık ve atmosferik etkileri azalttıkları için, hiperspektral görüntü işlemede umut verici olduğu [106]'da belirtilmiştir. [107]'de spektral genlik öznitelikleri spektral türev öznitelikleri ile birleştirilerek hiperspektral görüntülerde sınıflandırma başarımı arttırılmıştır. [108]'de spektral yansıma ve türev bilgisi karar seviyesinde kaynaştırılarak hiperspektral görüntü sınıflandırma için kullanılmıştır. Türevsel analizler, ayrıca, [109]'da spektral karışım analizi ve [110]'da gürültü giderimi için kullanım bulmuştur. Bu çalışmada türevsel öznitelikler doğrudan kullanılmamakta olsa da

spektral gradyanın arttırılması öznitelik çıkarımında spektral detayı vurgulamakta ve sınıflandırma başarımını arttırmaktadır.

4.1.1. AKA

AKA, doğrusal olmayan ve durağan olmayan verileri analiz etmek için geliştirilmiş, veriye bağlı ve parametrik olmayan bir ayrıştırma yöntemidir [102]. AKA ile bir işaret sonlu sayıda İKF'ye ve bir artıklık işaretine ayrıştırılmaktadır. Bu ayrıştırma kayıplı olmayıp, orijinal işaret, İKF'ler ile ayrıklık işareti toplanarak geri elde edilebilir. AKA ile elde edilen ilk İKF yüksek geçiren süzgeçlenmiş işareti andırmakta ve ilk İKF'de yerel olarak en yüksek frekanslar yer almaktadır. Geri kalan İKF'ler ise sırayla daha düşük yerel frekansları barındırmakta olup, bant geçiren süzgeçlenmiş işareti andırmaktadır. İKF'lerin merkez frekansları süzgeç bankasında olduğu gibi oktav bir bant şeklinde azalmakta olup, tam ve neredeyse dik bir taban oluşturmaktadır [102].

AKA doğrusal olmayan ve durağan olmayan veriler için Fourier ve dalgacık dönüşümlerine göre daha başarılı bir ayrıştırma yöntemidir. Bunun nedeni, AKA ile Fourier dönüşümü gibi doğrusallık ve durağanlık varsayımı yapılmaması ve dalgacık dönüşümü gibi veriye göre farklı başarımlar veren farklı taban fonksiyonların sahip olmayıp, tamamen veriye bağımlı olmasıdır. Ayrıca, dalgacık dönüşümünde, frekans ölçekleri örnekleme frekansı ve ayrıştırma seviyesine bağlı olarak sabittir. AKA'da ise frekans ölçekleri tamamen veriye bağlıdır ve İKF'ler yerel frekansları içermektedir [102].

AKA ile elde edilen İKF'ler aşağıdaki iki kistası sağlamak zorundadır:

- 1) Uç noktaların (en büyük ve en küçük noktaları) ve sıfır geçişlerinin sayısı aynı veya en fazla bir farklı olmalıdır.
- 2) Sırasıyla uç en büyük noktalar ve uç ek küçük noktalardan elde edilen üst ve alt zarfın ortalaması her noktada sıfır olmalıdır.

AKA orijinal olarak tek boyutlu işaretler için önerilmiş olsa da literatürde AKA'yı iki boyuta çıkarmak için çeşitli çalışmalar yürütülmüştür. Örneğin [111]'de jeodezik operatör tabanlı morfolojik işlemler ile uç noktaları bulan ve RBF ara değerlemesi ile

zarfları çıkartan çift boyutlu AKA önerilmiştir. [112]'de uç noktalar tespit edildikten sonra zarfların elde edilmesi ince-tabaka yumuşatma eğrisi (thin-plate smoothing spline) ara değerlemesi kullanılmıştır. [113]'te içboyama (inpainting) ile zarflar çıkartılırken, [114] ve [115]'te kısmi türev denklemi tabanlı bir yaklaşım geliştirilmiştir.

İki boyutta İKF'leri elde etmek için kullanılan eleme işlemi genel olarak şu şekilde özetlenebilir:

- 1) z_k = girdi işareti. Başlangıçta yineleme sayısı $k = 1$.
- 2) z_k işaretinin tüm yerel en büyük ve en küçük noktaları çıkartılır.
- 3) Sırasıyla yerel en büyük ve yerel en küçük noktalardan ara değerlendirme ile üst zarf e_{max} ve alt zarf e_{min} elde edilir.
- 4) Üst ve alt zarfın ortalaması ile ortalama zarf elde edilir;

$$e_{ort} = (e_{max} + e_{min})/2 \quad (4.1)$$

- 5) Ortalama zarf giriş işaretinden çıkartılır;

$$h = z_k - e_{ort} \quad (4.2)$$

- 6) Ortalama zarfın durma kistasını sağlayıp sağlamadığı kontrol edilir. Bu durma kistası ortalama zarfın büyüklüğünün sıfıra yakın olmasıdır;

$$\frac{\sum_{x=1}^W \sum_{y=1}^H e_{ort}(x, y)}{W \times H} < \tau \quad (4.3)$$

Bu denklemde W ve H verinin uzamsal boyutları, τ ampirik olarak belirlenen eşik değeridir. Durma koşulu sağlanmazsa h yeni z_k işareti olarak alınarak algoritmanın 2. adımına dönlülmektedir. Durma koşulu sağlandığında h yeni İKF olarak alınır;

$$IKF_k = h \quad (4.4)$$

- 7) Elde edilen İKF girdi işaretinden çıkartılarak artıklık işareti elde edilir;


$$\text{artıklık} = \text{girdi işareti} - IKF_k \quad (4.5)$$

Artıklık işaretinde ara değerlendirme ile zarf elde edilecek kadar yerel en büyük ve yerel en küçük notalar varsa, artıklık işareti girdi işareti olarak alınarak ve k bir arttırılarak 1. adıma dönülür. Aksi halde işlem sonlandırılır.


İki boyutlu AKA, hiperspektral görüntü sınıflandırması için ilk olarak [103]'de kullanılmış olup, sınıflandırma başarımını önemli derecede arttırdığı gözlemlenmiştir. İki boyutlu AKA'nın bu alandaki başarısı veri-tabanlı yapısı ve dolayısıyla İKF'lerin veriye uzamsal olarak adapte olmasından kaynaklanmaktadır [103]. Bu sayede verinin uzamsal özellikleri sınıflandırma işlemine yüksek katkı sağlayacak şekilde bütünleştirilmektedir. [103]'te hiperspektral verinin her spektral bandına iki boyutlu AKA uygulanmış ve her bant için, çıkartılan ilk birkaç İKF toplanarak, yüksek sınıflandırma başarımının elde edildiği yeni bir veri oluşturulmuştur. [104]'te ilk iki İKF kompozit bir çekirdek yapısı ile kullanılarak sınıflandırma başarımı artırımı yapılmıştır. [107]'de bu iki yaklaşım dalgacık dönüşümü tabanlı gürültü giderimi, alçak geçiren süzgeç yapısı, keskinlik giderici süzgeç yapısı, spektral ve uzamsal düzlem kompozit çekirdekleri ve morfolojik tabanlı sınıflandırıcılar ile karşılaştırılarak AKA yaklaşımının başarımı gösterilmiştir.

Bu tez kapsamında da iki boyutlu AKA yaklaşımı için, [103-105]'te de kullanılan, [112]'de önerilen yaklaşım tercih edilmiştir. Bu yaklaşımda bir nokta eğer değeri tüm komşu noktalarından daha büyükse / küçükse yerel en büyük / yerel en küçük nokta olarak alınmakta olup, zarflar ince-tabaka yumuşatma eğrisi ara değerlemesi ile elde edilmektedir.

Bu yöntem ile AVIRIS Indian Pine verisine AKA uygulandığında ($\tau = 0,006$) iki fark spektral bant için elde edilen İKF'ler Şekil 4.1 ve Şekil 4.2'de sunulmuştur. Bu şekiller, görsellik için gri ölçekte 0 – 1 değerleri arasına normalize edilmiştir. İlk İKF'nin en yüksek yerel uzamsal frekansları taşıdığı ve dolayısıyla en az uzamsal bütünleşime sahip olduğu görülebilmektedir. Son İKF'ler ise en düşük yerel frekansları taşımakta olup, en fazla uzamsal bütünleşime sahiptir. Artıklık işaretleri ise yerel DC değerlerini içeren ortalama işaretlerdir. Şekil 4.1'de 30. spektral bant için üç İKF elde edildiği görülmektedir. 3. İKF'ten sonra artıklık işaretinde dört yerel en büyük nokta kalmasına rağmen, iki en küçük nokta kaldığı, bu sayı da alt zarfı elde etmek için yetersiz olduğundan dolayı işlem sonlanmıştır.



Şekil 4.1. Indian Pine verisi 30. spektral bant için iki boyutlu AKA (a) Orijinal bant görüntüsü (b) Birinci İKF (c) İkinci İKF (d) Üçüncü İKF (e) Artıklık işareti



Şekil 4.2. Indian Pine verisi 29. spektral bant için iki boyutlu AKA (a) Orijinal bant görüntüsü (b) Birinci İKF (c) İkinci İKF (d) Üçüncü İKF (e) Artıklık işareti

Şekil 4.2’de ise 29. spektral bant için 4 İKF elde edildiği ve artıklık işaretinde bu aşamadan sonra bir adet yerel en büyük, bir adet de yerel en küçük nokta kaldığı görülmektedir. Bununla beraber, 4. İKF’de neredeyse hiç uzamsal detay olmadığı ve artıklık işareti ile büyük farklılık göstermediği de görülmektedir. Bu yüzden, bu

spektral bant için 4. İKF atılarak, 3. İKF'nin en yüksek (mantıklı) uzamsal bütünleşim içerdği söylenebilir.

4.1.2. Spektral gradyan geliştirmeli AKA

Özgün olarak geliştirilen bu yöntemde, iki boyutlu AKA'nın uzamsal işlemesine spektral gradyan geliştirmesi yapılmakta ve bu sayede uzamsal-spektral işleme ile sınıflandırma başarımının artırılması hedeflenmektedir. Geliştirilen yaklaşımda İKF'lerin ağırlıkları toplam mutlak spektral gradyanı en büyükleyecek şekilde, genetik algoritma (GA) kullanılarak optimize edilmektedir.

GA, evrim süreci tabanlı, buluşsal bir arama yöntemidir [116]. En dik iniş (steepest descent) ve Newton yöntemlerinin aksine, yöntem türev içermemekte ve arama nokta nokta yapılmamaktadır. Bunun yerine, çözüm uzayı paralel olarak aranmakta, bu sayede optimizasyonun yerel minimum noktalarına takılma ihtimali daha düşük olmaktadır [117]. GA bu hristik arama yaklaşımını, evrimden esinlenen iki varsayım ile gerçekleştirir:

- 1) Popülasyondaki her bireyin zindelik (fitness) değeri mevcut problemi çözmedeki başarısının bir ölçümüdür. Bireyler mevcut problem için aday çözümlerdir.
- 2) Popülasyondaki farklı bireyleri birleştirerek problemi çözmede daha gelişmiş başarıya sahip yeni bireyler elde edilebilir.

Bu iki varsayım ışığında, GA'da kromozom olarak adlandırılan aday sonuçlar yinelemeli olarak daha iyi sonuçlara evrimleşmektedir.

GA süreci şöyle özetlenebilir:

- 1) Rastgele olarak bir ilk popülasyon (çözüm aday kümesi) yaratılır.
- 2) Popülasyondaki her kromozomun zindelik değeri bir amaç fonksiyonu ile ölçülür.
- 3) Popülasyondan zindelik değerine göre kromozomlar seçilir.
- 4) Seçilmiş kromozomlardan çaprazlama ve mutasyon ile yeni bir popülasyon oluşturulur. Çaprazlama ve mutasyon oranları probleme bağlı değerlerdir.
- 5) Yeni popülasyon eski popülasyon ile değiştirilir.
- 6) Durma koşulu sağlanana kadar algoritma yinelemeli olarak 2. adımdan devam eder.

GA işlemi Şekil 4.3'teki akış şeması ile gösterilebilir.



Şekil 4.3. GA işlem akışı

GA literatürde AKA işlemi ile daha önceden kullanılmış olup, [118]'de yerel en büyük ve en küçük noktaların zarflar için optimize edilmesi amacıyla, [119]'da İKF'lerden elde edilen çekirdek temel bileşenlerinin optimizasyonunda kullanılmıştır. [120]'de ise GA en küçük kareler DVM ile birlikte AKA'nın kenar etkilerinin giderilmesi amacıyla kullanılmıştır. Ancak GA, bu tez çalışmasında olduğu gibi İKF'lerden öznitelik verisinin oluşturulması veya İKF ağırlıklarının belirlenmesi amacıyla literatürde kullanım bulmamıştır.

Geliştirilen özgün spektral gradyan geliştirmeli AKA işlemi şu şekilde özetlenebilir:

1) Hiperspektral verinin her spektral bandına iki boyutlu AKA uygulanarak İKF'ler elde edilir.

2) Elde edilen İKF'ler ile ağırlıklı toplam sonucu en büyük toplam mutlak spektral gradyana sahip veriyi oluşturacak ağırlıkları tespit etmek için GA uygulanır:

2.1) Her bir bireyin içerdiği sayılar olan ağırlıkların negatif olmaması ve toplamlarının bire eşit olması kistası sağlanması koşulu ile rastgele bir İKF ağırlıkları popülasyonu yaratılır.

2.2) Her bireyin zindelik değeri hesaplanır. Bu hesap için,

$$I_l = \frac{\sum_{k=1}^N (w_{l_k} \times IKF_k)}{|\sum_{k=1}^N (w_{l_k} \times IKF_k)|} \quad (4.6)$$

$$SpGrad_l = \frac{1}{W \times H \times S} \times \sum_{x=1}^W \sum_{y=1}^H \sum_{b=1}^S \left| \frac{\partial I(x, y, b)}{\partial b} \right| \quad (4.7)$$

ifadeleri kullanılır. Denklem (4.6)'da İKF'lerin ağırlıklı toplamından elde edilen veri 0 – 1 aralığına normalize edilmekte, böylece farklı spektral bantlarda elde edilen İKF'lerin farklı genlikte olmasının zindelik fonksiyonu olan gradyan hesabını etkilememesi sağlanır. Bu denklemlerde l popülasyondaki birey numarası, N İKF sayısını, W , H ve S verinin iki uzamsal ve bir spektral boyutunu, I ise İKF'ler ile elde edilen veriyi göstermektedir. Başka bir deyişle, ağırlık kümeleri olan bireylerin zindelikleri, bu ağırlıklar kullanılarak oluşturulacak verinin mutlak spektral gradyanıdır.

2.3) Popülasyondan bireyler, bireylere zindelik değerleri ile doğru orantılı seçilme olasılığı atayan rulet çarkı seçimi yöntemine göre seçilir.

2.4) Seçilen bireylerden 0,7 çaprazlama oranı ve 0,07 mutasyon oranı ile yeni bireyler oluşturulur. Bu işlem yeni popülasyonun boyutu eski popülasyon boyutuna eşit olana kadar devam ettirilir.

2.5) Durma koşulu sağlanmadıysa adım 2.2'den devam edilir. Bu çalışmada durma koşulu en büyük yineleme sayısı olarak alınmıştır. Durma koşulu sağlanmışsa popülasyondaki en yüksek zindeliğe sahip birey çıktı olarak alınır.


3) GA sonucunda elde edilen bireyin içerdiği ağırlıklar kullanılarak yeni veri,

$$I^* = w_k^* \times IKF_k \quad (4.8)$$


ifadesinde olduğu şekilde oluşturulur. w_k^* genetik algoritma sonucu elde edilen bireyin içerdiği İKF ağırlıklarıdır.

4) İKF'lerin ağırlıklı toplamı ile elde edilen yeni hiperspektral veri RBF çekirdekli DVM sınıflandırıcı kullanılarak sınıflandırılır.

Şekil 4.4'te AVIRIS Indian Pine verisinden elde edilen İKF'ler eşit ağırlıkla toplandığında, Şekil 4.5'te ise geliştirilen özgün yaklaşımla elde edilen ağırlıklar ile toplandığında elde edilen verilerin 30. spektral bandı sunulmuştur. Özgün yöntem ile elde edilen ağırlıklar 2 İKF için $w_1 = 0,057$ ve $w_2 = 0,943$ ve 3 İKF için $w_1 = 0,157$, $w_2 = 0,003$ ve $w_3 = 0,840$ 'dır.



Şekil 4.4. Indian Pine verisi 30. spektral bant için elde edilen bant görseli (a) İlk iki İKF eşit ağırlıkla toplandığında (b) İlk üç İKF eşit ağırlıkla toplandığında



Şekil 4.5. Indian Pine verisi 30. spektral bant için elde edilen bant görseli (a) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (b) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında

4.1.3. Deneysel sonuçlar

4.1.3.1 Deney verileri

Deneysel sonuçlar üç gerçek hiperspektral veride çıkartılmıştır. Bu veriler AVIRIS Indian Pine, ROSIS Pavia Üniversitesi ve HYDICE DC Mall verileridir.

AVIRIS Indian Pine verisi 145×145 piksel boyutunda olup, 220 spektral bant içermektedir. Deney, atmosferik gürültü içeren bantlar elenerek 200 spektral bant üzerinden gerçekleştirilmiştir. Verinin spektral aralığı $0,4 - 2,5 \mu\text{m}$ olup, uzamsal çözünürlüğü 20 metredir.

Indian Pine verisi hiperspektral görüntü işlemede en sık kullanılan görüntülerden biri olmasına karşılık, sınıflara ait spektral imzalar çok benzer ve pikseller yüksek oranda karışıklı olduğundan, sınıflandırıcı için zor bir veridir [122]. Bunun dışında, sınıfların kendi içinde de bölgesel olarak değişen toprak yapısı ve önceki senenin ekinlerinden kalan birikintiden dolayı farklılık fazla olmaktadır [123]. Bununla beraber, uzamsal işlemenin sınıflandırma dahil edilmesiyle sınıflandırma başarımının artırılabilirdiği bilinmektedir.

Verinin orijinal yer doğrusu haritası 16 sınıf içermesine karşın, bu çalışmada, literatürdeki birçok çalışmada olduğu gibi, küçük sayıda örnek içeren sınıflar elenerek 9 sınıf kullanılmıştır. Indian Pine verisinin yer doğrusunda içerdiği sınıflar ve örnek sayıları Tablo 4.1’de verilmiştir.

ROSIS Pavia Üniversitesi verisi ise 340×610 piksel boyutunda olup, 115 spektral bant içermektedir. Deney, atmosferik gürültü içeren bantlar elenerek 103 spektral bant üzerinden gerçekleştirilmiştir. Verinin spektral aralığı $0,4 - 0,85 \mu\text{m}$ olup, uzamsal çözünürlüğü 1,5 metredir. ROSIS Pavia Üniversitesi verisi sınıfları arasında spektral farklılıklar yüksek bir veridir. Pavia Üniversitesi verisinin yer doğrusunda içerdiği 9 sınıf ve bu sınıflara ait örnek sayıları Tablo 4.2’de verilmiştir.

HYDICE DC Mall verisi ise 1280×307 piksel boyutunda olup, 210 spektral bant içermektedir. Deney, atmosferik gürültü içeren bantlar elenerek 193 spektral bant üzerinden gerçekleştirilmiştir. Verinin spektral aralığı $0,4 - 2,5 \mu\text{m}$ olup, uzamsal çözünürlüğü 30 metredir. DC Mall verisi, sınıfları arasında spektral farklılıklar

yüksek bir veridir. DC Mall verisinin yer doğrusunda içerdği sınıflar ve örnek sayıları Tablo 4.3’de verilmiştir.

Tablo 4.1. Indian Pine verisi yer doğrusu örnek sayıları

Sınıf	Örnek Sayıları
Mısır – sürülmemiş	1434
Mısır – minimum sürülmüş	834
Çimen / otlak	497
Çimen / ağaçlar	747
Saman – kümelenmiş	489
Soya fasulyesi - sürülmemiş	968
Soya fasulyesi – minimum sürülmüş	2468
Soya fasulyesi – temiz	614
Koru	1294
Yonca	54
Bina / çimen / ağaçlar / yollar	380
Mısır	234
Çimen / otlak – biçilmiş	26
Yulaf	20
Taş – demir - kuleler	95
Buğday	212

Tablo 4.2. Pavia Üniversitesi verisi yer doğrusu örnek sayıları

Sınıf	Örnek Sayıları
Ağaçlar	524
Asfalt	548
Katran	375
Çakıl	392
Boyanmış Metal Levhalar	265
Gölgeler	231
Tuğlalar	514
Çayırlar	540
Çıplak Toprak	532

Tablo 4.3. DC Mall verisi yer doğrusu örnek sayıları

Sınıf	Örnek Sayıları
Çatı	3834
Sokak	416
Patika	175
Çimen	1928
Ağaç	405
Su	1224
Gölge	97

4.1.3.2 Deney süreci

Sınıflandırma başarımının ölçümü için RBF çekirdek DVM kullanılmıştır. SVM parametrelerin tespiti için beş katlı çapraz-doğrulama kullanılmış olup, SVM'in C parametresi 10 ile 1000 arasında 10 büyüklüğünde adım aralıklarıyla, RBF'in γ parametresi ise 0,1 ile 2 arasında 0,1 büyüklüğünde adım aralıklarıyla taranmıştır. Çapraz-doğrulama en yüksek başarıyı veren parametreler sınıflandırmada kullanılmıştır. AKA için τ parametresi deneysel olarak 0,006 seçilmiştir. Sınıflandırma sonuçları farklı veri eğitim oranları (VEO) için verilmiştir. Örneğin, % 10 VEO, yer doğrusu bilinen noktalardan % 10'unun eğitim verisi, % 90'ının ise test verisi olarak kullanıldığı anlamına gelmektedir. Eğitim verileri yer doğrusu noktalarından, sınıfların önsel olasılıklarını koruyacak şekilde, rastgele olarak seçilmektedir. Her veri ve eğitim oranı için 20 koşu yapılarak, sınıflandırma başarımları ortalama ve değişinti cinsinden verilmiştir.

Sınıflandırma başarımları arasındaki farkların istatistiksel açıdan önemi McNemar testi ile ölçülmüştür. McNemar testinde 0,05 önemlilik seviyesi için, $|Z| > 1,96$ ise sınıflandırma farkı istatistiki açıdan önemli bir fark olarak görülmektedir. Z pozitif ise yeni sınıflandırma önceki sınıflandırmadan daha yüksek başarı vermiştir ve tersi de geçerlidir. Verilen sonuçlarda Z değerleri geliştirilen özgün yaklaşım ve İKF'ler için eşit ağırlık kullanan yaklaşım [105] arasında hesaplanmıştır.

Indian Pine verisinde 56, Pavia Üniversitesi verisinde ise 8 spektral bant 4. İKF'ye sahip olmadığından dolayı geliştirilen özgün yaklaşım sadece ilk üç İKF'yi

değerlendirmeye almıştır. Dikkat edilmesi gereken bir nokta [107]'de pencereleme tabanlı uç nokta çıkarımı kullanılmış olduğundan dolayı çeşitli bantlarda 3. İKF elde edilemezken, bu çalışmada, [105]'te olduğu üzere, komşuluk tabanlı uç nokta çıkarımı kullanılmış, böylece her spektral bantta 3 İKF elde edilebilmiş olmasıdır.

4.1.3.3. Deneysel sonuçlar

Tablo 4.4'de geliştirilen yöntemin Indian Pine verisinde, 2 İKF ve 3 İKF kullanılacağı durumlarda, İKF'ler için tespit ettiği ağırlıklar gösterilmektedir. GA ile elde edilen ağırlıklar dikkate alındığında 2 İKF durumunda 2. İKF'nin, 3 İKF durumunda ise 3. İKF'nin çok daha yüksek ağırlık aldığı görülmektedir. Ağırlıkların tespitinde uzamsal ve spektral işleme bir arada kullanılmakta, elde edilen ağırlıklarda düşük frekanslar içeren İKF'lerin ağırlıklarının daha yüksek olması bu şekilde daha yüksek uzamsal bütünleşimin sınıflandırma işlemine dahil edilmesini sağlamaktadır.

Tablo 4.4. Özgün yöntem için Indian Pine verisinde tespit edilen İKF ağırlıkları

İKF Sayısı	w_1	w_2	w_3
2	0,057	0,943	-
3	0,157	0,003	0,840

Tablo 4.5'te ise Indian Pine verisi için, orijinal veri, [105]'te kullanılan İKF'lerin eşit ağırlıklı toplanması (AKA ile temsil edilmiştir) ve özgün yöntem ile tespit edilen ağırlıklarla toplanması (AKA-SG ile temsil edilmiştir) yaklaşımları için % 5, % 10 ve % 20 sınıflandırma oranlarında sınıflandırma başarımları verilmiştir. Tablo 4.5'te, ayrıca, kullanılan ya da İKF'ler ile oluşturulan verinin 0 - 1 aralığında normalize edildikten sonra elde edilen mutlak spektral gradyan değerleri (S) de sunulmuştur.

Sınıflandırma sonuçlarından, İKF'lerin eşit ağırlıklı olarak toplanması yaklaşımının orijinal veriyi doğrudan kullanmaya göre önemli bir başarı artışı sağladığı görülmektedir. Geliştirilen yaklaşımın ise İKF'lerin eşit ağırlıklı olarak toplanması yaklaşımından daha iyi sonuç verdiği Tablo 4.5'ten net olarak gözlemlenmektedir. Ayrıca, beklendiği üzere, VEO arttıkça her yaklaşım için sınıflandırma başarımının arttığı ve standart sapmanın azaldığı dikkat çekmektedir.

Tablo 4.5. Indian Pine verisi için DVM sonuçları

Veri Temsili	İKF Sayısı	S	% 5 VEO		% 10 VEO		% 20 VEO	
			μ	σ	μ	σ	μ	σ
Orijinal	-	0,0149	83,73	1,25	88,11	0,54	90,88	0,31
AKA [105]	2	0,0043	93,56	0,64	96,78	0,45	98,54	0,21
	3	0,0052	94,69	0,79	97,01	0,48	98,42	0,23
AKA-SG	2	0,0086	94,56	0,87	97,84	0,35	99,31	0,20
	3	0,0139	96,99	0,49	98,64	0,23	99,53	0,09

Geliştirilen özgün yöntemin, İKF'lerin eşit ağırlık toplanması yöntemine göre, oluşturduğu verideki spektral gradyan değerlerinin daha yüksek olduğu Tablo 4.5'ten görülmektedir. Yöntem sonucunda, elde edilen İKF ağırlıkları kullanılarak ağırlıklı toplam sonucu oluşturulan verinin mutlak spektral grafyanı en büyüklenmektedir.

Tablo 4.5'ten, ayrıca, orijinal veride mutlak spektral gradyan değerinin oldukça yüksek olduğu görülmektedir. Bu değer yüksek olması, AKA işleminde artıklık işaretinin içinde atılan spektral bant ortalamalarının (DC) orijinal veride mevcut olması kaynaklıdır. Başka bir deyişle, spektral bant ortalamaları yüzünden yanıltıcı bir spektral gradyan değeri elde edilmiştir.

Bu durumu daha detaylı incelemek için farklı bir deneysel çalışma daha yürütülmüş ve bu deneysel çalışma kapsamında, spektral bant ortalamaları, işlemler başlamadan önce tüm spektral bantlardan çıkartılarak atılmıştır. Bu şekilde elde edilen sonuçlar Tablo 4.6'da sunulmuştur.

Tablo 4.6. Indian Pine verisi ortalama (DC) değerler önceden çıkarılınca DVM sonuçları

Veri Temsili	İKF Sayısı	S	% 5 VEO		% 10 VEO		% 20 VEO	
			μ	σ	μ	σ	μ	σ
Orijinal	-	0,0043	83,93	1,03	87,93	0,51	90,65	0,28
AKA [105]	2	0,0043	93,90	0,96	97,19	0,43	98,63	0,22
	3	0,0056	94,36	0,78	97,04	0,32	98,35	0,23
AKA-SG	2	0,0087	94,93	0,77	98,08	0,34	99,22	0,15
	3	0,0142	96,26	0,70	98,65	0,28	99,39	0,15

Tablo 4.6'dan, orijinal veri üzerinden yapılan sınıflandırmada, bant ortalamalarının atılmasının sınıflandırma başarımında önemli bir etki yaratmadığı ve veriden elde edilen spektral gradyan değerini azalttığı görülmektedir.

Tablo 4.6'dan ayrıca görüldüğü üzere, AKA yaklaşımları açısından ise ortalamaların atılmasının spektral gradyana etkisi, bu ortalamalar AKA işleminde halihazırda atıldığı için, ihmal edilebilirdir.

Sınıflandırma başarısı açısından, bu veri için, 3 İKF durumunda, bant ortalamalarının önceden atılmadığı durumda atıldığı duruma göre düşük VEO oranlarında daha yüksek başarı sağlamış olduğundan ve bant ortalamaların atılması ek işleminden yöntemi arındırmak amacıyla, bundan sonraki deney çalışmalarda sonuçlar bant ortalamaları atılmadan çıkartılmıştır.


Tablo 4.7'de ise, Indian Pine verisi için, sınıflandırma başarımı çıkartılan yaklaşımlar ile elde edilen veriler üzerinden, sınıflar arası Bhattacharya uzaklıkları [124] sunulmuştur.

Tablo 4.7. Indian Pine verisi için Bhattacharya uzaklıkları

Sınıf Etiketleri	Orijinal Veri	AKA 1 İKF	AKA 2 İKF	AKA 3 İKF	AKA-SG 2 İKF	AKA-SG 3 İKF
1	4,9480	17,9664	25,1881	16,7828	125,4068	73,1381
2	6,6806	22,7036	30,4912	22,2627	153,8602	89,1335
3	11,3647	28,3680	41,5495	28,7209	187,7102	102,6301
4	6,7152	22,7786	31,7502	22,6364	165,0530	92,1914
5	11,6844	30,4498	46,5603	42,6544	212,4732	145,9952
6	5,8919	20,6376	28,0821	19,4561	149,9422	81,0393
7	2,9409	14,9321	24,3035	15,3122	108,9680	71,0624
8	9,7405	26,8654	38,4945	29,2402	179,3697	104,5461
9	5,2551	19,6266	32,6727	24,3885	149,0544	101,9873

Tablo 4.7'den, geliştirilen yöntemin sınıflar arası uzaklığı artırdığı, dolayısıyla sınıflar arası ayrıştırıcılığı ve sınıflandırma başarımını artıracakları görülmektedir.

Şekil 4.6’da Indian Pine verisinde % 5 VEO’da, sayısal sonuçları Tablo 4.5’te verilen, sınıflandırma haritaları sunulmuştur. Şekil 4.6’da sunulan görsel sonuçlarda da, eşit ağırlıklı AKA’nın orijinal veriyi doğrudan kullanmaya ve önerilen yöntemin eşit ağırlıklı AKA’ya başarımlı üstünlüğü net şekilde görülmektedir.



Şekil 4.6. Indian Pine verisi % 5 VEO’da sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında (c) İlk iki İKF eşit ağırlıkla toplandığında (d) İlk üç İKF eşit ağırlıkla toplandığında (e) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (f) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında

Indian Pine verisi için, sadece çok sayıda örnek içeren dokuz sınıf değil, tüm sınıflar kullanıldığında, VEO yaklaşımı kullanılmamıştır. Bunun nedeni, bazı sınıfların eleman sayısının çok az olması, dolayısıyla oransal bir eğitim verisinde az örnekle temsil edilecek olmalarıdır. Bu durumda başarıyı ölçmek için [124]’teki yaklaşım kullanılmıştır. Çok az örnek içeren “yonca”, “çimen / otlak – biçilmiş” ve “yulaf” sınıflarından 15, diğer tüm sınıflardan 50 örnek rastgele seçilerek eğitim verisi olarak alınmıştır. Geri kalan tüm noktalar ise test verisinin içinde alınmıştır. Yöntemler 20 sefer çalıştırılarak sınıflandırma başarımları ortalama ve standart sapma olarak hesaplanmıştır. Sonuçlar Tablo 4.8’de sunulmuştur. Geliştirilen AKA-SG yaklaşımının eşit ağırlıklı AKA yöntemine göre 2 İKF durumunda % 1, 3 İKF durumunda ise % 2 sınıflandırma başarımları iyileştirmesi sağladığı görülmektedir.

Tablo 4.8. Indian Pine verisi tüm sınıflar kullanıldığında DVM sonuçları

Sınıflandırma Başarımı	Orijinal Veri	AKA [105]		AKA-SG	
		2 İKF	3 İKF	2 İKF	3 İKF
μ	79,1724	91,1312	93,3484	92,2655	95,3674
σ	1,1355	0,9533	1,1753	1,2216	0,8150

Tablo 4.9 ve Tablo 4.10’da Pavia Üniversitesi verisi için elde edilen İKF ağırlıkları ve sınıflandırma sonuçları sunulmuştur.

Tablo 4.9. Pavia Üniversitesi verisinde tespit edilen İKF ağırlıkları

İKF Sayısı	w_1	w_2	w_3
2	0,006	0,994	-
3	0,001	0,168	0,831

Tablo 4.10. Pavia Üniversitesi verisi için DVM sonuçları

Veri Temsili	İKF Sayısı	S	% 5 VEO		% 10 VEO		% 20 VEO	
			μ	σ	μ	σ	μ	σ
Orijinal	-	0,0038	82,15	1,43	86,18	1,18	89,02	0,66
AKA [105]	2	0,0045	90,18	1,25	94,55	0,77	97,14	0,49
	3	0,0060	93,15	1,03	96,15	0,53	97,70	0,43
AKA-SG	2	0,0124	93,05	1,73	97,65	1,09	97,70	0,36
	3	0,0241	94,38	0,76	97,89	0,59	99,60	0,39

Tablo 4.11 ile 4.12’de ise DC Mall verisi için elde edilen İKF ağırlıkları ve sınıflandırma sonuçlar sunulmuştur.

Tablo 4.11. Özgün yöntem için DC Mall verisinde tespit edilen İKF ağırlıkları

İKF Sayısı	w ₁	w ₂	w ₃
2	0,0002	0,9998	-
3	0,0390	0,0265	0,9345

Tablo 4.12. DC Mall verisi için DVM sonuçları

Veri Temsili	İKF Sayısı	S	% 5 VEO		% 10 VEO		% 20 VEO	
			μ	σ	μ	σ	μ	σ
Orijinal	-	0,0021	99,23	0,18	99,42	0,12	95,56	0,10
AKA [105]	2	0,0012	98,94	0,24	99,46	0,18	99,77	0,11
	3	0,0014	99,48	0,28	99,57	0,16	99,89	0,09
AKA-SG	2	0,0055	99,21	0,42	99,67	0,30	99,95	0,11
	3	0,0095	99,53	0,31	99,82	0,24	99,98	0,06

İKF ağırlıklarının PAvia verisinde de DC Mall verisinde de, Indian Pine verisinde olduğu gibi, düşük seviye İKF’lerde yüksek seviye İKF’lere göre daha yüksek olduğu görülmektedir. Geliştirilen yöntemin tespit ettiği ağırlıklarla ile oluşturulan öznitelik uzayında iki veri için de sınıflandırma başarımını artırdığı görülmektedir.


Kullanılan üç farklı hiperspektral verideki, geliştirilen özgün yaklaşım ile eşit ağırlıklı İKF toplamı içeren AKA yaklaşımının sınıflandırma başarımları arasında farkın istatistiki açıdan önemli olup olmadığının tespiti amacıyla, % 5 ve % 10 VEO için, önerilen yöntem ile İKF’lerin eşit ağırlıklarla birleştirilmesi arasında McNemar testi sonuçları çıkartılmış ve bu sonuçlar Tablo 4.13’te verilmiştir.

Tablo 4.13’te sınıflandırma sonuçları arasındaki farkların genel olarak istatistiki açıdan anlamlı çıktığı görülmektedir. Bu durum, mutlak spektral gradyanı en büyükleme yaklaşımının sınıflandırma başarımını istatistiki açıdan önemli derecede etkilediği bilgisini vermektedir.


Tablo 4.13. McNemar testi sonuçları

Veri	VEO	İKF Sayısı	AKA Ort. Sınıflandırma [105]	AKA-SG Ort. Sınıflandırma	z	
					μ	σ
Indian Pine	% 5	2	93,7610	94,8648	3,9212	2,9458
		3	94,9718	96,9461	8,0498	3,0769
	% 10	2	96,8973	97,9297	4,8462	3,3463
		3	97,0382	98,7817	8,9423	1,8364
Pavia Üniv.	% 5	2	90,1814	93,0476	4,9690	3,6222
		3	93,1537	94,3846	2,3613	1,6635
	% 10	2	94,5580	97,8418	7,6253	2,7633
		3	96,0982	97,8623	4,0104	2,3077
DC Mall	% 5	2	98,9442	99,2108	2,0366	3,2785
		3	99,4845	99,5334	0,6891	3,5475
	% 10	2	99,4620	99,6705	2,2119	3,0002
		3	99,6822	99,8218	2,3155	2,5656

Şekil 4.7’de ve Şekil 4.8’de, Pavia Üniversitesi verisi için, sayısal sonuçları Tablo 4.10’da verilen, % 5 VEO’da elde edilen sınıflandırma haritaları sunulmuştur.




Şekil 4.7. Pavia Üniversitesi verisi % 5 VEO’da sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında




Şekil 4.8. Pavia Üniversitesi verisi % 5 VEO'da özgün yöntem ile elde edilen sınıflandırma haritaları -2 (a) İlk iki İKF eşit ağırlıkla toplandığında (b) İlk üç İKF eşit ağırlıkla toplandığında (c) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (d) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında

Geliştirilen özgün yaklaşımla elde edilen başarımların artışı, Pavia Üniversitesi verisi için kullanılan yer doğrusu haritası az sayıda örnek noktası içerdiği için, Şekil 4.7 ve Şekil 4.8'den kolay şekilde ayırt edilememektedir.

Bununla beraber, hatalı sınıflandırma sonucu, yer doğrusundaki renk ile farklı renkte ifade edilmiş örnek sayısının AKA tabanlı yöntemlerde orijinal veriyi doğrudan kullanma yaklaşımına göre az olduğu görülmektedir. Şekil 4.9 ve Şekil 4.10'da ise Pavia Üniversitesi verisi için daha güncel olan bir yer doğrusu haritası kullanılarak sınıflandırma yapıldığında elde edilen sınıflandırma haritaları paylaşılmıştır.



Şekil 4.9. Pavia Üniversitesi verisi yeni yer doğrusu ile sınıflandırma haritaları (a) Yer doğrusu (b) Orijinal veri kullanıldığında (c) İlk iki İKF eşit ağırlıkla toplandığında (d) İlk üç İKF eşit ağırlıkla toplandığında



Şekil 4.10. Pavia Üniversitesi verisi yeni yer doğrusu için özgün yaklaşım ile sınıflandırma haritaları - 2 (a) İlk iki İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında (b) İlk üç İKF özgün yöntemin tespit ettiği ağırlıklarla toplandığında

4.1.3.4. Farklı sınıflandırma yöntemleri ile deneysel sonuçlar

Geliştirilen özgün yöntemin başarısının DVM sınıflandırma yöntemine bağlı olmadığını göstermek amacıyla, Indian Pine verisinde, sınıflandırma başarımları iki farklı sınıflandırma yöntemi kullanılarak da çıkartılmıştır.

Tablo 4.14'te [125]'te önerilen Gauss süreci yaklaşımı kullanıldığında elde edilen sonuçlar sunulmuştur. Bu yaklaşımda bir örneğin bir sınıf etiketine ait olma olasılığının monotonik olarak gizli (latent) bir fonksiyona bağlı olduğu kabul edilmektedir. Önsel ortak değişinti matrisi, Laplace ve beklenti en büyüklenmesi (expectation maximization) gibi bir çıkarım yöntem ile kullanılarak Gauss olmayan ortak sonsal ortak değişinti yakınsanır. Bu çalışmada [125]'te en yüksek başarımları göstermiş olan RBF tabanlı önsel ortak değişinti matrisi ve Laplace yakınsama yöntemi ve logistic olabirlik kullanılmıştır. Önsel olasılıkların aynı olması için eğitim verisine her sınıftan aynı sayıda örnek alınmış olup, örnek sayısı [126]'da olduğu gibi 200 seçilmiştir. İki sınıflandırma yöntemi de yirmişer kere çalıştırılmış olup, sınıflandırma başarımları ortalama ve standart sapma cinsinden verilmiştir.

Geliştirilen özgün yöntemin sağladığı sınıflandırma başarımı artışı net şekilde görülmektedir.

Tablo 4.14. Gauss süreci yaklaşımı ile Indian Pine verisi için sonuçlar

Veri Temsili	İKF Sayısı	Gauss Olabilirlik		Logistic Olabilirlik	
		μ	σ	μ	σ
Original	-	86,82	3,41	86,84	3,96
AKA [105]	2	96,53	0,55	96,41	0,64
	3	96,11	0,90	96,73	0,53
AKA-SG	2	97,94	0,33	97,69	0,41
	3	98,28	0,88	98,75	0,33

Tablo 4.15’te ise sınıflandırma yöntemi olarak en yakın komşular (nearest neighbors) yöntemi kullanıldığında elde edilen sınıflandırma başarımları verilmiştir. Bu sınıflandırma yöntemi kullanıldığında geliştirilen yaklaşım ile diğer yaklaşımlara göre sağlanan başarımı artışı çok daha fazla olmuştur.

Tablo 4.15. En yakın komşular yaklaşımı ile Indian Pine verisi için sonuçlar

Veri Temsili	İKF Sayısı	Gauss Olabilirlik		Logistic Olabilirlik	
		μ	σ	μ	σ
Original	-	72,10	0,91	76,31	0,44
AKA [105]	2	79,43	0,76	87,28	0,67
	3	88,60	0,78	92,73	0,43
AKA-SG	2	86,40	0,88	93,10	0,56
	3	95,56	0,71	97,84	0,24

4.1.3.5. Bant seçimi ve çıkarımı yaklaşımları ile deneysel sonuçlar

İncelemek için ilginç bir nokta, geliştirilen spektral gradyan tabanlı özgün yöntemin bant seçimi veya bant çıkarımı yöntemleriyle birlikte kullanıp kullanılamayacağı ve bu durumda hala sınıflandırma başarımını artırıp artırmayacağıdır.

Bu amaçla, bu çalışma kapsamında, Ardışık İleri Bant Çıkartımı (Sequential Forward Band Extraction-SFBE) [126] AKA öncesi ve sonrası kullanılarak sınıflandırma

başarımları çıkartılmıştır. SFBE spektral bant çıkarımını ardışık belirli bir sayıda spektral bandın ortalamasını alarak gerçekleştirmektedir. İstenen bant sayısı m ise SFBE Jeffries-Matusita uzaklığına bağlı bir optimizasyon kullanılarak m adet başlangıç ve bitiş bandı çifti tespit edilmektedir [126]. Bu bant çiftleri arasında kalan bantların ortalamaları ile m adet spektral bant çıkartılmaktadır.

Tablo 4.16’da AKA öncesi SFBE ile bant çıkarımı işlemi yapıp, çıkartılan 40 spektral bant üzerinden yöntemler uygulandığında elde edilen başarımlar verilmiştir. SFBE eğitim verisine uygulandığından dolayı, yöntemin her koşulunda farklı bantlar çıkartılmakta, dolayısıyla da geliştirilen özgün yöntemle belirlenen İKF ağırlıkları her koşuda değişmektedir. Ancak her koşuda benzer ağırlıklar elde edilmektedir: 2 İKF durumu için 2. İKF, 3 İKF durumu içinse 3. İKF en yüksek ağırlığı almaktadır. Bant çıkarımı ile birlikte kullanıldığında da önerilen yöntemin başarımları artırdığı Tablo 4.16’dan görülmektedir.

Tablo 4.16. AKA öncesi SFBE (40 bant) kullanıldığında Indian Pine verisi için sonuçlar

Veri Temsili	İKF Sayısı	% 5 VEO		% 10 VEO		% 20 VEO	
		μ	σ	μ	σ	μ	σ
Orijinal	-	84,73	0,82	88,16	0,47	90,28	0,42
AKA [105]	2	89,47	1,10	95,21	0,56	97,29	0,34
	3	93,82	0,85	96,69	0,41	98,18	0,27
AKA-SG	2	90,98	0,78	96,77	0,46	98,51	0,34
	3	95,43	1,01	97,99	0,39	99,30	0,16

Tablo 4.17’de Indian Pine verisi için AKA sonrası SFBE uygulandığında elde edilen başarımlar paylaşılmıştır. Bu durumda AKA orijinal veriye uygulanmıştır ve AKA tabanlı yöntemler ile yeni veri temsilleri oluşturulmuştur. SFBE bu adımdan sonra uygulanmış olup, bu yüzden özgün yaklaşımda kullanılan İKF ağırlıkları Tablo 4.4’teki ile aynıdır.

Tablo 4.17’den görülebileceği gibi, bu durumda da önerilen yöntem sınıflandırma başarımlarını artırmaktadır.

Tablo 4.17. AKA sonrası SFBE (40 bant) kullanıldığında Indian Pine verisi için sonuçlar

Veri Temsili	İKF Sayısı	% 5 VEO		% 10 VEO		% 20 VEO	
		μ	σ	μ	σ	μ	σ
Orijinal	-	84,76	0,79	88,06	0,53	90,14	0,29
AKA [105]	2	92,24	1,16	96,52	0,32	97,93	0,30
	3	94,79	0,68	97,05	0,38	98,40	0,24
AKA-SG	2	92,44	0,68	97,09	0,28	98,62	0,21
	3	96,47	0,82	98,44	0,28	99,26	0,11

4.1.4. Vargılar

Bu çalışma kapsamında, hiperspektral görüntü sınıflandırma için uzamsal ve spektral işlemeyi birleştiren özgün bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşımda hiperspektral verinin spektral bantları iki boyutlu AKA ile İKF'lerine ayrıştırılmakta ve genetik algoritma tabanlı optimizasyon ile İKF'lerin ağırlıklı toplamı ile elde edilen veri temsili spektral gradyanını en büyük yapacak ağırlıkların tespiti sağlanmaktadır. Her spektral banda ayrıca uygulanan AKA uzamsal işleme sağlamaktadır. Bu çalışmada geliştirilen spektral gradyan artırımı yaklaşımı ise verideki uzamsal bilgileri öne çıkaran AKA tabanlı işleme spektral işlemeyi dahil etmektedir. Böylece spektral ve uzamsal işlemeyi bir arada kullanan bir ayrıştırma yöntemi elde edilmiş olmaktadır. Farklı hiperspektral verilerde ve farklı sınıflandırma yöntemleri kullanılarak gerçekleştirilen deneysel sonuçlar, geliştirilen özgün yaklaşımın yüksek başarımını ortaya koymaktadır.

SONUÇLAR VE ÖNERİLER

Hiperspektral görüntüleme uzaktan algılama alanındaki en güçlü araçlardan biridir. Hiperspektral görüntülerin içerdikleri yüksek miktardaki spektral bilgi kullanılarak, sınıflandırma, tespit ve tanıma gibi görüntü işleme işlevleri standart görüntülere göre çok daha başarılı olarak gerçekleştirilebilmektedir. Uzamsal bilgi ile spektral bilginin verimli bir şekilde bir arada kullanılması ise ilgili görüntü işleme işlevlerinin başarımını daha da artırmaktadır.

Bu tez kapsamında üzerinde çalışılan iki bağlantılı konudan biri, hiperspektral görüntü işleme alanında son yıllarda büyük önem taşıyor hale gelmiş olan son eleman çıkarımı ve spektral karışım analizi ile hiperspektral görüntü işleme alanında hala en yaygın çalışma konusu olan sınıflandırma başarımı artırımdır. Bu çalışmalarda, spektral işleme ile uzamsal işlemeyi verimli şekilde bir arada kullanan ve bu sayede başarımı artırmayı hedefleyen özgün yaklaşımlar geliştirilmiştir. Tez kapsamında üzerinde çalışılan diğer konu ise hiperspektral verilerin uzamsal çözünürlüğünün, uzamsal bağımlılık esasına dayanarak ve ek bir veri kullanmadan, artırılmasıdır.

Bölüm 1’de son eleman çıkarımı konusu işlenmiştir. Verinin içerdiği materyallerin saf durumlarındaki spektral imzaları olarak tanımlanan son elemanları veriden çıkarmak için literatürde yer alan belli başlı yaklaşımlar ve yöntemler paylaşılmıştır. Daha sonra, bu tez kapsamında özgün olarak geliştirilen, son eleman çıkarımı için anomali gözetken uzamsal ön-işleme yaklaşımı aktarılmıştır. Geliştirilen özgün yaklaşım bir yandan son eleman çıkarımına uzamsal ön-işlemeyi dahil ederek başarımı artırırken, diğer yandan da anomali son elemanların kaybedilmemesini sağlayarak literatürde bu alandaki diğer ön-işleme yaklaşımlarından ayrılmaktadır. Özellikle veri sıkıştırma ve büyük veri analizi gibi durumlarda, askeri uygulamalar başta olmak üzere birçok farklı uygulama alanı için, anomali son elemanların kaybedilmemesi önem taşımaktadır. Sentetik ve gerçek veriler üzerinden elde edilen deneysel sonuçlar, geliştirilen özgün yöntemin başarımını ortaya koymuştur.

Bölüm 2’de, pikselleri son elemanların bolluk oranları cinsinden ifade etmek için kullanılan spektral karışım analizi incelenmiştir. Bu kapsamda literatürde hala ağırlığını korumakta olan en küçük kareler tabanlı karışım analizi yöntemleri paylaşılmış ve bu yöntemlerin tek başına ve son eleman çıkarımı yöntemleriyle birlikte kullanımı üzerine deneysel sonuçlar aktarılmıştır. Bu bölümde spektral karışım analizine uzamsal bilgi işlemeyi dahil ederek başarımı artırmayı amaçlayan bulanık mantık ile spektral karışım analizinin de üzerinde durulmuştur. Bulanık mantık ile spektral karışım analizi üzerine geliştirilmiş iki özgün yaklaşım aktarılmış ve deneysel sonuçlar paylaşılmıştır.

Hiperspektral verilerde uzamsal bağımlılık esasına dayanarak başka bir veri kullanılmadan uzamsal çözünürlüğün artırılması yaklaşımı Bölüm 4’te ele alınmıştır. Bu bölümde öncelikle literatürde yakın zamanda kendine yer etmiş olan benzetimli tavlama ile uzamsal çözünürlük artırımı yaklaşımı aktarılmış ve deneysel sonuçlar paylaşılmıştır. Daha sonra, özgün olarak geliştirilen, ikili parçacık sürü optimizasyonu kullanan uzamsal çözünürlük artırımı yaklaşımı aktarılmış ve deneysel sonuçlar sunulmuştur. Deneysel sonuçlar geliştirilen özgün yöntemin başarımını ortaya koymakta olup, yöntem paralel işlemeye ve FPGA mimari yapısına yüksek yatkınlığı ile literatürdeki benzer yöntemlerden ayrılmaktadır. Bu alanda gerçekleştirilecek gelecek çalışmalar arasında özgün yöntem için paralel işleme ve FPGA mimarisi yapısı ve daha verimli maliyet fonksiyonları geliştirilmesi sayılabilir.

Son bölümde hiperspektral görüntü sınıflandırması başarımının artırılması için uzamsal bilgi kullanımı üzerinde durulmuş olup, bu alanda geliştirilen özgün yaklaşım paylaşılmıştır. Bu yaklaşım ampirik kip ayrışımının uzamsal işlemesine spektral gradyan en büyükleme aracılığıyla spektral işleme dahil etmekte olup, bu sayede üretilen öznitelik uzayında sınıflandırma başarımının artırılması sağlamaktadır. Geliştirilen özgün yaklaşım farklı sınıflandırma yöntemleri ile istatistiki açıdan önemli derecede artırılmış sınıflandırma başarımı sağlamaktadır.

Son eleman çıkarımı, spektral karışım analizi, uzamsal çözünürlük artırımı ve sınıflandırma başarımı artırımı hiperspektral görüntü işleme alanında en önemli araştırma konuları arasındadır. Bu konular üzerine odaklanılmış bu tez kapsamında

paylaşılmış olan bilgilerin ve geliştirilmiş olan özgün yöntemlerin hiperspektral görüntü işleme alanlarında bilgi birikimine ve bu alanlarda çalışan araştırmacı ve bilim adamlarına yüksek faydası olacağı düşünülmektedir. Bununla beraber, bu araştırma alanları hala yeni yaklaşım ve yöntemlere ve geliştirilmeye açıktır.

KAYNAKLAR

- [1] Landgrebe D. A., *Signal theory methods in multispectral remote sensing*, John Wiley and Sons, Hoboken, New Jersey, U.S.A., 2003.
- [2] Jensen J. R., *Introductory digital image processing*, 3rd Ed., Prentice Hall, Upper Saddle River, New Jersey, U.S.A, 2005.
- [3] Fauvel M., Benediktsson J. A., Chanussot J., Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46** (11), 3804-3814.
- [4] Thomas C., Ranchin T., Wald L., Chanussot J., Synthesis of multispectral images to high spatial resolution a critical Review of fusion methods based on remote sensing physics, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46** (5), 1301-1312.
- [5] Bioucas-Dias J. M., Plaza A., Dobigeon N., Parente M., Du Q., Gader P., Chanussot J., Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5** (2), 354-379.
- [6] Lou B., Chanussot J., Doute S., Zhang L., Empirical automatic estimation of the number of endmembers in hyperspectral images, *IEEE Geoscience and Remote Sensing Letters*, 2013, **10** (1), 24-28.
- [7] Chang C.-I, *Hyperspectral imaging: techniques for spectral detection and classification*, Kluwer, Norwell, Massachusetts, U.S.A., 2003.
- [8] Chang C.-I, Du Q., Estimation of number of spectrally distinct spectral signal sources in hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2004, **42** (3), 608-619.
- [9] Harsanyi J. C., Farrand W., Chang C.-I, Detection of subpixel spectral signatures in hyperspectral image sequences, *American Society of Photogrammetry & Remote Sensing Annual Convention*, Reno, Nevada, U.S.A., 23-28 April 1994.
- [10] Bioucas-Dias J. M., Nascimento J. M. P., Hyperspectral subspace identification, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46** (8), 2435-2445.
- [11] Boardman J. W., Kruse F. A., Green R. O., Mapping target signatures via partial unmixing of AVIRIS data, *Summaries of the Sixth JPL Airborne Earth Science Workshop*, Pasadena, California, U.S.A., 4-8 March 1996.

- [12] Harsanyi J. C., Chang C.-I., Hyperspectral image classification and dimensionality reduction: orthogonal subspace projection, *IEEE Transactions on Geoscience and Remote Sensing*, 1994, **32** (4), 779-785.
- [13] Winter M. E., N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data, *Imaging Spectrometry V, Proceeding of SPIE*, Denver, Colorado, U.S.A., 27 October 1999.
- [14] Nascimento J. M. P., Dias J. M. B., Vertex component analysis: a fast algorithm to unmix hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43** (4), 898-910.
- [15] Hendrix E. M. T., Garcia I., Plaza J., Martin G., Plaza A., A new minimum-volume enclosing algorithm for endmember identification and abundance estimation in hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 2012, **50** (7), 2744-2756.
- [16] Li J., Bioucas-Dias J. M., Minimum volume simplex analysis: a fast algorithm to unmix hyperspectral data, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Boston, Massachusetts, U.S.A., 6-11 July 2008.
- [17] Bioucas-Dias J. M., Variable splitting augmented Lagrangian approach to linear spectral unmixing, *IEEE First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS'2009)*, Grenoble, France, 26-28 August 2009.
- [18] Miao L., Qi H., Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization, *IEEE Transactions on Geoscience and Remote Sensing*, 2007, **45** (3), 765-777.
- [19] Chan T., Chi C., Huang Y., Ma W., Convex analysis based minimum-volume enclosing simplex algorithm for hyperspectral unmixing, *IEEE Transactions on Signal Processing*, 2009, **57** (11), 4418-4432.
- [20] Plaza A., Martinez P., Perez R., Plaza J., Spatial/spectral endmember extraction by multidimensional morphological operations, *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40** (9), 2025-2041.
- [21] Rogge D. M., Rivard B., Zhang J., Sanchez A., Harris J., Feng J., Integration of spatial-spectral information for the improved extraction of endmembers, *Remote Sensing of Environment*, 2007, **110** (3), 287-303.
- [22] Mei S., He M., Wang Z., Feng D., Spatial purity based endmember extraction for spectral mixture analysis, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **48**, 3434-3445.
- [23] Zortea M., Plaza A., Spatial preprocessing for endmember extraction, *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47** (8), 2679-2693.

- [24] Martin G., Plaza A., Region-based spatial preprocessing for endmember extraction and spectral unmixing, *IEEE Geoscience and Remote Sensing Letters*, 2011, **8** (4), 745-749, 2011.
- [25] Martin G., Plaza A., Spatial-spectral preprocessing prior to endmember identification and unmixing of remotely sensed hyperspectral data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, **5** (2), 380-395.
- [26] Ball G. H., Hall D. J., ISODATA: a novel method of data analysis and pattern classification, *Stanford University*, AD-699616, 1-61, 1965.
- [27] Hartigan J. A., Wong M. A., Algorithm AS 136: A k-means clustering algorithm, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 1979, **28** (1), 100-108.
- [28] Tilton J. C., Analysis of hierarchically related image segmentations, *IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data*, Greenbelt, Maryland, U.S.A., 27-28 October 2003.
- [29] Matteoli S., Diani M., Corsini G., A tutorial overview of anomaly detection in hyperspectral images, *IEEE A&E Systems Magazine*, 2010, **25** (7), 5-27.
- [30] Reed I. S., Yu X., Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution, *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1990, **38** (10), 1760-1770.
- [31] Stein D. W. J., Beaven S. G., Hoff L. E., Winter E. M., Shaum A. P., Stocker A. D., Anomaly detection from hyperspectral imagery, *IEEE Signal Processing Magazine*, 2002, **19** (1), 58-69.
- [32] Chang C.-I., Chang S.-S., Anomaly detection and classification for hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40** (6), 1314-1325.
- [33] Kwon H., Nasrabandi N., Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**, 388-397.
- [34] Schököpf B., Smola A. J., *Learning with kernels*, The MIT Press, Cambridge, Massachusetts, U.S.A., 2002.
- [35] Kruse F. A., Lefkoff A. B., Boardman J. B., Heidebrecht K. B., Shapiro A. T., Barloon P. J., Goetz A. F. H., The spectral image processing system (SIPS) – interactive visualization and analysis of imaging spectrometer data, *Remote Sensing of Environment*, **44**, 145-163.
- [36] Keshava N., Mustard J. F., Spectral unmixing, *IEEE Signal Processing Magazine*, 2002, **19** (1), 44-57.

- [37] Hapke B., *Theory of reflectance and emittance spectroscopy*, Cambridge University Press, Cambridge, United Kingdom, 1993.
- [38] Plaza J., Plaza A., Martinez P., Perez R., Joint linear/nonlinear spectral unmixing of hyperspectral image data, *IEEE International Geoscience and Remote Sensing Symposium*, Barcelona, Spain, 23-28 July 2007.
- [39] Settle J. J., Drake N. A., Linear mixing and estimation of ground cover proportions, *International Journal of Remote Sensing*, 1993, **14** (6), 1159–1177.
- [40] Heinz D. C., Chang C.-I, Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **39** (3), 529-545.
- [41] Chang C.-I, Heinz D. C., Constrained subpixel target detection for remotely sensed imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2000, **38** (3), 1144-1159.
- [42] Petrou M., Foschi P. G., Confidence in linear spectral unmixing of single pixels, *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37** (1), 624-626.
- [43] Foody G. M., Cox D. P., Sub-pixel land cover composition estimation using a linear mixture model and fuzzy membership functions, *International Journal of Remote Sensing*, 1994, **15**, 619-631.
- [44] Foody G. M., Estimation of sub-pixel land cover composition in the presence of untrained classes, *Computers & Geosciences*, 2000, **26**, 469-478.
- [45] Silvan-Cardenas J. K., Wang L., Fully constrained linear spectral unmixing: analytic solution using fuzzy sets, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48** (11), 3992-4002.
- [46] Krinidis S., Chatzis V., A robust fuzzy local information c-means clustering algorithm, *IEEE Transactions on Image Processing*, 2010, **19** (5), 1328-1337.
- [47] Zare A., Spatial-spectral unmixing using fuzzy local information, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Vancouver, Canada, 24-29 July 2011.
- [48] Zare A., Gader P., Piece-wise convex spatial-spectral unmixing of hyperspectral imagery using possibilistic and fuzzy clustering, *Proceedings of IEEE International Conference on Fuzzy Systems*, 2011, 741-746.
- [49] Nascimento J. M. P., Bioucas-Dias J. M., Nonlinear mixture model for hyperspectral unmixing, *Image and Signal Processing for Remote Sensing XV, Proceedings of SPIE*, Berlin, Germany, 31 August 2009.
- [50] Borel C. C., Gerstl S. A. W., Nonlinear spectral mixing model for vegetative and soil surfaces, *Remote Sensing of Environment*, 1994, **47** (3), 403-416.

- [51] Raksuntorn N., Du Q., Nonlinear spectral mixture analysis for hyperspectral imagery in an unknown environment, *IEEE Geoscience and Remote Sensing Letters*, 2010, **7** (4), 836–840.
- [52] Somers B., Cools K., Delalieux S., Stuckens J., derZande D. V., Verstraeten W. W., Coppin P., Nonlinear hyperspectral mixture analysis for tree cover estimates in orchards, *Remote Sensing of Environment*, 2009, **113**, 1183–1193.
- [53] Fan W., Hu B., Miller J., Li M., Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data, *International Journal of Remote Sensing*, 2009, **30** (11), 2951–2962.
- [54] Halimi A., Altmann Y., Dobigeon N., Tournieret J.-Y., Nonlinear unmixing of hyperspectral images using a generalized bilinear model, *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **11**, 4153–4162.
- [55] Altmann Y., Dobigeon N., Tournieret J.-Y., Bilinear models for nonlinear unmixing of hyperspectral images, *3rd Workshop on Hyperspectral Image Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Lisbon, Portugal, 6-9 June 2011.
- [56] Hapke B. W., Bidirectional reflectance spectroscopy. I. theory, *Journal of Geophysical Research*, 1981, **86**, 3039-3053.
- [57] Broadwater J., Chellappa R., Banerjee A., Burlina P., Kernel fully constrained least squares abundance estimates, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Barcelona, Spain, 23-27 July 2007.
- [58] Liu K., Chang C.-I, Du Y., Kernel-based linear spectral mixture analysis for hyperspectral image classification, *First Workshop on Hyperspectral Image Signal Processing – Evolution in Remote Sensing (WHISPERS)*, Grenoble, France, 26-28 August 2009.
- [59] Liu K., Wong E., Dy Y., Chen C. C.-C., Chang C.-I, Kernel-based linear spectral mixture analysis, *IEEE Geoscience and Remote Sensing Letters*, 2012, **9** (1), 129-133.
- [60] Broadwater J., Banerjee A., A comparison of kernel functions for intimate mixture models, *First Workshop on Hyperspectral Image Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Grenoble, France, 26-28 August 2009.
- [61] Broadwater J., Banerjee A., A generalized kernel for areal and intimate mixtures, *2nd Workshop on Hyperspectral Image Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Reykjavik, Iceland, 14-16 June 2010.
- [62] Broadwater J., Banerjee A., Mapping intimate mixtures using an adaptive kernel-based technique, *3rd Workshop on Hyperspectral Image Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Lisbon, Portugal, 6-9 June 2011.

- [63] Guilfoyle K. J., Althouse M. L., Chang C.-I., A quantitative and comparative analysis of linear and nonlinear spectral mixture models using radial basis function neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39** (8), 2314–2318.
- [64] Plaza J., Plaza A., Spectral mixture analysis of hyperspectral scenes using intelligently selected training samples, *IEEE Geoscience and Remote Sensing Letters*, 2010, **7**, 371–375.
- [65] Licciardi G., Del Frate F., Pixel unmixing in hyperspectral data by means of neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49** (11), 4163–4172.
- [66] Licciardi G., Marpu P. R., Chanussot J., Benediktsson J. A., Linear versus nonlinear pca for the classification of hyperspectral data based on the extended morphological profiles, *IEEE Geoscience and Remote Sensing Letters*, 2012, **9** (3), 447–451.
- [67] Altmann Y., Halimi A., Dobigeon N., Tournet J.-Y., Supervised nonlinear spectral unmixing using a postnonlinear mixing model for hyperspectral imagery, *IEEE Transactions on Image Processing*, 2012, **21** (6), 3017–3025.
- [68] Heylen R., Burazerovic D., Scheunders P., Non-linear spectral unmixing by geodesic simplex volume maximization, *IEEE Journal of Selected Topics in Signal Processing*, 2011, **5** (3), 534–542.
- [69] Close R., Gader P., Wilson J., Using physics-based macroscopic and microscopic mixture models for hyperspectral pixel unmixing, *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII, Proceedings of SPIE*, Baltimore, U.S.A., 8 May 2012.
- [70] Liu K., Chang C.-I., Exploration of component analysis in multi/hyperspectral image processing, *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIV, Proceedings of SPIE*, Orlando, Florida, U.S.A., 16 March 2008.
- [71] Atkinson P. M., Mapping sub-pixel boundaries from remotely sensed images, *Innov. GIS*, 1997, **4**, 166–180.
- [72] Aplin P., Atkinson P. M., Sub-pixel land cover mapping for per-field classification, *International Journal of Remote Sensing*, 2001, **22**, 2853–2858.
- [73] Verhoeve J., De Wulf R., Land cover mapping at sub-pixel scales using linear optimization techniques, *Remote Sensing of Environment*, 2002, **79** (1), 96–104.
- [74] Tatem A. J., Lewis H. G., Atkinson P. M., Nixon M. S., Super-resolution target identification from remotely sensed images using a Hopfield neural network, *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39** (4), 781–796.

- [75] Atkinson P. M., Super-resolution land cover classification using geostatistical optimization, *GeoENV IV - Geostatistics for environmental applications*, Editors: Sanchez-Villa X., Carrera J., Gomez-Hernandez J. J., 1st ed., Kluwer, Dordrecht, The Netherlands, 2003.
- [76] Mertens K. C., Verbeke L. P. C., Ducheyne E. I., De Wulf R. R., Using genetic algorithms in sub-pixel mapping, *International Journal of Remote Sensing*, 2003, **24** (21), 4241–4247.
- [77] Mertens K. C., Verbeke L. P. C., Westra T., De Wulf R. R., Subpixel mapping and sub-pixel sharpening using neural network predicted wavelet coefficients, *Remote Sensing of Environment*, 2004, **91** (2), 225–236.
- [78] Mianji F. A., Zhang Y., Gu Y., Resolution enhancement of hyperspectral images using a learning-based super-resolution mapping technique, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Cape Town, South Africa, 12-17 July 2009.
- [79] Villa A., Chanussot J., Benediktsson J. A., Ulfarsson M., Jutten C., Super-resolution: an efficient method to improve spatial resolution of hyperspectral images, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Vancouver, Canada, 24-29 July 2011.
- [80] Villa A., Chanussot J., Benediktsson J. A., Jutten C., Spectral unmixing for the classification of hyperspectral images at a finer resolution, *IEEE Journal of Selected Topics in Signal Processing*, 2011, **5** (3), 521-533.
- [81] Villa A., Chanussot J., Benediktsson J. A., Jutten C., Dambreville R., Unsupervised methods for the classification of hyperspectral images with low spatial resolution, *Pattern Recognition*, 2013, **46**, 1556-1568.
- [82] Nquyen M. Q., Atkinson P. M., Lewis H. G., Superresolution mapping using a Hopfield neural network with fused images, *IEEE Transactions on Geoscience and Remote Sensing*, 2006, **44** (3), 736-749.
- [83] Metropolis N., Rosenbluth A. W., Rosenbluth M. N., Teller A. H., Teller E., Equations of state calculations by fast computing machines, *Journal of Chemistry and Physics*, 1958, **21**, 1087-1092.
- [84] Kirkpatrick S., Gelatt C. D., Vecchi M. P., Optimization by simulated annealing, *Science*, 1993, **220**, 671-680.
- [85] Kennedy J., Eberhart R., Particle swarm optimization, *IEEE International Conference on Neural Networks*, Perth, Australia, 27 November-1 December 1995.
- [86] Wei C., Xu-chu Y., Bing-gong W., PSO-GA endmember extraction for hyperspectral imagery, *International Conference on Computer Application and System Modelling (ICCASM)*, Taiyuan, China, 22-24 October 2010.

- [87] Maneiro M., XiaoJian X., Particle swarm optimization for unmixing hyperspectral image, *IEEE 10th International Conference on Signal Processing (ICSP)*, Beijing, China, 24-28 October, 2010.
- [88] Kennedy J., Spears W. M., Matching algorithms to problems: an experimental test of the particle swarm and some genetic algorithms on the multimodal problem generator, *IEEE International Conference on Evolutionary Computation*, Anchorage, Alaska, U.S.A., 4-9 May 1998.
- [89] Kennedy J., Eberhart R. C., A discrete binary version of the particle swarm optimization, *IEEE International Conference on Systems, Man, and Cybernetics*, Orlando, Florida, U.S.A., 12-15 October 1997.
- [90] Afshinmanesh F., Marandi A., Rahimi-Khan A., A novel binary particle swarm optimization method using artificial immune system, *The International Conference on Computer as a Tool (EUROCON)*, Belgrade, Serbia & Montenegro, 21-24 November 2005.
- [91] Khanesar M. A., Teshnehlab M., Shoorehdeli M. A., A novel binary particle swarm optimization, *15th Mediterranean Conference on Control & Automation*, Athens, Greece, 27-29 June 2007.
- [92] Jun X., Chang H., The discrete binary version of the improved particle swarm optimization algorithm, *International Conference on Management and Service Science (MASS)*, Wuhan, China, 20-22 September 2009.
- [93] Chen E., Pan Z., Sun Y., Liu X., A binary particle swarm optimization based on proportion probability, *Third International Conference on Business Intelligence and Financial Engineering (BIFE)*, Hong Kong, China, 13-15 August 2010.
- [94] Goel P. K., Prasher S. O., Patel R. M., Landry J. A., Bonnell R. B., Viau A. A., Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn, *Computers and Electronics in Agriculture*, 2003, **39** (2), 67-93.
- [95] Yang H., Meer F. V. D., Bakker W., Tan Z. J., A back-propagation neural network for mineralogical mapping from AVIRIS data, *International Journal of Remote Sensing*, 1999, **20** (1), 97-110.
- [96] Vaiphasa C., Innovative genetic algorithm for hyperspectral image classification, *International Conference on Map Asia*, Kuala Lumpur, Malaysia, 13-15 October 2003.
- [97] Camps-Valls G., Bruzzone L., Kernel-based methods for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43** (6), 1351-1362.

- [98] Gualteri J. A., Cromp R. F., Support vector machines for hyperspectral remote sensing classification, *27th AIPR Workshop: Advances in Computer-Assisted Recognition, Proceedings of SPIE*, Washington, D.C., U.S.A., 14 October 1998.
- [99] Fauvel M., Chanussot J., Benediktsson J. A., Evaluation of kernels for multiclass classification of hyperspectral remote sensing data, *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Toulouse, France, 15-19 May 2006.
- [100] 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*, 2005, **43** (7), 1617-1634.
- [101] Tarabalka Y., Benediktsson J. A., Chanussot J., Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques, *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47** (8), 2973-2987.
- [102] 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, *Proceedings of the Royal Society of London, Series A: Mathematical and Physical Sciences*, 1998, **454** (1971), 903-995.
- [103] Demir B., Ertürk S., Empirical mode decomposition pre-process for higher accuracy hyperspectral image classification, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Boston, Massachusetts, U.S.A., 6-11 July 2008.
- [104] Demir B., Ertürk S., An empirical mode decomposition and composite kernel approach to increase hyperspectral image classification accuracy, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Cape Town, South Africa, 12-17 July 2009.
- [105] Demir B., Ertürk S., Empirical mode decomposition of hyperspectral images for support vector machine classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48** (11), 4071-4084.
- [106] Tsai F., Philpot W. D., A derivative-aided hyperspectral image analysis system for land-cover classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40** (2), 416-425.
- [107] Demir B., Ertürk S., Spectral magnitude and spectral derivative feature fusion for improved classification of hyperspectral images, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Boston, Massachusetts, U.S.A., 6-11 July 2008.
- [108] Kalluri R., Prasad S., Bruce L. M., Decision-level fusion of spectral reflectance and derivative information for robust hyperspectral land cover classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48** (11), 4047-4058.

- [109] Zhang J., Rivard B., Sanchez-Azofeifa A., Derivative spectral unmixing of hyperspectral data applied to mixtures of lichen and rock, *IEEE Transactions on Geoscience and Remote Sensing*, 2004, **42** (9), 1934–1940.
- [110] Othman H., Qian S.-E., Noise reduction of hyperspectral imagery using hybrid spatial-spectral derivative-domain wavelet shrinkage, *IEEE Transactions on Geoscience and Remote Sensing*, 2006, **44** (2), 397–408.
- [111] Nunes J. C., Bouaoune Y., Delechelle E., Niang O., Bunel P., Image analysis by bidimensional empirical mode decomposition, *Image Video Computation*, 2003, **21** (12), 1019–1026.
- [112] Linderhed A., Compression by image empirical mode decomposition, *IEEE International Conference on Image Processing (ICIP)*, Genoa, Italy, 11-14 September 2005.
- [113] Koh M.-S., Rodriguez-Marek E., Fisher T. R., A new two dimensional empirical mode decomposition for images using inpainting, *IEEE 10th International Conference on Signal Processing (ICSP)*, Beijing, China, 24-28 October 2010.
- [114] Diop E. H. S., Alexandre R., Boudraa A.-O., A PDE model for 2D intrinsic mode functions, *16th IEEE International Conference on Image Processing (ICIP)*, Cairo, Egypt, 7-10 November 2009.
- [115] Diop E. H. S., Alexandre R., Boudraa A.-O., Analysis of intrinsic mode functions: A PDE approach, *IEEE Signal Processing Letters*, 2010, **17** (4), 398–401.
- [116] Holland J., *Adaptation in Natural and Artificial Systems*, University of Michigan Press, Michigan, U.S.A., 1975.
- [117] Ng S. C., Leung S. H., Chung C. Y., Luk A., Lau W. H., The genetic search approach—A new learning algorithm for adaptive IIR filtering, *IEEE Signal Processing Magazine*, 1996, **13** (6), 38–46.
- [118] Kopsinis Y., McLaughlin S., Investigation and performance enhancement of the empirical mode decomposition based on a heuristic search optimization approach, *IEEE Transactions on Signal Processing*, 2008, **56** (1), 1–13.
- [119] Tang J., Zhao L., Yue H., Chai T., Yu W., Spectral kernel principal component selection based on empirical mode decomposition and genetic algorithm for modeling parameters of ball mill load, *International Conference on Intelligent Computation Technology and Automation (ICICTA)*, Guandong, China, 28-29 March 2011.
- [120] Jiang H., Ma J., Li Q., Yang Y., Research of end effects in Hilbert–Huang transform based on genetic algorithm and support vector machine, *International Conference on Information Systems (ICIS)*, Saint Louis, Missouri, U.S.A., 12-15 December, 2010.

- [121] Chang C.-I, Recent advances in hyperspectral signal and image processing, *Transworld Research Network*, Kerala, India, 2006.
- [122] Jimenez L. O., Landgrebe D. A., Hyperspectral data analysis and supervised feature reduction via projection pursuit, *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37** (6), 2653-2667.
- [123] Bhattacharyya A., On a measure of divergence between two statistical populations defined by their probability distributions, *Bulletin of the Calcutta Mathematical Society*, 1943, **35**, 99–109.
- [124] Tarabalka Y., Benediktsson J. A., Chanussot J., Tilton J. C., Multiple spectral-spatial classification approach for hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48** (11), 4122-4132.
- [125] Bazi Y., Melgani F., Gaussian process approach to remote sensing, *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48** (1), 186-197.
- [126] Serpico S. B., Moser G., Extraction of spectral channels from hyperspectral images for classification purposes, *IEEE Transactions on Geoscience and Remote Sensing*, 2007, **45** (2), 484-495.

KİŞİSEL YAYINLAR ve ESERLER

- [1] **Ertürk A.**, Güllü M. K., Ertürk S., Hyperspectral image classification using empirical mode decomposition with spectral gradient enhancement, *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51** (5), 2787-2798.
- [2] **Ertürk A.**, Çeşmeci D., Gerçek D., Güllü M. K., Ertürk S., Integrating anomaly detection to spatial preprocessing for endmember extraction of hyperspectral images, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Melbourne, Australia, 21-26 July 2013.
- [3] **Ertürk A.**, Çeşmeci D., Gerçek D., Güllü M. K., Ertürk S., Hiperspektral görüntüler için anomali ve homojen bölge gözetin son eleman çıkarımı, 21. *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU)*, Girne, Kıbrıs, 24-26 Nisan 2013.
- [4] **Ertürk A.**, Güllü M. K., Ertürk S., Hyperspectral image classification with spectral gradient enhancement for empirical mode decomposition, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Munich, Germany, 22-27 July 2012.
- [5] **Ertürk A.**, Güllü M. K., Ertürk S., Hiperspektral görüntü sınıflandırması için spektral iyileştirmeli ampirik kip ayrıştırması tabanlı yaklaşım, 20. *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU)*, Muğla, Türkiye, 18-20 Nisan 2012.

ÖZGEÇMİŞ

Alp Ertürk lisans ve yüksek lisans derecelerini sırasıyla 2007 ve 2010 yıllarında Orta Doğu Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden aldı. 2010 yılından beri Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda Araştırma Görevlisi olarak görev yapmaktadır. İlgili alanları arasında görüntü işleme, uzaktan algılama ve örüntü tanıma sayılabilir.