

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI**

YÜKSEK LİSANS TEZİ

**UZAMSAL VE SPEKTRAL ÖZNELİKLERİ KAYNAŞIMI
KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLER İÇİN
DEĞİŞİM TESPİTİ**

AHMED ALRAIMI

KOCAELİ 2016

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

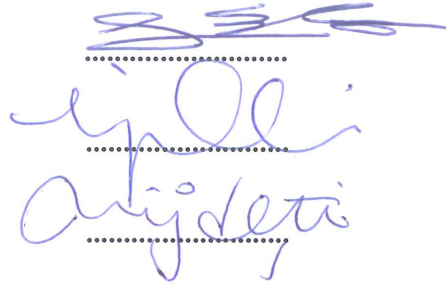
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

UZAMSAL VE SPEKTRAL ÖZNETELİKLERİ KAYNAŞIMI
KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLER İÇİN
DEĞİŞİM TESPİTİ

AHMED ALRAIMI

Prof.Dr. Sarp ERTÜRK
Danışman, Kocaeli Üniv.
Doç.Dr. Kemal GÜLLÜ
Jüri Üyesi, Kocaeli Üniv.
Doç.Dr. Müjdat ÇETİN
Jüri Üyesi, Sabancı Üniv.


.....
.....
.....

Tezin Savunulduğu Tarih: 29.12.2016

ÖNSÖZ VE TEŞEKKÜR

Bu tezdeki açıklanan çalışma uzamsal ve spektral öznitelikleri her ikisinin bir kaynaştırma yaklaşımı kullanılarak hiperspektral görüntüler için değişim tespiti gelişimi herkese faydalı olmasını ve bu konularda çalışacak kişilere yol gösterici olmasını temenni ederim.

Yüksek lisans eğitim boyunca bana desteklerini esirgemeyen, yoğun çalışma temposuna rağmen beni hiç geri çevirmeyen ve bana katlanan, ve zorlandığım anlarda problemleri çözmeme yardımcı olan değerli hocam ve danışmanım sayın Prof. Dr. Sarp Ertürk'e teşekkürlerimi sunarım. Bu tezi yazmama çok yardımcı ve bana motiv olan değerli sayın Yard. Doç. Dr. Alp Ertürk'e ve sayın Araştırma göre. Ersin Özüağ 'a çok teşekkür ederim.

Bana bütün ömrüm boyunca destek verip sahip çıkan ve akademik hayatıma destekleyen, haklarını asla ödeyemeyeceğim sevgili Annem ve Babam, bana sahip çıkan zor günlerde bana çok destek veren ve her zaman bana motiv olan sevgilim, ruh ikizim, değerli eşim Yasmeen, hayatımı renklendiren, gönülüm benim evladım Rayyan başta olmak üzere tüm ailem ve benim bugünlere gelmeme katkısı olan tüm dostlarıma teşekkürü borç bilirim ve size minnetlerimi arz ederim.

Haziran – 2016

Ahmed ALRAİMİ

İÇİNDEKİLER

ÖNSÖZ ve TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLOLAR DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
ÖZET.....	viii
ABSTRACT	ix
GİRİŞ	1
1. GENEL KAVRAMLAR AÇIKLAMASI.....	4
1.1.Hiperspektral Görüntüleme.....	4
1.1.1. Hiperspektral görüntülerin sunduğu bilgiler	5
1.1.2. Hiperspektral görüntüleme uygulamaları.....	6
1.1.3. Hiperspektral görüntüler ile normal görüntülerin karşılaştırması	7
1.2.Hiperspektral Görüntülerde Boyut İndirgeme	7
1.2.1. Öznitelik çıkartımı	8
1.2.2. Bant seçimi.....	10
1.3.Yerel İkili Desen (LBP)	14
1.4.Gabor Filtresi	15
1.5.LBP ve Gabor Filtresinin Karşılaştırılması.....	17
1.6.Değişim Tespiti	19
1.6.1. Spektral açışleme (SAM)	19
2. HİPERSPEKTRAL GÖRÜNTÜLERDE DEĞİŞİM TESPİTİNE GİRİŞ	22
2.1.Yığılmış Çok Zamanlı Hiperspektral Görüntü Tabanlı Değişim Tespiti.....	23
2.2.Altuzay Tabanlı Değişim Tespiti	24
2.3.Karışım Giderimi Tabanlı Hiperspektral Değişim Tespiti.....	25
2.4.Spektral ve Uzamsal Bilgilerin Kaynaşımı Tabanlı Değişim Tespiti	26
2.5.Değişim Tespiti için Uzamsal-Spektral Çarpaz-Korelasyon	26
2.6.Değişim Tespiti için Çoklu Sınıflandırma Sistemi ve Uzamsal- Spektral Öznitelikleri Kullanımı	27
3. UZAMSAL ve SPEKTRAL ÖZİNİTELİKLERİ KAYNAŞIMI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLER İÇİN DEĞİŞİM TESPİTİ.....	28
3.1.Tezde Önerilen Değişim Tespiti Yaklaşımı.....	28
3.1.1. Bant seçimi.....	30
3.1.2. Uzamsal – spektral öznitelik çıkartımı.....	34
3.1.3. Özniteliklerin kaynaştırılması	35
3.1.4. SAM kullanarak değişim tespiti.....	35
3.2.Deneysel Sonuçlar.....	35
3.2.1. Deneysel veriler	35
3.2.2. Deneysel sonuçlar	37

4. SONUÇ VE ÖNERİLER	42
KAYNAKLAR	43
KİŞİSEL YAYINLAR VE ESERLER	47
ÖZGEÇMİŞ	48



ŞEKİLLER DİZİNİ

Şekil 1.1.	Bir hiperspektral veri küpünün iki boyutlu projeksiyonu	4
Şekil 1.2.	Farklı bitkilerin yansıtma (reflektans) spektrumları.....	6
Şekil 1.3.	Hiperspektral görüntü için ön işlenmiş boyut indirgeme	9
Şekil 1.4.	HLFE ile Washington, DC Mall üç sınıflı sonuçları.....	11
Şekil 1.5.	LBP (M = 8, R = 1) operatörü	15
Şekil 1.6.	Farklı LBP operatörler örnekleri	15
Şekil 1.7.	Farklı yönlerde 2 boyutlu Gabor çekirdekleri	17
Şekil 1.8.	LBP ve Gabor filtresi örneği (a) Giriş görüntü (b) LBP kodlanmış görüntü (c) Gabor özneliklerinin görüntüsü $\theta = 0$ (D) Gabor özneliklerinin görüntüsü $\theta = \pi / 4$ (E) Gabor özneliklerinin görüntüsü $\theta = \pi/2$ (F) Gabor özneliklerinin görüntüsü $\theta = 5\pi/4$	18
Şekil 1.9.	Değişim tespiti gösterimi	20
Şekil 1.10.	Spektral açının temsili gösterimi	21
Şekil 2.1.	Altuzay mesafesi gösterimi	24
Şekil 2.2.	İki farklı veri kümesinin değişim tespiti sonuçlarının ROC eğrileri	25
Şekil 3.1.	Tezde önerilen yöntemin akış şeması.....	29
Şekil 3.2.	Indian Pines verileri kullanılarak farklı bant sayıları için SVM sınıflandırma başarımı.....	30
Şekil 3.3.	Indian Pines verisi için LPE ile seçilen bantlar	33
Şekil 3.4.	LBP ile öznelik çıkartımı	34
Şekil 3.5.	Veri setleri ve değişim yer doğrusu haritaları (a-b) Pavia Uni(c-d) Indian Pines (e-f) Salinas	36
Şekil 3.6.	Indian Pines için değişim tespiti ROC	38
Şekil 3.7.	Pavia University için değişim tespiti ROC	38
Şekil 3.8.	Salinas için değişim tespiti ROC.....	39
Şekil 3.9.	Indian Pines için AUC.....	40
Şekil 3.10.	Pavia University için AUC.....	40
Şekil 3.11.	Salinas için AUC	41

TABLULAR DİZİNİ

Tablo 1.1. Hiperspektral Görüntüler ile Normal Görüntülerin karşılaştırması	7
Tablo 3.1. Sentetik görüntülerin değiştirilmiş seçilen sınıflar	37



SİMGELER VE KISALTMALAR DİZİNİ

a	: LPE Enküçükleme Parametre Vektörü
b	: SAM için Bant Sayısı
B	: LPE için En Farklı Bant Hedefi
bw	: Gabor Uzamsal Frekans Bant Genişliği
e	: Doğrusal Tahmin Hatası Kestirimi
I	: Özdeş Matris
LBP_M	: LBP Yerel Komşu Piksellerinin Sayısı
LBP_R	: LBP Yerel Komşu Yarıçapı
N	: Piksel Sayısı
P	: Dikgen Altuzay
r	: SAM Referans Pixel Spektrumu
t	: SAM Hedef Pixel Spektrumu
X	: LPE için Bantların 3 Sütun Matrisi
Z	: OSP için Bantların 2 Sütun Matrisi
B'	: B'nin LPE Kestirimi
T_c	: LBP Orta Pikselin Değeri
X^T	: X'in Transpozesi
Y_0	: Dikgen Altuzaylar Projeksiyonu
Z^T	: Z'in Transpozesi
α	: SAM Spektral Açısı
γ	: Gabor Fonksiyonun Uzamsal En-Boy Oranı
θ	: Gabor Fonksiyonunun Normal Ve Paralel Çizgilerinin Yönü
λ	: Gaborda Sinüzoidal Faktörün Dalga Boyu
σ	: Gaborda Gauss Zarfının Standart Sapması
Φ	: Seçilen Bantların Alt Kümesi
ψ	: Gaborda Faz Ofseti

Kısaltmalar

ACE	: Adaptive Coherence/Cosine Estimator (Adaptif Tutarlılık / Kosinüs Kestiricisi)
AUC	: Area Under Curve (Eğrinin Altındaki Alanı)
AVIRIS	: Airborne Visible-Infra Red Imaging Spectrometer (Havadan Görülebilir / Kızılötesi Görüntüleme Spektrometresi)
CVA	: Change Vector Analysis (Değişim Vektör Analizi)
FF	: Feature Fusion (Özniteliklerin Kaynaştırılması)
FSD	: First Spectral Derivative (Birinci Spektral Türevi)
HLFE	: Hurst and Lyapunov Exponents Feature Extraction (Hurst and Lyapunov Üs Değerleri Öznitelik Çıkartımı)
HOG	: Histogram of Oriented Gradient (Yönelimli Gradyent Histogramı)
HSI	: HyperSpectral Image (Hiperspektral Görüntü)
ICA	: Independent Component Analysis (Bağımsız Bileşen Analizi)

LBP	: Local Binary Pattern (Yerel İkili Deseni)
LPE	: Linear Prediction Error (Doğrusal Tahmin Hatası)
OSP	: Orthogonal Subspace Projection (Dikgen Altuzaylar Projeksiyonu)
PCA	: Principal Component Analysis (Temel Bileşenler Analizi)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristik)
SAM	: Spectral Angle Mapper (Spektral Açık Eşleme)
SCD	: Subspace-Based Change Detection (Altuzay Tabanlı Değişim Tespiti)
SNR	: Signal to Noise Ratio (Sinyal Gürültü Oranı)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
USS	: Uniform Spectral Spacing (Düzgün Spektral Aralığı)
VD	: Virtual Dimensionality (Sanal Boyut)



UZAMSAL VE SPEKTRAL ÖZNELİKLERİ KAYNAŞIMI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLER İÇİN DEĞİŞİM TESPİTİ

ÖZET

Uzaktan algılama verilerindeki deęişimleri tespit etmek için sadece spektral imza kullanıldığında yerel ve konum tabanlı uzamsal öznitelikler tarafından sağlanan zengin bilgiler göz ardı edilirken bu durum, deęişim tespitinde deęerli bilgilerin kullanılmaması anlamına gelmektedir. Bu yüzden bu tezde, hem hiperspektral görüntülerdeki doku ile zengin bilgileri hem de spektral imzaları kullanmak için yeni bir deęişim tespiti yöntemi önerilmiştir.

Deneyisel sonuçlar, görüntü deęişiklikleri tespit etmek için Spektral Açık Eşleme (Spectral Angle Mapper SAM) yeteneğini geliştirmek için bantlar doku bilgisini kullanarak etkili bir yöntem olduğunu göstermiştir. Üstelik hiperspektral görüntüler (hyperspectral image HSI) veri setleri elde edilen sonuçları önerilen yöntemin bazı muhtemel alternatiflerden daha üstün olduğunu göstermektedir.

Anahtar Kelimeler: Gabor Filtresi, Hiperspektral Görüntü, Spektral Açık Eşleme (SAM), Yerel İkili Örüntü.

CHANGE DETECTION FOR HYPERSPECTRAL IMAGES USING SPATIAL AND SPECTRAL FEATURES FUSION

ABSTRACT

Considering spectral signatures to detect changes in remote sensing data, while ignoring the rich information provided by the local and global spatial features may lead to the problem of losing valuable information that can help in the process of change detection. Thus in this thesis, a change detection paradigm to utilize both the rich texture information - extracted by Local Binary Pattern (LBP) and Gabor filter - and the spectral signatures in hyperspectral images is proposed.

Experimental results have demonstrated that utilizing bands texture information is an effective method to increase the ability of Spectral Angle Mapper (SAM) to detect changes in the images. Moreover, results on several hyperspectral image HSI data sets show that the proposed framework is superior to some possible alternatives.

Key words: Gabor Filter, Hyperspectral Image, Spectral Angle Mapper (SAM), Local Binary Pattern.

GİRİŞ

1980'lerde Goetz ekibi ile Jet Propulsion Laboratory'de, yeni bir tür uzaktan algılama aracı geliştirdiğinde, dünyada uzaktan algılama alanında bir devrim yaşanmıştır. Bu araç AVIRIS “Airborne Visible-Infra Red Imaging Spectrometer” olarak adlandırılmıştır. Bu araç, hiperspektral sensörleri kullanarak uzaktan algılama ile yeryüzünün belirli bir sahnesi için farklı dalga boyunda birçok görüntü yakalamaktadır. AVIRIS algılayıcısında her görüntü 400 - 2400 nm içindeki dalga bandı içerisindeki dar bantlar için yakalanan birçok yansıma görüntüsünden oluşmaktadır. Aviris algılayıcısı Şekil i’de gösterildiği üzere platform olarak uçak kullanmakta ve taramam mantığıyla çalışmaktadır. Hiperspektral görüntülerin taşıdığı zengin spektral bilgi nedeniyle, havacılık mühendisliği, bilimsel uzaktan algılama, uzayın incelenmesi, çevre izleme de dâhil olmak üzere çok farklı alanlarda hiperspektral görüntüler kullanım alanı bulmuştur [12-15].

Hiperspektral görüntüleme çeşitli uygulamalarda geniş bir alanda kullanılır. Hiperspektral görüntüleme aslen madencilik ve jeoloji için geliştirilmiş olmasına rağmen şimdi birçok farklı alanlara yayılmıştır. Hiperspektral görüntüleme teknolojisi bilimsel ve teknolojik gelişmeler sayesinde sürekli olarak herkes tarafından daha fazla kullanılabilir hale gelmektedir. Genel olarak hiperspektral görüntüleme hedef tespiti, malzeme tanıma, malzeme sınıflandırma, yeryüzü özellikleri tespiti, vb alanlarda uygulanmaktadır.

Son zamanlarda, hiperspektral görüntüler (HSI) tarafından sağlanan zengin bilgiler nedeniyle, bu alanda çeşitli uygulamalar için birçok görüntü işleme yöntemi geliştirilmiştir. Bu görüntü işleme tekniklerinin biri değişim tespiti olup, basit anlamda, değişim tespiti farklı zamanlarda aynı sahne için alınan iki veya daha fazla görüntünün arasındaki değişimi yakalamayı amaçlamaktadır. Hiperspektral görüntüler kullanarak değişim tespiti arazi kullanımı ve arazi örtüsü izleme [5], kentsel gelişim [6], ekosistem izleme[7, 8], ve afet izleme [9] gibi pek çok uygulamada önemli bir rol oynamaktadır.

Uzaktan algılama ile deęişim tespiti için farklı yöntemler önerilmiştir. Ancak mevcut çalışmaların çoęu sadece hiperspektral verilerin spektral özniteliklerini kullanmaktadır. Örneęin, doğrudan spektral görüntü bantlarının arasındaki farkı hesaplayıp sonrasında bu fark deęerinin eşiklenmesi ile deęişim tespiti [10,11]'de gösterilmiş olup bu çalışmalarda teelde piksel çiftlerinin spektral bantlardaki seviye deęerlerinin farkı alınarak çalışan deęişim vektör analizi (CVA) kullanılmıştır.

Uzaktan algılama verilerindeki deęişimleri tespit etmek için sadece spektral imza kullanıldığında yerel ve konum tabanlı uzamsal öznitelikler tarafından sağlanan zengin bilgiler göz ardı edilirken bu durum, deęişim tespitinde deęerli bilgilerin kullanılmaması anlamına gelmektedir. Bu yüzden bu tezde, hem hiperspektral görüntülerdeki doku temelli zengin bilgileri hem de spektral imzaları birlikte kullanmak için yeni bir deęişim tespiti yöntemi önerilmiştir. Önerilen yaklaşımda yerel ve uzamsal doku özniteliklerini üretmek amacıyla görüntü bantlarının bir alt kümesi seçilip yerel ikili örüntü (LBP) ve Gabor filtresi kullanılmakta olup öznitelik seçimi teknięi olarak doğrusal tahmin hatası (LPE) [25] kullanımına dayanan bir yöntem önerilmiştir. Daha sonra, tüm LBP, Gabor, ve spektral imzalarını birleştirek hem spektral hem de uzamsal özniteliklerinden yararlanmak amacıyla bir kaynaştırma aşaması uygulanmıştır. Kaynaştırma uygulanmadan önce aynı ölçeęe getirmek için özniteliklerinin normalleştirilmesi gerekmektedir. Son olarak, deęişim tespiti için, Spektral Açık Eşleme (SAM) kullanılmıştır. SAM öznitelikler arasındaki açıyı hesaplayan ve bant sayısı kadar boyutlu öznitelik vektörleri gibi davranan iki vektör arasındaki spektral benzerlięi belirlemektedir. Ayrıntılı bilgi Bölüm 3'de sunulmuştur.

Bu tez aşıęıdaki gibi düzenlenmiştir. Bölüm 1'de, hiperspektral görüntüleme ve uygulamaları gibi kavramlar açıklanarak bu çalışmada belirtilen genel kavramlar tanımlanmıştır. Geliştirilen yöntemin alt basamaklarını teşkil eden boyut indirgeme, Yerel İkili Örüntü (LBP) operatörü, Gabor filtresi ve Spektral Açık Eşleme gibi terim ve yaklaşımlar da bu bölümde ele alınmaktadır.

Hiperspektral görüntüler için kullanılmış olan deęişim tespiti yaklaşımlarından literatürde mevcut ilgili çalışmalar Bölüm 2'de açıklanmıştır. Bu bölümde, kullanım

özelliklerine odaklanarak hem spektral hem de uzamsal deęişim tespiti yaklaşımlarının farklı özellikleri tartışılmıştır.

Bölüm 3'de bu tezde hiperspektral görüntülerde deęişim tespiti için önerilmiş olan uzamsal ve spektral özniteliklerin kaynaştırılmasına dayanan yaklaşım detaylı olarak açıklanmıştır. Bu bölümde yöntemin akış şeması üzerinden önerilen yaklaşım açıklanmaktadır. Bu bölümün sonunda önerilen yaklaşımın deneylerde kullanılan veriler tanıtılarak çıkarılan sonuçlar sunulmaktadır.


Son olarak, bu çalışmada elde edilen sonuçların deęerlendirmelerini bölüm 4'de verilmiştir. Ayrıca gelecek çalışmalar için olası öneriler verilmiştir.



1. GENEL KAVRAMLAR AÇIKLAMASI

1.1. Hiperspektral Görüntüleme

Hiperspektral görüntüleme veya görüntüleme spektroskopisi, hem dijital görüntüleme gücü hem de spektroskopinin bir araya geldiği bir teknolojidir. Hiperspektral görüntülerdeki her piksel farklı dalga boylarındaki dar bantlarda meydana gelen yansımayı temsil eden spektral bilgiye sahiptir. Bu nedenle hiperspektral görüntüler bilgi açısından zengindir. Hiperspektral kameralar değişik spektral bantlardaki yansımaların yoğunluğunu veya ışık parlaklığını algılar. Böylece, hiperspektral görüntüdeki her piksel, dalga boyuna bağlı sürekli bir spektrumu kapsayacak bilgileri barındırmaktadır. Örnek bir hiperspektral görüntü Şekil 1.1’de verilmiştir.



Şekil 1.1. Bir hiperspektral veri küpünün iki boyutlu projeksiyonu [38]

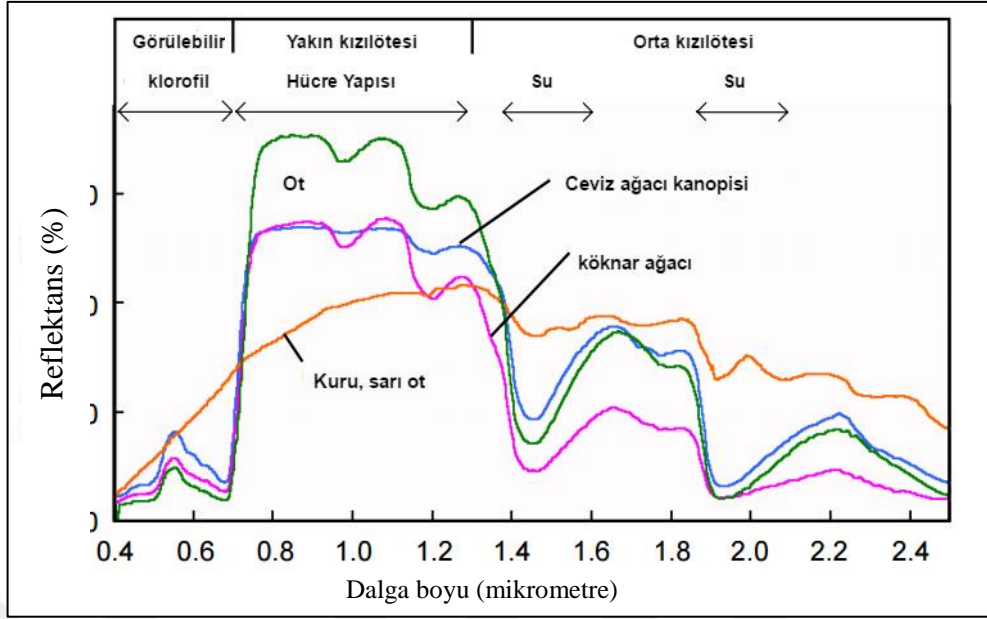
Hiperspektral görüntüler yapı gereği sahne hakkında çok daha detaylı ve kesin bilgi verebilirken, yaygın olarak kullanılan renkli görüntüler sadece üç spektral kanalı (kırmızı, yeşil ve mavi) tespit etmektedir. Bu yüzden, farklı nesnelerin spektral özelliklerine göre sınıflandırılması konusunda hiperspektral görüntüler oldukça etkili çözüm sağlamaktadır.

Havacılık mühendisliği, bilimsel uzaktan algılama, ayın incelenmesi, çevre gözleme de dahil olmak üzere birçok farklı alanda hiperspektral görüntülerin taşıdığı geniş ve zengin spektral bilgilerin kullanılabilirdiği keşfedilmiştir. Ayrıca havadan uzaktan algılama, askeri hedef tespiti, tıp ve biyofizik alanında ve aynı zamanda farklı laboratuvar uygulamaları gibi uygulamalarda da hiperspektral görüntüleme kullanılabilir.

1.1.1. Hiperspektral görüntülerin sunduğu bilgiler

Hiperspektral görüntülerin en temel özelliği spektral yansımadır. Spektral yansıma, gelen enerjinin sahnedeki yansıyan enerjiye oranını dalga boyuna bağlı bir fonksiyon olarak temsil eder. Farklı malzemelerin farklı dalga boylarında gelen enerjiyi dağıtımına veya soğurma dereceleri farklı olup, malzemeler bu özelliklerine göre sınıflandırılabilir. Spektral yansımadaki farklılıklar, farklı malzeme veya sınıfları spektral yansıma eğrilerine (dalga boyuna bağlı spektral yansıma) göre karşılaştırma açısından oldukça faydalıdır. Hiperspektral görüntülerin sınıflandırmasında ayrıca emilim bantları olarak adlandırılan bir kavram vardır. Bu kavrama göre farklı malzemeler seçici bir şekilde gelen enerjiyi bazı bantlarda emerek oluşan spektral eğrinin aşağı yönlü sapmasına yol açarlar. Bu nedenle, spektral eğrinin genel şekli, konumu ve bantlar emilim gücü farklı malzemelerin tespiti ve sınıflandırması açısından faydalı bir şekilde kullanılabilir.

Şekil 1.2’de, bu etkileri göstermek için örnek bitkilerin spektral yansıma eğrileri (kısaca spektrumları) gösterilmiş olup, belirli emilim bantları ve genel spektral eğri yapıları görülmektedir.



Şekil 1.2. Farklı bitkilerin yansıtma (reflektans) spektrumları [3]

1.1.2. Hiperspektral görüntüleme uygulamaları

İlk olarak hiperspektral uzaktan algılama dünya yüzeyindeki mineralleri keşfetmek için kullanılmıştır. Bugünlerdeyse, hiperspektral uzaktan algılama teknolojisi birçok çevresel ve beşeri uygulamada ilgi görmektedir. Örnek uygulamalar olarak arazi ve toprak gözlemi, atmosfer gözlemi (su buharı, bulut özellikleri, aerosoller gibi), çevresel gözlemler, kar ve buz (kar örtüsü fraksiyonu, tane boyutu, erime gibi) sayılabilir. Öte yandan kıyı bölgesi olarak temsil edilen alanlar, plajlar ve bitki örtüleri hiperspektral uzaktan algılama ile incelenebilmektedir. Son zamanlarda, bitki bilimi alanında biyo-jeokimyasal çevrim için gerekli mekanizmaların anlaşılıp yüzey atmosfer (karbon ve hidrolojik döngünün, O₂ ve CO₂ değişimi) etkileşimlerinin tespitinde hiperspektral temelli uzaktan önemli katkılar sağlamaktadır.

Hiperspektral görüntüleme teknolojisi aşağıda verilen birçok uygulamada kullanım alanı bulmaktadır [4].

- Hiperspektral görüntüleme ile maden arama, kaynak yönetimi ve çevre izleme.
- Tarım alanında ürünlerin gelişiminin ve sağlık durumunun izlenmesi
- Jeoloji alanında değerli minerallerin hızlı bir şekilde haritanlaması
- Astronomi alanında uzamsal çözünürlüklü spektral görüntüleri sağlanması
- Askeri alanda kimyasal savaş ajanlarının tespit ve tanımlanması için benzersiz algılama yeteneği sağlanması

- Petrol endüstrisinde yeryüzündeki petrol kaynaklarını belirlemek
- Ekolojide gözetim ve tarihi el yazmalarının araştırılması
- Nano-ilaç dağıtım ve Nanotoksikoloji gibi araştırma alanları
- Bitkisel arařtırmalar, adli tıp, yařam bilimleri, gıda analizi ve mineral arařtırmaları gibi araştırma alanlarında kullanılmaktadır

1.1.3. Hiperspektral görüntüler ile normal görüntülerin karıřılařtırması

Hiperspektral Görüntüler ile Normal Görüntülerin karıřılařtırması Tablo 1.1’de verilmiřtir. Hiperspektral görüntüler spektral özellikleri sayesinde kimyasal bilgiler içeridiğinden görüntü işleme uygulamalarında çok daha etkin çözümler sağlayabilmektedir.

Tablo 1.1. Hiperspektral Görüntüler ile Normal Görüntülerin karıřılařtırması

	Normal Görüntüler	Hiperspektral Görüntüler
Uzamsal Bilgiler	✓	✓
Spektral Bilgiler	×	✓
Kimyasal Bilgiler	×	✓

1.2. Hiperspektral Görüntülerde Boyut İndirgeme

Uzaktan algılamada hiperspektral sensörler kullanılarak yeryüzünün belirli bir sahnesi için birçok görüntü yakalanabilmektedir [15]. Örneğın AVIRIS hiperspektral sisteminde alınan her görüntü 400 - 2400 nm arasındaki dalga boyunda yakalanmış yansımalarından oluşmaktadır. Hiperspektral görüntülerde bulunan zengin spektral bilgi sayesinde yeryüzündeki malzemelerin spektral benzerliklerine göre ayırt edilebilmesi mümkün olmaktadır ve AVIRIS sensörünün ilk uygulamaları da bu yönde olmuştur.

Temel olarak bir hiperspektral görüntüdeki her piksel çok sayıda (genel olarak yüzlerce, bazen binlerce) spektral banttandır. Hiperspektral görüntüler yüksek boyut ve yüksek veri kapasitesi yanı sıra bantlar arası ilintiden dolayı aynı zamanda pek çok ihtiyaç fazlası bilgiye sahip olduğundan farklı sınıflara ait piksellerinin ayrıştırılmasında yüksek boyutlu veri problem yaratabilmektedir.


Örneğin çok sayıda spektral bant ile genelde sınırlı sayıda mevcut olan eğitim örnekleri arasındaki ters oran nedeniyle eğitimi sınıflandırma başarımı düşebilmektedir.

[16]'de belirtildiği üzere, yüksek bant sayısından kaynaklı sorunlara karşı tatmin edici bir sonuç elde edebilmek için yüksek oranda eğitim verisi gereklidir. Ancak, özellikle uzaktan algılama uygulamalarında hiperspektral görüntülerin sınıflandırması için kullanılacak eğitim örneklerinin sayısı sınırlı olabilmektedir. Sınırlı sayıdaki eğitim verisi hiperspektral görüntülerin sınıflandırmasında ve yüksek boyutlu veri analizinde sık karşılaşılan bir sorundur. Yüksek boyutlu veride sınırlı sayıda eğitim verisi olması durumunda, Hughes fenomenine (ya da boyutluluk lanetine) göre algoritma başarımı oldukça düşük olabilmektedir.

Verideki yüksek boyutluluk sorununu aşabilmek için, hiperspektral görüntülerde yapılacak analiz öncesi bir ön işleme adımı olarak boyut indirgeme uygulanabilmektedir. Bu işlem Şekil 1.3'de gösterilmektedir. Boyut indirgeme, verinin düşük boyutlu yapısını çıkartarak hesaplama karmaşıklığını azaltabilmekte ve veri analizi performansını artırarak değişim tespiti ya da sınıflandırma gibi işlemlerin sonuçlarını iyileştirebilmektedir. Yukarıda belirtilen nedenlerden dolayı, boyut indirgeme için öznitelik çıkartımı veya bant seçimi yaklaşımları kullanılmaktadır.

1.2.1. Öznitelik çıkartımı

Karakteristik açıdan (özellik bakımından) benzer yapılar öznitelik olarak tanımlanmaktadır. Öznitelikle görüntü işleme alanında önemli bir rol oynamaktadır. Öznitelik çıkartımı genel olarak bir veriyi temsil etmek üzere kompakt bir sayısal gösterimin elde edilmesi işlemidir.



Şekil 1.3. Hiper spektral görüntü için ön işlenmiş boyut indirgeme [39]

[16]'ye göre görüntü işleme alanında öznitelik çıkartımı işlemi kolay örüntü sınıflandırması yapabilmek için belirli bir örüntü ile şekil bilgilerinin temsil edilmesidir. Örüntü tanıma ve görüntü işleme alanında, öznitelik çıkartımı boyut indirgemenin özel bir formu olarak tanımlanabilmektedir. Orijinal veriden “en alakalı” bilgileri elde etmek ve daha düşük boyutlu uzayda bu bilgileri temsil etmek öznitelik çıkartımının boyut indirgeme aracı olarak kullanılmasındaki ana yaklaşımdır.

Bir algoritma tarafından işlenecek giriş verisi boyutu çok büyük olduğunda veya veride artıklık mevcut olduğunda giriş verisi boyut azaltılmış bir yapıya (öznitelikler vektörü) dönüştürülebilir. Öznitelik çıkartımı bu anlamda giriş verilerinin özellikler kümesi haline dönüşümüdür. Çıkarılan öznitelikler özenle seçilmiş (bilgiyi iyi temsil ediyor) ise istenilen işlevin gerçekleştirilmesi için bu öznitelik kümesinin boyutu giriş verisinin boyutundan küçük olabilmektedir


Nesne tanıma için imgeler üzerinden farklı öznitelik çıkartımı yöntemi literatürde önerilmiş durumdadır: Renk Histogramı Tekniği, Fourier Katsayısı, Morfolojik Öznitelikler, Temel Bileşenler Analizi, Maksimum Eğri Noktaları, İmza Çıkartımı, Dalgacık Fonksiyonları ve Projeksiyon, vb.[17, 27].

Hiperspektral veriler için de literatürde pek çok yöntem özellikle sınıflandırmadan önce veri boyutunu indirgemek için geliştirilmiş olup bu sayede Hughes fenomeni azaltılmaktadır. En yaygın kullanılan eğitimsiz yaklaşımlar temel bileşenler analizi (PCA) [1] ve bağımsız bileşen analizi (ICA) [2] yaklaşımlarıdır. PCA yaklaşımı HSI'nın önemli bilgilerinin temel bileşenler olarak adlandırılan az sayıda banda projeksiyonunu gerçekleştirmekte olup, ancak istenen spektral imzaların vurguladığından emin olunamaktadır. Diğer tarafta ICA yaklaşımı, dönüştürülmüş bileşenlerin mümkün olduğunca bağımsız olmasını sağlamaktadır. Ancak, ICA-tabanlı yöntemlerin karmaşıklığı nedeniyle işlem yükü fazla olabilmektedir. Bu yöntemlerin her pikselin uzamsal bilgisini [2] dikkate almadan bağımsız olarak işlem yapmaları, bu tarz öznitelik çıkarımlarının dezavantajı olarak görülmektedir.

[15]'de, spektrumlar için Hurst ve Lyapunov üstelleri (HLFE) olarak adlandırılan yeni bir eğitimsiz öznitelik çıkartımı yaklaşımı verilmiştir. Bu öznitelikler yerel ve genel spektral profilleri ortaya çıkartan indislerdir. Şekil 1.4.'de örnek bir veri için sonuçlar gösterilmiştir. Öte yandan, bu önerilen yöntem eğitimsiz olduğu için doğrudan sınıflar arası mesafeyi ele almamaktadır. Önemli bir özelliği, iki özniteliğin bütün spektral ölçümlerden elde edilebilmesidir.

1.2.2. Bant seçimi

Bant seçimi hiperspektral görüntülerde boyut indirgeme için yaygın kullanılan basit bir tekniktir. Temel bileşen analizi (PCA) gibi yaklaşımlar öznitelik çıkartmak için kullanılırken, özniteliklerde (düşük boyutlu uzay gösteriminde) bir anlamda orjinal veriler değiştirilmektedir. Bu yüzden, alternatif olarak bant seçimi yaklaşımı kullanılarak sadece orjinal bantlardan bir alt kümesi seçilip orijinal verilerin fiziksel anlamı korunabilmektedir.



Şekil 1.4. HLFE ile Washington, DC Mall üç sınıflı sonuçları [15]

Bant seçimi yöntemleri hiperspektral görüntülerin en önemli bantlarını ayıklamak için genelde yüksek spektral korelasyondan yararlanmaktadır. Değişim tespiti veya sınıflandırma uygulamalarında bant seçimi kullanıldığı zaman başarımda sağlanabilecek olası artış yanı sıra önemli bir faydası işlemsel yükün azalmasıdır.

Literatürde farklı bant seçimi yaklaşımları geliştirilmiştir. Bu yaklaşımlar sınıf bilgisinin varlığına bağlı olarak 2 kategoride incelenebilir:

- **Eğitilmiş bant seçimi:** Bu yaklaşımlarda nesne veya sınıf bilgisi önsel olarak bilinmekte olup bu bilgilerle ilgili en önemli verilerin hangi bantlar tarafından içerildiği tespit edilmektedir. Bu tür yöntemlere örnek olarak Kanonik Analizi [18], Jeffries-Matusita mesafesi [19], ve Bhattacharya mesafesi [20] verilebilir.
- **Eğitimsiz bant seçimi:** Eğitilmiş bant seçimi kullanarak genelde daha iyi sonuçlar sağlanabilmesine rağmen nesne bilgileri her zaman 'önsel' olarak mevcut değildir. Bu durumlarda eğitimsiz yöntemler gereklidir. Değişim tespiti veya sınıflandırma için eğitimsiz bant seçimi kullanımı sadece ayırt edici değil, aynı zamanda bilgi ihtiva eden veri bantlarını elde etmeye çalışmaktadır. Bu alanda değişik yöntemler önerilmiş olup örnek olarak Birinci Spektral Türevi (FSD),

Düzgün Spektral Aralığı (USS) [21], Dikgen Altuzaylar Projeksiyonu (OSP) ve Doğrusal Tahmin Hatası (LPE) [25] verilebilir.

Bant seçimi yöntemlerin çoğu bir bant çiftini karşılaştırmak ve aralarındaki benzerlikleri tespit etmek için ikili arama kullanmaktadır. Benzerlikleri tespit etmek için karşılıklı bilgi, JM mesafesi, uzaysal ilişki gibi ölçütlerin kullanılması mümkündür. Hiperspektral görüntülerdeki çok sayıda bant mevcut olduğundan ikili arama kullanmak önemli ölçüde zaman almakta ve hesapsal yükü arttırabilmektedir. Bu nedenle, hesap yükü açısından bantların arasındaki bant benzerliklerinin ortaklaşa tespit edilmesi ve tek bir bandın diğer çoklu gruplarla birlikte değerlendirilmesine tercih edilmektedir [28].

[26]'ye göre, ortaklaşa arama tabanlı bant seçim algoritmaları üç adımda özetlenebilir:

1. İki adet başlangıç bandı seçilir ve bantların alt kümesi $\Phi = \{\text{Bant 1, Bant 2}\}$ olarak ortaya çıkarılır.
2. Bazı kriterler uygulanıp Φ kümesinden en farklı bant bulunarak bu kümeye eklenir.
3. İstenen bant sayısı elde edilinceye kadar 2. adım tekrarlanır.

Daha iyi ve başarılı sonuçlar alınması için bazı noktalar dikkate alınmalıdır. Düşük işaret-gürültü oranına (SNR) sahip ve su buhari emme bantları baştan ihmal edilmelidir. Sonrasında veriye genelde veri kovaryans matrisi ve Eigen ayrışması kullanılarak beyazlatma uygulanmaktadır. [25]'de verilen sonuçlarda bant seçimi aşamasında görüntüdeki piksellerin tamamı yerine mantıklı sayıdaki bir alt kümesinin (örneğin verinin %5 veya %10'u gibi) kullanılmasının algoritmaların çıktısını etkilemediği bulunmuştur. Ayrıca kullanılacak bant sayısının kestirimim için Sanal Boyut (VD) hesaplaması gibi yaklaşımlar kullanılarak seçimi yapılacak bant sayısının tespit edilmesi mümkündür.

Doğrusal tahmin hatası yaklaşımı, özellikle filtreleme ve konuşma kodlamada kullanılan en küçük kareler yaklaşımında tahmin hatasını en aza indirmeyi hedefleyen doğrusal kestirim katsayılarını belirlemeye çalışan bir yaklaşımdır. Bu durumda, önerilen bant seçimi algoritmasında ilk iki bant seçildikten sonra en farklı

üçüncü bandı bulmak için ilk iki bant kullanılarak aşağıdaki formül (doğrusal kestirim) uygulanarak en farklı bant B tespit edilmektedir.

$$B = a_0 + a_1 \text{Band}_1 + a_2 \text{Band}_2 \quad (1.1)$$

Burada B' doğrusal kestirim sonucu olup, a_0, a_1, a_2 katsayıları LPE $e = \| B - B' \|$ hatasını en aza indirecek şekilde seçilmektedir. Bu nedenle parametre vektörü $a = (a_0 \ a_1 \ a_2)^T$, en küçük kare yaklaşımı kullanılarak

$$a = (X^T X)^{-1} X^T Y \quad (1.2)$$

şeklinde bulunabilmektedir. Burada N adet piksel içeren bir veri için $X \ N \times 3$ boyutunda bir matris olup ilk sütunu birdir, ikinci ve üçüncü sütunlar sırasıyla Bant 1 ve Bant 2 'nin piksellerini içermektedir. Aynı denklemde y ise $N \times 1$ vektör olup o esnada sınıanan bant B'nin piksellerini içermektedir. Bant seçimi için e'de maksimum hataya (en yüksek farka) sahibi olan bant, en farklı olması gereken üçüncü bandı olarak aşağıdaki gibi belirlenebilir.

$$B = \text{argmax}(e) \quad (1.3)$$

LPE ile benzer mantıkla çalışan başka yöntemler var. Örnek olarak Dikgen Altuzaylar Projeksiyonu (OSP) verilebilir. İlk iki bant sonrası en farklı bant B için, Dikgen Altuzaylar P aşağıdaki formül kullanılarak hesaplanmaktadır.

$$P = I - Z(Z^T Z)^{-1} Z^T \quad (1.4)$$

Burada I, N boyutunda özdeş bir matrisdir (N piksel sayısını göstermektedir), Z ise $N \times 2$ boyutunda matris olup birinci ve ikinci sütunlar sırasıyla Bant1 ve Bant2 'nin piksellerini içermektedir. Y_0 projeksiyon formülü aşağıdaki gibidir:

$$Y_0 = P^T y \quad (1.5)$$

Burada y vektörü, aday bant B piksellerini içerir. Maksimum= $\| Y_0 \|$ değerini veren bant üçüncü bant olarak kabul edilir.

1.3. Yerel İkili Örüntü (LBP)

Yerel ikili örüntü [24] ışıklılık değişmezliği, rotasyonla değişmeyen öznitelikler ve Yönelimli Gradyen Histogramı (HOG) gibi önemli özellikleri sağlayan bir doku tanımı operatördür. LBP basitçe her bir pikselin doku özniteliklerini kendi yerel komşu pikselleri ile kıyaslayarak çıkartmaktadır. LBP bu sebeple verimli bir yerel uzamsal örüntü tanımlayıcısı olarak adlandırılabilir. Kısaca, LBP operatörü pikselleri bir bölge olarak alıp ve sonra bu bölgedeki orta pikselin değeri ile eşikleme yaparak her pikseli etiketlemektedir.

LBP özniteliklerinde [25] bir pencere için orta pikselin değeri T_c olarak ifade edilirse, bu pikselin her komşusu bir ikili etiketle "0" veya "1" olarak atanır. Esasında, orta pikselin değeri daha büyük ise, karşılaştırılan piksel etiketi 0 olarak atanır aksi takdirde 1'dir. Eşit aralıklı pikseller bir daire oluşturmakta olup daire yarıçapı R olarak adlandırılabilir. Yani R orta piksel ile komşu pikseller arasındaki mesafenin ne kadar olduğunu gösterir. LBP istenen açısal alan nicemlemesi ve uzamsal çözünürlüğün dairesel komşuluğunda hesaplanabilir. Orta pikselin değeri T_c ise LBP kodu şu şekilde bulunur:

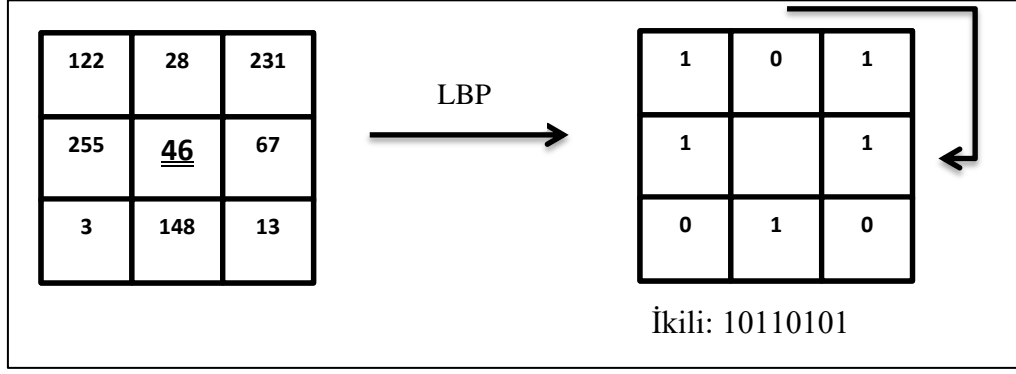
$$LBP_{M,R}(T_c) = \sum_{i=0}^{M-1} P(i)2^i \quad (1.6)$$

$$P(i) = \begin{cases} 1, & \text{if } T(i) \geq T(c) \\ 0, & \text{otherwise} \end{cases} \quad (1.7)$$

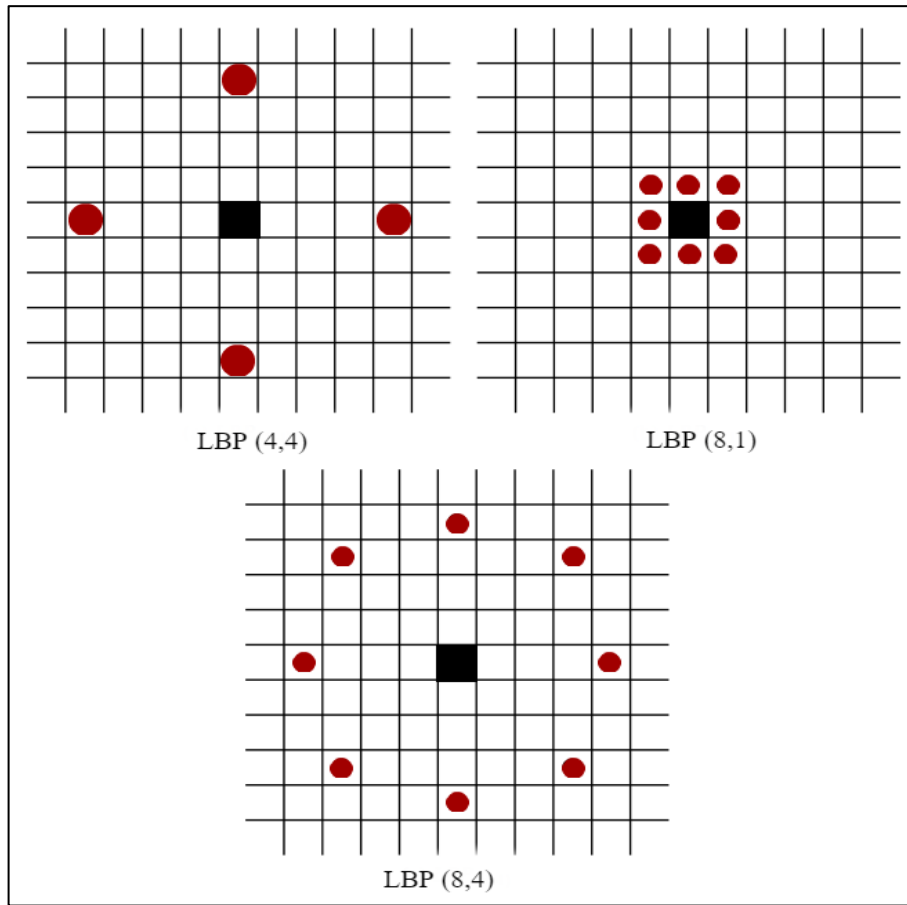
Şekil 1.5. LBP operatörüne ait örnek bir işlemi göstermektedir.

Yerel ikili örüntü operatörleri iki önemli parametre ile oluşturulabilmektedir. İlk parametre komşu piksel sayısıdır. İkincisi ise herhangi bir uzamsal çözünürlükteki açısal alan nicemlemesidir. Uygulamada, LBP operatörü oldukça ayırt edici bir operatör olup, her orta pikselin LBP değerinin komşularının farklı örüntülerini sakladığı düşünülebilir [23]. Şekil 1.6. farklı parametreler ile oluşturulmuş LBP operatörlerine örnekler göstermektedir.

Burada LBP (M, R) şeklinde M komşu piksel sayısını temsil eder ve R yarıçapı göstermektedir.



Şekil 1.5. LBP (M = 8, R = 1) operatörü



Şekil 1.6. Farklı LBP operatör örnekleri

1.4. Gabor Filtresi

Gabor filtresi, Dennis Gabor tarafından geliştirilmiş ve doğrusal işlemler uygulanarak kenarların algılanmasında kullanılabilecek bir filtredir. Gabor filtresi görüntüde yönelimleri ve frekansları önceden tanımlanmış dokularının temsil edilmesinde ve nesnelerin ayırt edilmesinde kullanılabilmektedir. Gabor filtresi, 2-boyutlu bir sistemde Gauss zarfı tarafından modüle edilmiş sinüzoidal bir işaretir ve

bu filtre görüntü işleme ve analizinde geniş bir uygulama alanına sahiptir. Örneğin hiperspektral görüntü sınıflandırmasında kullanımı [26]'de ele alınmıştır. Gabor filtresi karmaşık bir sayı olarak temsil edilmekte olup, gerçek ve sanal kısımları aşağıdaki gibi gösterilebilir:

Karmaşık Gabor filtesi ifadesi

$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\exp\left(i\left(2\pi\frac{x'}{\lambda}+\psi\right)\right) \quad (1.8)$$

olup gerçek kısım

$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\cos\left(2\pi\frac{x'}{\lambda}+\psi\right) \quad (1.9)$$

olarak, sanal kısım ise

$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\sin\left(2\pi\frac{x'}{\lambda}+\psi\right) \quad (1.10)$$

olarak ifade edilebilir. Burada

$$x'=x\cos\theta+y\sin\theta \quad (1.11)$$


ve

$$y'=-x\sin\theta+y\cos\theta \quad (1.12)$$

olmaktadır.

Yukarıdaki denklemlerde, λ sinüzoidal bir dalga boyu faktörünü temsil eder, θ ise Gabor fonksiyonunun normal ve paralel çizgilerinin yönünü göstermektedir. Şekil 1.7'de farklı yönelimlerde Gabor çekirdekleri gösterilmektedir. İfadelerdeki ψ faz ofseti, σ (sigma) Gauss zarf standart sapması ve γ ise uzamsal en-boy oranıdır. Bu parametreler Gabor fonksiyonunu destekleyen elipsi belirlemektedir. Uzamsal frekans bant genişliği b_w olmak üzere λ değerine göre σ parametresi aşağıdaki gibi tespit edilebilir:

$$\sigma=\frac{\lambda}{\pi}\sqrt{\frac{\ln 2}{2}\frac{2^{b_w}+1}{2^{b_w}-1}} \quad (1.13)$$



Şekil 1.7. Farklı yönlerde 2 boyutlu Gabor çekirdekleri [26]


1.5. LBP ve Gabor Filtresinin Karşılaştırılması

Yerel İkili Örüntü (LBP) ve Gabor filtresi önceki bölümlerde tanıtılmış olup Gabor filtresinin konum tabanlı çalıştığını LBP operatörünün ise yerel operatör olduğunu ifade etmek mümkündür. Bu sebeple, her bir operatörün farklı açılardan bir görüntüdeki doku bilgilerini çıkartma yeteneğine sahip olduğu açıktır. Şekil 1.8’de normal bir örnek görüntü kullanılarak çıkartılan farklı LBP ve Gabor öznelikleri gösterilmektedir. Şekil 1.8 (b) $P = 8, R = 1$ parametreleri ile LBP kodlu görüntüyü göstermektedir. Şekil 1.8 (c-f) Gabor filtresinin farklı yönelimleri kullanılarak filtrelenmiş görüntüleri göstermektedir ($[0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{5\pi}{4}]$).

Şekil 1.8’deki her Gabor filtrelenmiş görüntü çıktısı ilgili Gabor filtersi için elde edilen global işaret gücünü yansıtır. LBP kodlu görüntü ise daha çok yerel uzamsal özneliklerin detaylarını (örneğin, kenarlar ve köşeler) göstermektedir. Bu nedenle literatürde Gabor filtersinin LBP operatörü ile birlikte kullanılmasını değerlendiren çalışmalar sunulmuştur. Gabor filtresi daha çok görüntüde doku bilgilerini küresel olarak çıkartmak için kullanılırken, Yerel İkili Örüntü (LBP) yerel bilgi elde etmek için kullanılır.

Hiperspektral görüntülerde aynı sınıfa ait piksellerin benzer bölgelere düştüğü tespit edilmiş olup, bu nedenle Gabor süzgeci belirli yönelim ve dalgalar için bir banttaki global doku bilgisini ifade edebilmektedir. LBP ise yerel doku bilgilerini tanımlamak

için kullanılabilir. Bu yüzden LBP ile Gabor filtresini birleştirerek daha iyi bir performans sergileyecek etkili bir yaklaşımın üretebileceği öngörülmüştür [24].



Şekil 1.8. LBP ve Gabor filtresi örneği (a) Giriş görüntüsü (b) LBP kodlanmış görüntü (c) Gabor özneliklerinin görüntüsü $\theta = 0$. (D) Gabor özneliklerinin görüntüsü $\theta = \pi / 4$. (E) Gabor özneliklerinin görüntüsü $\theta = \pi / 2$. (F) Gabor özneliklerinin görüntüsü $\theta = 5\pi / 4$.

1.6. Değişim Tespiti

Genel olarak, değişim tespiti çoklu zamansal veri setlerinde zamansal etkileri nicel olarak analiz eden uygulamaları kapsamaktadır. Değişim tespiti farklı zamanlarda gözlemlenen bir bölgede veya nesnede meydana gelen değişimleri tespit etmek için uygulanan bir işlem olarak tanımlanabilir. Değişim tespiti genellikle belirli bir veri setinde zamansal etkinin ölçülebilmesine olanak tanımaktadır [29].


Şekil 1.9'da değişim tespitine örnek gösterilmiştir. Değişim tespiti, arazi kullanım değişimi, yaşam alanlarının ayrıştırılması, ormansızlaşma oranının tespiti, kıyı değişimi, kentsel yayılım ve diğer birikimli değişimlerin bulunması gibi pek çok uygulamada kullanılabilir.

Görüntülere uygulanan değişim tespiti algoritmaları uzamsal, spektral, radyometrik ve zamansal değişikliklerden etkilenmektedir. İşlevselliğe göre farklı değişim tespiti yöntemlerinin kullanılması mümkündür. Literatürde yaygın kullanılan değişim tespiti yaklaşımları cebirsel işlem temelli yaklaşımlar (görüntü farkı, görüntü regresyonu ve CVA gibi), dönüşüm tabanlı yaklaşımları (PCA, Gram-Schmidt gibi), sınıflandırma tabanlı yaklaşımları (sınıflandırma sonrası işlem, Hibrid değişim tespiti, Yapay Sinir Ağları gibi) olarak ele alınabilir.

1.6.1. Spektral açı eşleme (SAM)

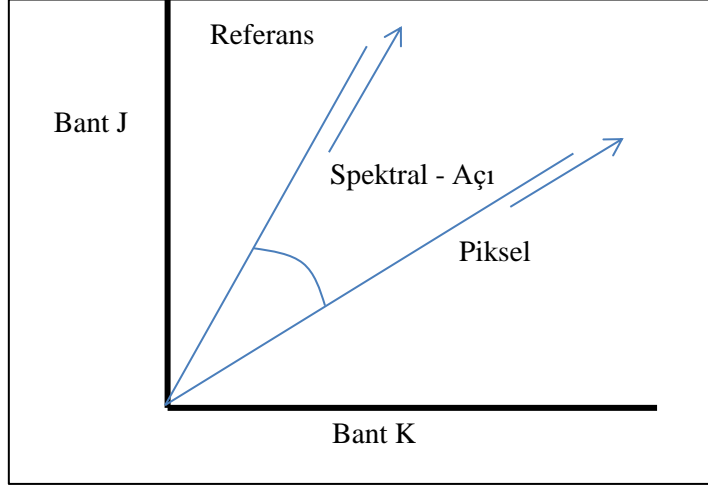
Spektral Açı Eşleme (SAM) genelde eğitimli yöntemlerde referans spektrumlar mevcut ise kullanılmakta olup belirli bir sınıfı temsil eden spektrumların homojen bir yapıya sahip olduğu varsayımına dayanır [41]. SAM algoritması iki spektrum arasındaki benzerliği hesaplamaktadır. Benzerlik arttıkça açı azalacağından bulunan SAM değeri açısal uzaklık ile ilişkilidir. SAM hesabında ilk spektrum test edilen spektrum olarak kabul edilir ve ikincisi ise referans spektrum olarak alınmaktadır. Spektral benzerlik ölçümü, her bir spektrum q bantlı ise temelde her piksel için uzayda q boyutlu bir vektör olarak hesaba katılabilir. SAM, iki spektrum arasındaki açıyı hesaplayarak ve bu iki spektrumu bant sayısı kadar boyutlu bir uzayın vektörleri gibi kabul ederek spektral benzerliklerini belirlemektedir. Normalizasyon nedeniyle ışıklılık değişikliklerinin etkisi bu algorithmada nispeten düşüktür. SAM aşağıdaki formül uygulanarak benzerlik ölçümü yapmaktadır.

$$\alpha = \cos^{-1} \left[\frac{\sum_{i=1}^b t_i r_i}{\sqrt{\sum_{i=1}^b t_i^2} \sqrt{\sum_{i=1}^b r_i^2}} \right] \quad (1.14)$$



Şekil 1.9. Değişim tespiti gösterimi [40]

Burada α spektral açığı, b bant sayısını, t hedef piksel spektrumunu ve r referans spektrumunu temsil etmektedir. Spektral açı azaldıkça benzerlik artmaktadır. Şekil 1.10'da spektral açının temsili gösterimi verilmiştir.



Şekil 1.10. Spektral açının temsili gösterimi

2. HİPERSPEKTRAL GÖRÜNTÜLERDE DEĞİŞİM TESPİTİNE GİRİŞ

Değişim tespiti işlemi farklı zamanlarda gözlemlenen bir nesnede veya sahnede bulunan değişimleri bulmak amacıyla gerçekleştirilen bir işlem olarak tanımlanabilir. Değişim tespiti genellikle bir veri setinde oluşan zamansal etkileri tespit etmek için kullanılır [29]. Uzaktan algılama teknolojisinde farklı zamanlarda aynı fiziksel alandan alınmış görüntüler kullanılarak değişim tespiti gerçekleştirilebilmektedir. Hiperspektral görüntüler kullanılarak yapılan değişim tespiti, çevresel değişimler ve termal özellikler de dikkate alınabildiğinden farklı uygulamalarda yaygın olarak kullanılmaktadır. Bu uygulamalardan bazıları, toprakların değişim analizi, arazi örtüsü izlenmesi, tarım, kentsel gelişim, afet izleme, arazi ve bitki örtüsü değişikliklerinin tespiti olarak verilebilir [29 - 31].

Hiperspektral görüntüler kullanılarak yapılan değişim tespitinde [29]'ye göre arazi örtüsünde gerçekleşen herhangi bir değişimin yansıma değerlerinde değişime yol açması gerekmekte olup bu değişimlerin atmosferik şartlar veya güneş açısının değişimi gibi etki eden faktörlerden daha fazla olması beklenmektedir. Bu tür etki eden faktörlerin etkisinin kısmen uygun veri seçilerek azaltılabildiği ifade edilmiştir.

Uzaktan algılama veri setleri kullanarak değişim tespiti gerçekleştirmek için birkaç temel araştırma sunulmuştur. Uzaktan algılama veri setleri ile değişim algılama için başlıca, arazi örtüsü sınıflandırma sonuçlarının karşılaştırması, çoklu veri sınıflandırma, görüntü farkı / oranlama, bitki örtüsü indeksi farkı, temel bileşenler analizi ve değişim vektör analizi yöntemleri önerilmiştir [31].

Hiperspektral görüntü tabanlı değişim tespiti için önerilen birçok genel yaklaşım bulunmaktadır. En basit yöntemlerden biri benzerliğin veya farkın eşiklenmesidir. Eşikleme ve eşik değeri seçimine bağlı olarak farklı öneriler geliştirilmiş olup, bazı örnekler [10] kaynaklarında verilmiştir. Basit olarak eşikleme tabanlı yöntemler, spektral görüntü bantları arasındaki farkı veya iki sahne arasındaki bitki örtüsü

indeksleri farkını hesaplayıp deęişim tespiti için bir eşik ayarlamaktadır. Yaygın olarak kullanılan bir dięer yöntem olan Deęişim Vektör Analizi (CVA) ise hiperspektral görüntülerde piksel nitelik vektörlerinin her çifti arasındaki farkı elde ederek deęişim tespiti yapmaktadır. Öznitelik vektörleri aynı zamanda bitki endeksleri ve uzamsal dokuları temsil eden özellikler olmak üzere genişletilebilir [11,32]. Temel Bileşen Analizi (PCA) hiperspektral görüntülerde bulunan artıklığı azaltmak ve sadece ayırt edici ama bilgi verici deęişim bilgilerini korumak için [33]'de kullanılmıştır.

2.1. Yığılmış Çok Zamanlı Hiperspektral Görüntü Tabanlı Deęişim Tespiti

[44]'de tek bir veri haline yığılmış çoklu-zamansal hiperspektral görüntüsü üzerinden spektral tabanlı deęişim yaklaşımı önerilmiştir. Önerilen yaklaşımda temel bileşen analizi (PCA) uygulanarak boyut azaltılır. Sonrasında PCA sonuçlarından hedef imzalar çıkarılmaktadır. Son olarak, hedeflenen deęişim alanlarını tespit etmek için Adaptif Tutarlılık / Kosinüs Kestiricisi (ACE) dedektörü kullanılmıştır.

Adaptif Tutarlılık / Kosinüs Kestiricisi (ACE) aşağıdaki gibi ifade edilebilmektedir.

$$ACE(X) = \frac{x^T \Gamma^{-1} S (S^T \Gamma^{-1} S)^{-1} S^T \Gamma^{-1} X}{x^T \Gamma^{-1} X} \quad (2.1)$$

Burada Γ pikseller tarafından belirlenen kovaryans matrisini temsil etmekte, x hiperspektral görüntüde gözlemlenen pikseli, S ise ilgili son üyeler üzerinden hedeflenen spektral matrisi temsil etmektedir.

Kullanılan görüntü modelinde yalnızca hedef spektral matris gereklidir ve görüntü kovaryans matrisi görüntüden hesaplanmaktadır. Daha fazla bilgi [34]'de bulunmaktadır.

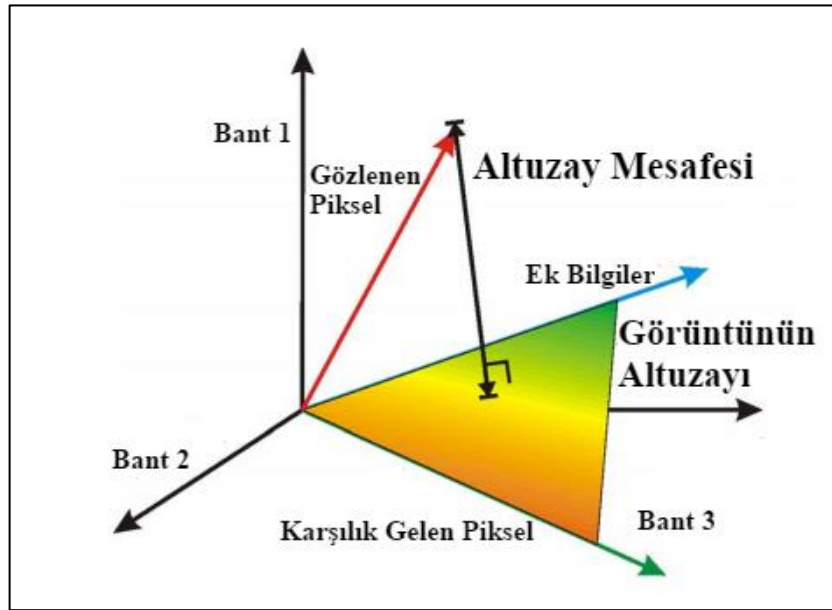
Hedeflenen deęişim tespiti sonuçları kappa katsayısı ddeğerine göre değerlendirilmektedir. [34]'deki yöntem, çalışmada bahsedilen dięer iki sınıflandırma tabanlı yönteme göre biraz daha iyi bir performans sergilemektedir. Ancak ilgili yöntemde hiperspektral görüntülerin sadece spektral imzası kullanılarak işlem yapıldığından uzamsal bilgi kullanılmamaktadır.

2.2. Altuzay Tabanlı Değişim Tespiti

Altuzay tabanlı değişim tespiti (SCD) spektral imzalardaki değişimi ölçmektedir [35]. Bu yöntemde referans (T1) imgeesinde karşılık gelen piksel kıllanarak arkaplan altuzayı oluşturulmaktadır. Ayrıca özel uygulamalar için arkaplan altuzayının oluşturulması T1 imgesindeki karşılık pikselin komşuluğundaki spektral bilgiler ve istenmeyen arazi örtüsünün spektral bilgisi şeklindeki iki adet ek bilgi kullanımı mümkündür. Sonrasında T2 imgesineki ilgili piksel ile karşılaştırma sağlanmaktadır.

Bu yöntemde referans piksel ve aday piksel arasında değişimin olup olmadığını tespit etmek üzere alt uzay mesafesini hesaplamak için Dikgen Altuzaylar Projeksiyonu (OSP) kullanılmaktadır. Dikgen Altuzaylar Projeksiyonu (OSP) kullanılarak hiperspektral görüntüde spektral bilginin kullanımının avantaj sağladığı belirtilmiştir.

Şekil 2.2’de SCD yaklaşımı gösterilmektedir. Bu gösterimde üç boyutlu uzayda alt uzay mesafesi gözlenen pikselin spektral imzasının (kırmızı vektör ile gösterilen), karşılık gelen piksel (yeşil vektör ile gösterilen) ve diğer ek bilgiler (mavi vektör ile gösterilen) tarafından oluşturulan altuzay izdüşümü alınarak değişim tespit edilmektedir.



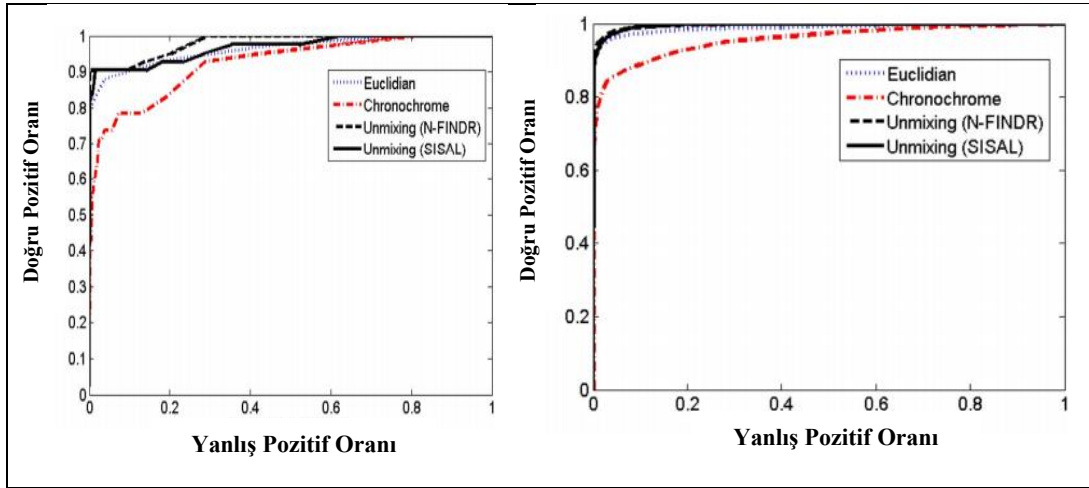
Şekil 2.1. Altuzay mesafesi gösterimi [35]

2.3. Karışım Giderimi Tabanlı Hiperspektral Değişim Tespiti

Değişim tespitinde önerilen yöntemlerinin çoğu sadece sahnedeki değişimlerin gerçekleştiği yerleri tespit etmeyi amaçlamaktadır. Ancak, [36]'da Spektral Karışım Giderimi kullanılarak geliştirilen yöntem değişimin doğası hakkında yorumlanabilir bilgileri sağlamayı amaçlamakta olup, tespit edilen değişimin sahnedeki saf maddeleri temsil eden son-elemanlarla ilişkisini de çıkartmaktadır.

Karışım Giderimi Tabanlı Bilgilendirici Değişim Tespiti [36] malzemelerin son elemanlarını temsil eden yeterli saflıktaki spektral imzaları çıkarma stratejisini kullanıp sonra bolluk kestirimi adımını gerçekleştirilmektedir. Son olarak zaman içinde bolluk haritalarındaki değişim tespit edilmektedir. Yani, bolluk haritasında her bir son üyeye karşılık gelen değişim farklı zamansal veri setlerine karşılık gelen bolluk haritaları üzerinden basit bir fark işlemiyle hesaplanmakta ve toplam değişim haritası her son üye için değişim haritalarının toplamı şeklinde elde edilmektedir.

Şekil 2.2'de ROC eğrileri üzerinden örnek değişim tespit başarımları gösterilmiştir. Sonuçlar Öklid mesafesi tabanlı ve Kronokrom tabanlı diğer karşılaştırılmış ve tespit sonuçlarının yakın olduğu gösterilmiştir.



Şekil 2.2. İki farklı veri kümesinin değişim tespiti sonuçlarının ROC eğrileri [36]

2.4. Spektral ve Uzamsal Bilgilerin Kaynaşımı Tabanlı Değişim Tespiti

[37]'de, hem spektral hem de uzamsal özniteliklerin kaynaştırılmasını kullanan eğitimsiz bir değişim tespiti yöntemi önerilmiştir. Bu yaklaşım birden fazla özniteliği birleştirmek için bulanık mantık kurallarını kullanmaktadır. Bu çalışmada örnek olarak yerel Haar öznitelikleri, bitki örtüsü indeksi, insan yapımı öznitelikler ve renk bilgisi kaynaştırılmaktadır. Yöntemde bulanık mantık kuralları kullanılarak çok seviyeli değişim tespiti yapılmaktadır. Her piksel için yerel bölgede Haar özniteliği ile bir aydınlatma değişmezi tanımlayıcısı oluşturulmaktadır. Renk öznitelikleri ise Hue değerleri kullanılarak temsil edilmektedir. İnsan yapımı yapılarla değişim alanını arttırmak amacıyla insan yapımı olmayan nesnelere algılayan değişim alanlarının ağırlıkları ayarlanmaktadır. Yaklaşımın başarımını test etmek için, tüm öznitelikler ayrı ayrı karşılaştırılıp sonrasında elde edilen sonuçlar çok düzeyli değişimi tespiti sonuçlarını sağlamak için bulanık mantık kuralları ile bir araya getirilmiştir.

Bu yaklaşımda sahnede meydana gelen değişimler otomatik olarak önsel bilgiler veya eğitim verileri kullanılmadan tespit edilebilmektedir. [37]'de değişim tespiti performansı görsel inceleme ile ve yer doğrusu haritası ile nicemsel karşılaştırma sonucunda değerlendirilmektedir. Sonuçlarda gösterilen istatistikler yer doğrusu haritasındaki değişimlerin % 90'dan daha yüksek oranda tespit edildiğini sergilemektedir.

2.5. Değişim Tespiti için Uzamsal-Spektral Çarpaz-Korelasyon

[42]'da uzaktan algılama değişim tespiti için normalize edilmiş uzamsal-spektral korelasyon yöntemi önerilmiştir. Bu yöntem, normalize edilmiş uzamsal korelasyon ve normalize edilmiş spektral korelasyon yöntemlerini geliştirerek uzam-zamansal uzaya geliştirmektedir. Önerilen uzamsal-spektral korelasyon yöntemi spektral korelasyon yöntemi gibi içsel olarak imza bağımlı olup aynı zamanda uzamsal bilgiyi de kullanmaktadır. Spektral korelasyonda olduğu gibi minimum düzeyde ön-işlem gereksinimi bulunmaktadır. Ayrıca genelde veri düzeltimi ihtiyacı bulunmamaktadır. Ayrıca normalize spektral korelasyona benzer şekilde radyometrik farklılıklarının ve imgedeki dinamik aralık farklılıklarının üstesinden gelmektedir.

Uzamsal-spektral korelasyon yönteminin spektral korelasyon yöntemine üstünlüğü değişim tespiti için tek bir pikselin spektral imzası yerine bölgesel spektral imzalar üzerinden yapılmasıdır. Bu sayede yöntem gürültüye ve piksel-karışımlarına karşı gürbüzlük kazandığı gibi hatalı kayıtlamaya karşı daha az hassasiyet göstermektedir.

2.6. Değişim Tespiti için Çoklu Sınıflandırma Sistemi ve Uzamsal-Spektral Öznitelikleri Kullanımı

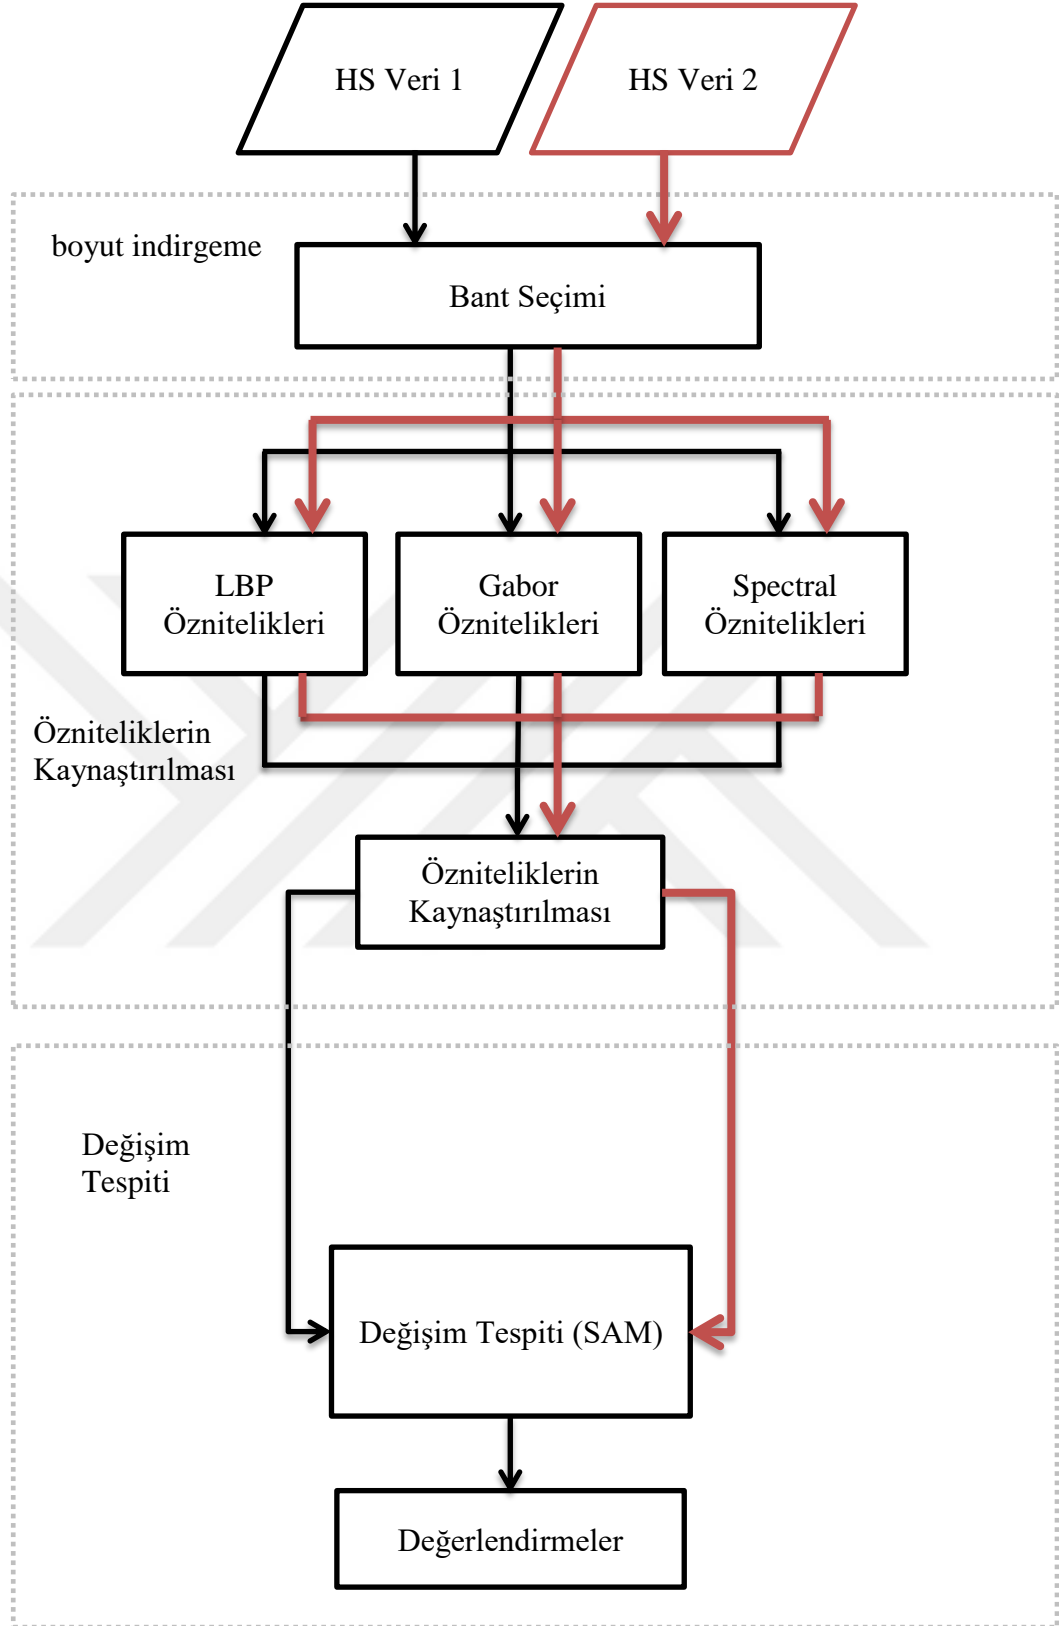
[43]'de çoklu sınıflandırma yapısında eğitim örneklerinin seçilmesi için özgün bir yaklaşım kullanan otomatik bir değişim tespiti yöntemi önerilmiştir. Eğitim verilerinin seçilmesinde önceki yöntemlerde kullanılan tek eşliğe bağlı bir seçim yerine ikili eşiklemeye bağlı bir yaklaşım geliştirilerek eğitim örneklerinin daha "akıllı" bir şekilde seçilmesi amaçlanmıştır. Daha yüksek değişim tespit doğruluğu için spektral bilgiye ek olarak doku ve morfolojik profil gibi uzamsal bilgiler de kullanılmıştır. Önerilen yaklaşımda aşırı öğrenme makinesi (ELM), multinomial lojistik regresyon (MLR) ve K-en yakın komşulu (KNN) sınıflandırma tabanlı bir çoklu sınıflandırma sistemi (MCS) kullanılmıştır. Önerilen yaklaşım yüksek çözünürlüklü uzaktan algılama imgelerinde değişim tespit başarımının iyileştirilebileceğini göstermiştir.

3. UZAMSAL ve SPEKTRAL ÖZNETELİKLERİ KAYNAŞIMI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLER İÇİN DEĞİŞİM TESPİTİ

Bu bölümde, tez çalışmasının katkısı açıklanmaktadır. Ayrıca hiperspektral görüntüler için önerilen uzamsal ve spektral özniteliklerin kaynaştırılması temelli değişim tespitinde kullanılan yöntemlerin uygulaması tarif edilmiştir. Önerilen yöntem genel olarak hiperspektral görüntünün uzamsal özniteliklerini çıkarmak için Gabor filtresi ile birlikte Yerel İkili örüntü (LBP) kullanılmaktadır ve sonra hiperspektral görüntü değişim tespiti gerçekleştirmek için spektral öznitelikler ile uzamsal öznitelikleri birleştirmektedir.

3.1. Tezde Önerilen Değişim Tespiti Yaklaşımı

Hiperspektral görüntü için değişim algılama prosedürüne başlamadan önce bir veri ön işleme ilk adımı olarak hiperspektral görüntünün boyutunun indirgenmesi özellikle işlem yükü açısından fayda sağlamaktadır. Boyut indirgemesi için bant seçimi uygulanarak en belirgin ve en bilgilendirici görüntü bantlarının alınması sağlanır ve işlenmesi gereken bantların sayısı azaltılır. Bu sayede işlem yükü azaltılmaktadır. Bantlar seçildikten sonra görüntünün doku öznitelikleri yerel olarak LBP ve global olarak Gabor filtresi kullanılarak çıkarılmaktadır. Özniteliklerin kaynaştırılması aşaması ile tek bir öznitelik vektörü içerisinde farklı öznitelik vektörleri birleştirilir. Son olarak değişim tespiti yaklaşımı uygulanmaktadır. Bu amaçla Spektral Açık Eşleme (SAM) yöntemi kullanılarak görüntülerdeki tüm karşılıklı piksellerin öznitelik vektörleri arasındaki benzerlikler hesaplanmaktadır. Benzerlik değerine göre değişim tespiti yapılmaktadır. Şekil 3.1'de önerilen yöntemin akış şeması gösterilmektedir.



Şekil 3.1. Tezde önerilen yöntemin akış şeması

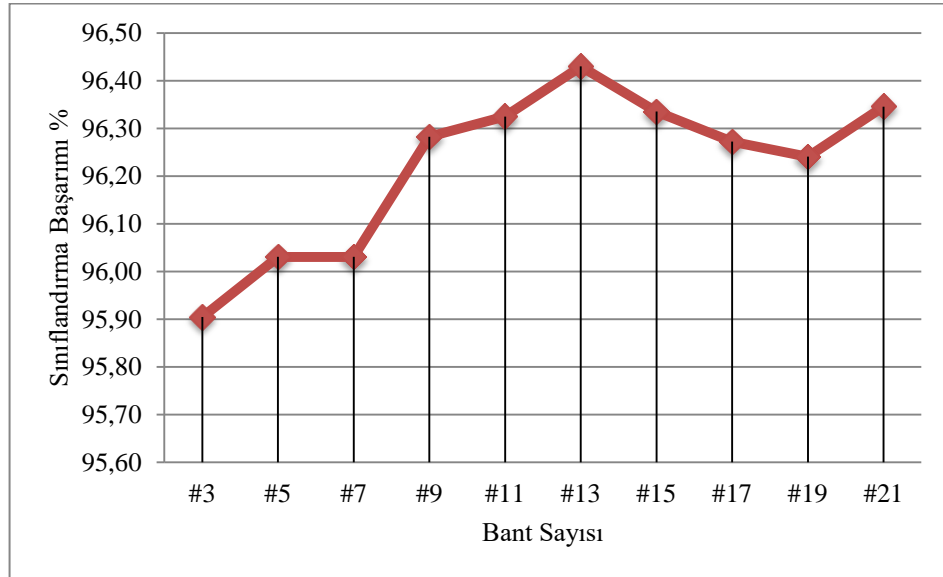
3.1.1. Bant seçimi

[25]'nin sonuçlarında bant seçimi yaklaşımı olarak LPE yönteminin üstünlüğü nedeniyle, bu tezde bant seçimi için LPE kullanılmıştır. Bölüm 1'de gösterildiği üzere LPE, bantlar arasındaki benzerliğin göre bant seçimi yapan etkili bir yöntemdir. LPE algoritmasının iyi sonuçlar üretmesi için birkaç adımın dikkate alınması gerekir.

- Gerekli bant sayısının belirlenmesi:

LPE eğitimsiz bir yöntem olduğundan gerekli bant sayısını önceden tanımlamak gerekir. Bant sayısını belirlemek için literatürde farklı yöntemler önerilmiştir. Literatürde mevcut örnek bir yaklaşım Sanal Boyutluluk (Virtual Dimensionality VD) yaklaşımıdır.

Bu tez çalışmada kolaylık açısından LBP öznelikleri ve SVM sınıflandırıcı kullanarak farklı bant sayılarında elde edilen sınıflandırma başarımları çıkarılarak en iyi sınıflandırma başarımını sağlayan bant sayısı kullanılmıştır. Örnek olarak, Şekil 3.2'de Indian Pines verisi için farklı bant sayısında elde edilen sınıflandırma başarımları gösterilmektedir.



Şekil 3.2. Indian Pines verileri kullanılarak farklı bant sayıları için SVM sınıflandırma başarımları

- Veri oranı:

Bazı görüntülerdeki görüntü boyutunun büyük olması nedeniyle bant seçimi işleminin hesap yükü fazla olabilir. Elde edilen sonuçlarda, görüntünün tamamı yerine piksellerin bir alt kümesinin kullanılmasının sonuçları etkilemediği görülmüştür. Bunun nedeni hiperspektral görüntülerde uzamsal korelasyon bulunmasıdır. Bu yüzden deneylerde LPE işleminde tüm piksel sayısının sadece % 10'u kullanılmıştır.

- Düşük SNR'lı Bantların Atılması:

Su buharı emilimi veya düşük yansımaya oranı nedeniyle düşük SNR'a (işaret gürültü oranına) sahip bantların önceden atılması gerekmektedir. Bazı hiperspektral veri setleri sağlayıcıları önceden bu bantları çıkarmaktadır. Fakat bazı yöntemler [22] örneğin bitişik bantlar ile düşük korelasyon katsayılarına sahip bantların manuel olarak çıkarılmasını önermektedir. Mevcut yaklaşımda da düşük SNR değerine sahip bantlar önceden manuel olarak elenmiştir.

- Veri Beyazlatma:

Bantlardaki çeşitli gürültüleri etkilerini giderebilmek için gürültü kestirimi mümkündür. Gürültü beyazlatma ve veri beyazlatma arasında benzerlik olduğundan dolayı ve aynı zamanda veri beyazlatmanın kolaylığından ötürü veri beyazlatma yöntemi daha çok tercih edilir. Veri beyazlatma temel olarak veri kovaryans matrisinin özdeğerlerinin çıkarılması ile gerçekleştirilebilir. LPE ile bantların seçim sürecinde beyazlatılmış bantlar kullanıldığı halde bant seçimden sonra algoritma aşamasında sadece orijinal bantlar kullanılmaktadır.

- LPE için ilk bantların seçimi:

İlk iki bant (Bant 1 ve Bant 2) LPE işlemi için önemlidir. İlk bantların büyük ölçüde farklı olması gerekir. İlk bantlar, bant seçimi performansı başarısında önemli rol oynayabilir. Bu nedenle hiperspektral görüntüde en farklı bantları tespit etmek için [22]'de bir algoritma geliştirilmiştir. Bu algoritmanın prosedürü aşağıdaki gibidir:

1) Rasgele bir bant (B_1) seçilip dik altuzayında diğer tüm bantların projeksiyonu bulunur.

2) B_1 dik altuzayında maksimum projeksiyonu olan bant ikinci bant (B_2) olarak alınır.

- 3) Maksimum projeksiyonu olan üçüncü bandı (B_3) bulunabilmek için B_2 dik altuzayı ile diğer tüm bantların iç çarpımı alınır.
- 4) Eğer $B_3 = B_1$ ise, o zaman B_1 ve B_2 en önemli benzersizliği olan çift olarak onaylanır ve ilk bant seçimi sonlandırılır. Eğer $B_3 \neq B_1$ ise, bir sonraki adıma geçilir.
- 5) $B_i = B_{i-1}$ oluncaya kadar projeksiyona devam edilir, sonra ya B_{i-1} ya da B_i bant seçiminde ilk B_1 olarak kullanılır.

– LPE bant seçimi:

Bölüm 1’de belirtildiği gibi, farklı bant B aşağıdaki denklem ile elde edilmektedir:

$$B' = a_0 + a_1 \text{Band}_1 + a_2 \text{Band}_2 \quad (3.1)$$


B' doğrusal kestirim sonucu olup, a_0, a_1, a_2 katsayıları LPE hatası $e = \|B - B'\|$ değerini en aza indirmecek şekilde belirlenmektedir. Parametre vektörü $a = (a_0 a_1 a_2)^T$ olarak tanımlanırsa, en küçük kare yaklaşımı kullanılarak:

$$a = (X^T X)^{-1} X^T y \quad (3.2)$$

elde edilebilir. Burada X bir $N \times 3$ bir matris olup ilk sütunu birdir, ikinci ve üçüncü sütunlar sırasıyla Bant 1 ve Bant 2 'nin piksellerini içerir (N toplam piksel sayısıdır). Buradaki y de bir $N \times 1$ vektör olup B 'nin piksellerini içerir. e 'de maksimum hata (fark) sahibi olan bant, en farklı üçüncü bandı olarak aşağıdaki gibi belirlenebilir:

$$B = \arg \max(e) \quad (3.3)$$

Şekil 3.3’de örnek IndianPine verisi için LPE ile seçilen bantlar gösterilmektedir.




Şekil 3.3. Indian Pines verisi için LPE ile seçilen bantlar

3.1.2. Uzamsal – spektral öznitelik çıkartımı

Boyut indirgeme adımından sonra ayırt edici ve bilgilendirici bantları seçilmiş durumdadır. Sonraki adımda seçilen bantlara Yerel İkili Örüntü ve Gabor filtresi kullanılarak öznitelik çıkartımı uygulanır.

LBP Özniteliklerini çıkartmak için öncelikle komşu piksel sayısı ve yarıçap parametreleri deneylerde sırasıyla $M = 8$, $R = 2$ olarak tanımlanmıştır. Sonra Şekil 3.4'de gösterildiği gibi, LBP görüntüsü üretmek için görüntüdeki her piksel için LBP kodu hesaplanmıştır. Sonra ilgili pikseller için piksel etrafında oluşturulan pencerede histogram kullanılarak öznitelikler oluşturulmuştur. Pencere boyutu önsel olarak belirlenmektedir.



Şekil 3.4. LBP ile öznitelik çıkartımı

Her bir bant için Gabor filtreleme uygulandığında, Gabor öznitelikleri seçilen her bant için ortalama büyüklük tepkisi şeklinde üretilir ve bu sebeple ilgili Gabor filtresi için sinyal gücünü yansıtır. Hiperspektral görüntülerin doğası gereği homojen bölgelere sahip olması nedeniyle Gabor öznitelikleri global doku bilgilerini yansıtmaktadır. Deneylerde kullanılan parametreler literatürde [25]'de sunulan sonuçlara göre ayarlanmıştır. Spektral özniteliklerine gelince, her pikselin orijinal spektral imza değerleri kullanılmaktadır.

3.1.3. Özniteliklerin kaynaştırılması

Bu bölümde üç farklı öznitelik türü birleştirilmektedir. LBP, Gabor ve spektral öznitelikleri tek bir kompozit vektör içerisinde birleştirilmektedir.

Her özneliğin ölçek çeşitliliği nedeniyle özniteliklerin birleştirilmesinden önce bir ön işleme adımı olarak normalleştirme gereklidir. Tüm öznitelikler (LBP, Gabor ve spektral) kendi içlerinde bağımsız olarak normalize edildikten sonra tek bir vektör halinde yığılanmakta ve tek bir öznitelik vektörü oluşturulmaktadır.

3.1.4. SAM kullanarak değişim tespiti

Her iki görüntüde uzamsal-spektral öznitelikler çıkartıldıktan sonra karşılıklı pikseller için SAM hesabı yapılmaktadır. SAM değeri belirli bir eşik üzerinde çıkan pikseller için değişim tespit edilmektedir.

3.2. Deneysel Sonuçlar

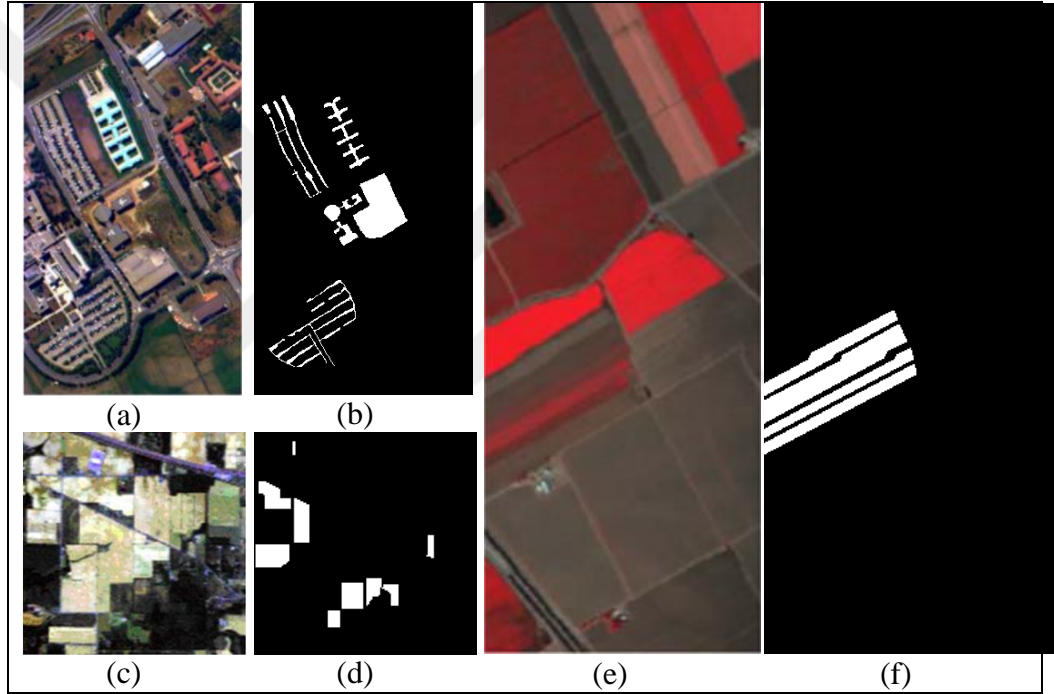
3.2.1. Deneysel veriler

Bu çalışmada Indian Pines, Pavia University, and Salinas isimli üç farklı hiperspektral veri seti kullanıldı. Indian Pines verisi Ulusal Havacılık ve Uzay İdaresi Havadan Görülebilir / Kızılötesi Görüntüleme Spektrometresi (AVIRIS) sensörü kullanılarak elde edilmiş olup, Haziran 1992 tarihinde Kuzeybatı Indiana'nın Indian Pine test alanı üzerinden toplanmış ve 145×145 piksel ve $0,4-2,5 \cdot 10^{-6}$ metre dalga boyu aralığında 224 spektral yansıma bandından oluşmaktadır. Bu görüntü daha büyük bir sahnenin bir alt kümesidir. Indian Pines verisinde sahnenin yaklaşık üçte ikisinde tarım arazileri, yaklaşık üçte birinde orman ve diğer bölümlerinde doğal bitki örtüleri bulunmaktadır. Bu görüntü 16 farklı sınıf içerir. Su emme bölgelerini kapsayan bantlar ([104-108], [150-163], 220 numaralı bantlar) çıkarılarak bantların toplam sayısı 200'e düşürülmüştür.

Pavia University veri seti, Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (ROSIS) sensörü tarafından toplanmıştır. Bu veri kümesi, İtalya'nın Pavia şehrini kapsayan 610×340 piksellik uzamsal kapsamaya sahip olup, DLR (Alman Havacılık ve Uzay Ajansı) tarafından yönetilen HySens projesi [32] altında

toplanmıştır. Veri seti su emme bantları çıkarılmadan önce 103 spektral bant içerir. Veri 0,43-um den 0,86-um spektral dalga boyuna ve 1,3 m uzamsal çözünürlüğe sahiptir. Dokuz sınıfı ile yaklaşık 42,776 etiketli piksel yer doğrusu haritası vardır.

Salinas sahnesi, Salinas Vadisi, California üzerinde 224-bant AVIRIS sensörü tarafından toplanmış ve göreceli yüksek uzamsal çözünürlük (3,7 metre piksel) ile karakterize edilmiştir. Kapsanan alan 217 örnek üzerinden 512 satır içerir. Indian Pines sahnesinde olduğu gibi su emme bantları ([108-112], [154-167], [224] sayılı bantlar) atılmıştır. Bu görüntü sebzeler, çıplak topraklar ve bağcılık alanlarını içerir ve yer doğrusu haritası 16 sınıf içermektedir.



Şekil 3.5. Veri setleri ve değişim yer doğrusu haritaları (a-b) Pavia Uni (c-d) Indian Pines (e-f) Salinas

Değişim tespiti yaklaşımının uygulanması için farklı zamanlarda alınmış iki görüntü gerektiği için ikinci görüntü referans (orijinal) görüntüden sentetik olarak üretilmiştir. Sentetik değişim oluşturmak için, her bir görüntü için doğruluk haritasına yerleştirilmiş sınıflardan rastgele bir kaç tane sınıf seçilmiştir. Daha sonra seçilen sınıfların piksel değerleri değiştirilmiştir. Bunun için 20 dB SNR değerinde beyaz Gauss gürültüsü eklenmiştir. Şekil 3.5’de değiştirilen veri setleri değişim haritaları ve Tablo 3.1’de değiştirilen sınıf bilgileri verilmiştir.

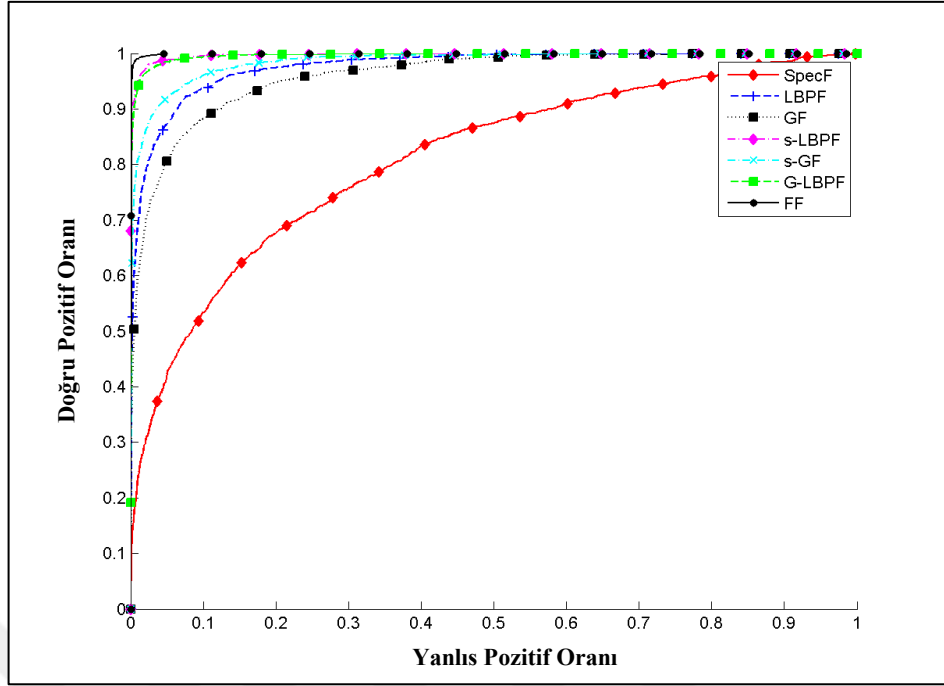
Tablo 3.1. Sentetik görüntülerin değiştirilmiş seçilen sınıflar

Görüntü	Değiştirilen sınıflar
Indian Pines	[4, 5, 6]
Pavia University	[5, 6, 7, 8]
Salinas scene	[11, 12, 13, 14]

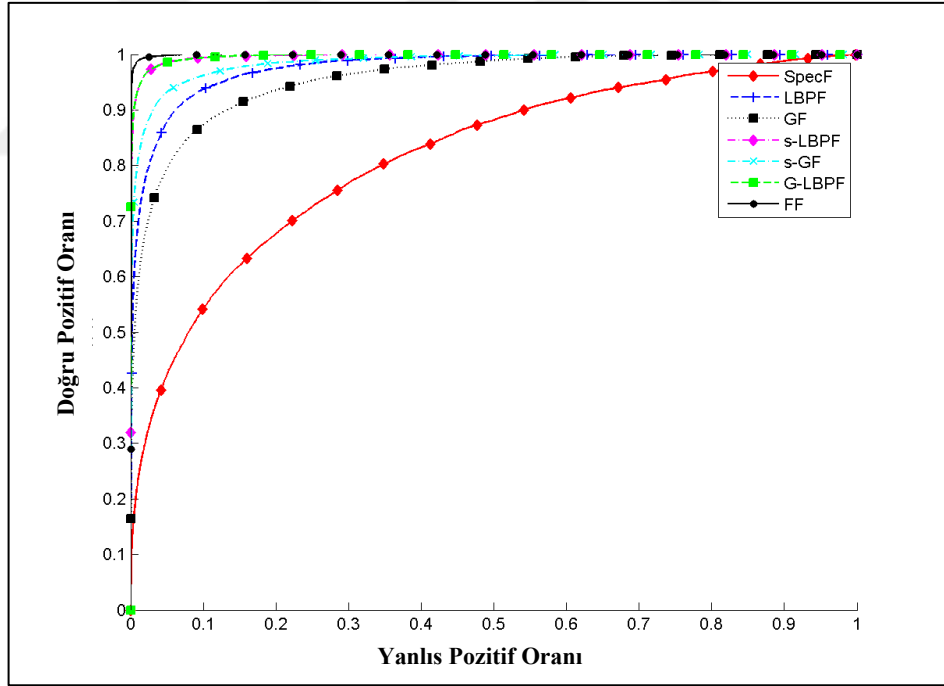
3.2.2. Deneysel sonuçlar

Hiperspektral görüntüler için tezde önerilen Uzamsal ve Spektral Özniteliklerin Kaynaştırılması temelli değişim tespiti yaklaşımının performansının değerlendirilmesi için farklı eşik değerleri kullanılarak elde edilen sonuçların doğru ve yanlış pozitif tespit oranını gösteren Alıcı İşletim Karakteristiği (Receiver Operating Characteristic - ROC) kullanılmıştır. Ayrıca üç veri seti kullanılarak elde edilen ROC eğrileri için Eğrinin Altındaki Alan (AUC) hesaplanmıştır.

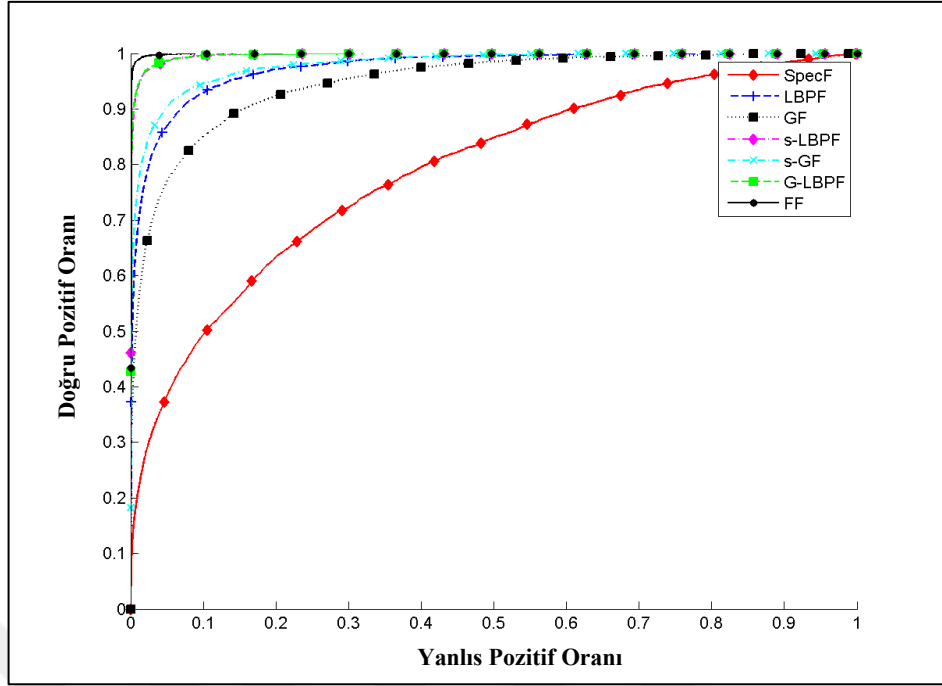
Üç veri seti kullanarak elde edilen ROC sonuçlar Şekil 3.6-3.9 şekillerinde gösterilmekte olup, tüm veri setleri ile test edilen tüm diğer kombinasyonların arasında tüm (LBF, Gabor ve spektral) Özniteliklerin Kaynaştırılması (FF) kullanılarak yapılan değişim tespitinin daima en iyi sonuçları ürettiği görülmektedir. Benzerlik ölçütü olarak kullanılan SAM, Öklid mesafesi gibi alternatif yaklaşımlara göre daha yüksek başarımlar sağladığı için tüm sonuçlar sadece SAM benzerlik ölçütü için raporlanmıştır.



Şekil 3.6. Indian Pines için deęişim tespiti ROC




Şekil 3.7. Pavia University için deęişim tespiti ROC

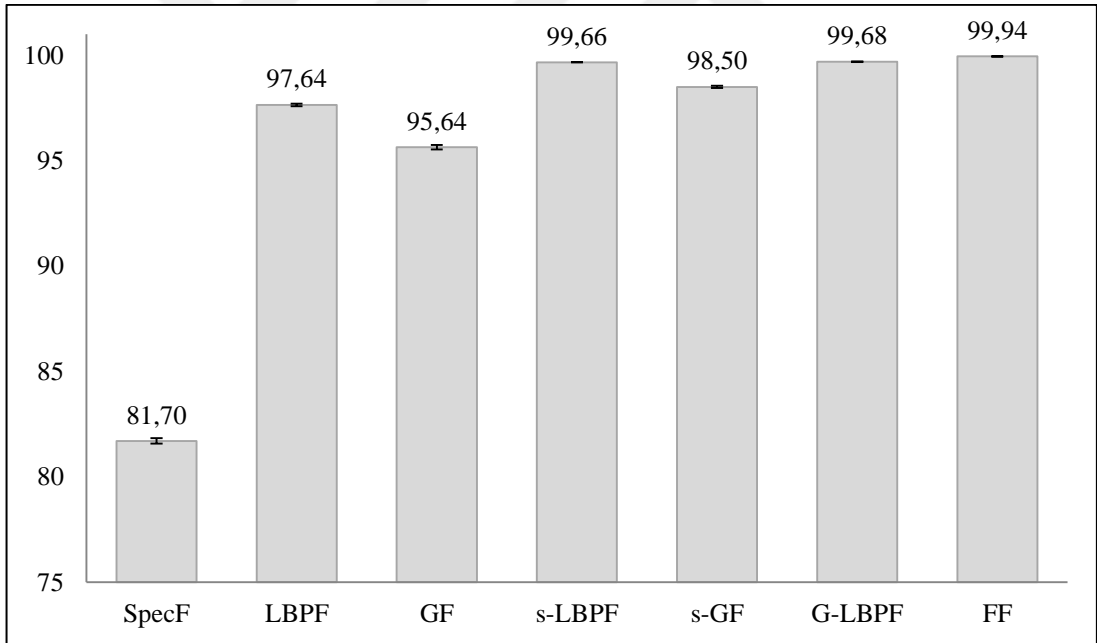


Şekil 3.8. Salinas için değişim tespiti ROC


Rakamsal değerler için ROC eğrilerinin altındaki alanlar (AUC) hesaplanabilir. Şekil 3,9-3,11’de ilgili veri setleri için farklı özniteliklerle elde edilen değişim tespit sonuçları için ROC eğrisi altındaki alan derğerli gösterilmiştir. Indian Pines için eğrinin altındaki alan (AUC) kullanarak en yakın performansın (G-LBP 99,73%) 0,23% bir farkla ikinci geldiği ve önerilen FF yönteminin, 99,96% değişim tespiti performansına sahip olduğunu göstermektedir. Pavia University veri seti için en yakın performans (G-LBP 99,68%) 0,26% bir farkla ikinci gelmekte olup FF yönteminin değişim tespiti performansı 99,94% dir. Son olarak FF yöntemi kullanılarak değişim tespitinin Salinas veri setindeki sonucu 99,95%’dir.



Şekil 3.9. Indian Pines için AUC



Şekil 3.10. Pavia University için AUC



Şekil 3.11. Salinas için AUC

4. SONUÇ VE ÖNERİLER

Bu tezde sunulan çalışma, hiperspektral görüntülerde uzamsal ve spektral özniteliklerin kaynaştırma yaklaşımı ile birleştirilmesi sonucu değişim tespit başarımının artırılmasına yönelik bir yaklaşımdır.

Literatürde, hiperspektral görüntülerde bulunan uzamsal özniteliklerin sağladığı faydaları kullanan çalışma sayısı sınırlıdır. Bu yüzden bu çalışmada, hem uzamsal doku bilgileri hem de spektral bilgileri kullanılabilen bir değişim tespiti yaklaşımını önerilmiştir.

Bu tezde, hem hiperspektral görüntülerdeki dokusal bilgileri hem de spektral imzaları kullanan bir değişim tespiti yaklaşımı önerilmiştir. Yerel ve global doku öznitelikleri üretmek amacıyla Doğrusal Tahmin Hatası (LPE) temelli bant seçimi sonrası Yerel İkili Örüntü (LBP) ve Gabor Filtresi temelli uzamsal öznitelikler çıkarılmıştır. Daha sonra, LBP, Gabor Filtresi sonuçları ve spektral imzalar birleştirilerek hem spektral hem de uzamsal özniteliklerden yararlanmak amacıyla bir kaynaştırma aşaması uygulanmıştır. Kaynaştırma aşaması uygulanmadan önce farklı öznitelikler aynı ölçüğe getirmek için verilerin bağımsız olarak normalleştirilmesi gerekmektedir. Son olarak değişim tespiti için karşılıklı piksel öznitelikler üzerinden Spektral Açık Eşleme (SAM) kullanılmıştır.

Deneysel sonuçlar, görüntü üzerindeki değişimleri tespit etmek için başarıyı geliştirmek amacıyla bantların doku bilgisinin kullanımının etkili bir yöntem olduğunu göstermiştir.

Tezde önerilen özniteliklerin kaynaştırılması yaklaşımı oluşan özniteliklerin yüksek bir boyuta sahip olmasına sebep olur ve işlem yükü artmaktadır. Gelecek çalışmalarda daha farklı öznitelik seçim yöntemleri araştırılacaktır.

KAYNAKLAR

- [1] Prasad S., Bruce L., Limitations of Principal Components Analysis for Hyperspectral Target Recognition, *IEEE Geosci. Remote Sens. Lett.*, 2008, **5**(4), 625-629.
- [2] Villa A., Benediktsson J. A., Chanussot J., Jutten C., Hyperspectral Image Classification with Independent Component Discriminant Analysis, *IEEE Trans. Geosci. Remote Sens.*, 2011, **49**(12), 4865-4876.
- [3] URL-1: <http://www.microimages.com/documentation/html/Tutorials/>, (Ziyaret tarihi: 15 April 2016).
- [4] URL-2: <http://www.azom.com/article.aspx?ArticleID=8495>, (Ziyaret tarihi: 20 May 2016).
- [5] Bagan H., Takeuchi W., Kinoshita T., Bao Y., Yamagata Y., Land Cover Classification and Change Analysis in The Horqin Sandy Land From 1975 to 2007, *IEEE J. Sel. Top. Appl.*, 2010, **3**(2), 168-177.
- [6] Xian G., Homer C., Updating The 2001 National Land Cover Database Impervious Surface Products To 2006 Using Landsat Imagery Change Detection Methods, *Remote Sens. Environ.*, 2010, **114**(8), 1676-1686.
- [7] Coppinand P., Bauer M., Digital Change Detection in Forest Cosystems with Remote Sensing Imagery, *RemoteSens.Rev.*, 1996, **13**(3-4), 207-234.
- [8] Pekel J.-F., Ceccato P., Vancutsem C., Cressman K., Vanbogaert E., Defourny P., Development And Application Of Multi-Temporal Colorimetric Transformation to Monitor Vegetation in The Desert Locust Habitat, *IEEE J. Sel. Topics. Appl. Earth Observ. Remote Sens.*, 2011, **4**(2), 318-326.
- [9] Vogelmann J.E., Kost J.R., Tolk B., Howard S., Short K., Xuexia C., Chengquan H., Pabst K., Rollins M. G., Monitoring Landscape Change For Landfire Using Multi-Temporal Satellite Imagery And Ancillary Data, *IEEE J. Sel. Topics. Appl. Earth Observ. Remote Sens.*, 2011, **4**(2), 252-264.
- [10] Smits P., Annoni A., Toward Specification-Driven Change Detection, *IEEE Transactions on Geoscience and Remote Sensing*, 2000, **38**(3), 1484-1488.

- [11] Malila W. A., Change Vector Analysis: An Approach For Detecting Forest Changes with Landsat, in *Proc. 6th Annu. Symp. Machine Processing of Remotely Sensed Data*, West Lafayette, Indiana, USA, 3-6 June 1980.
- [12] Dopido I., Villa A., Plaza A., Gamba P., A Quantitative and Comparative Assessment of Unmixing-Based Feature Extraction Techniques for Hyperspectral Image Classification, *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, 2012, **5**(2), 421-435.
- [13] Zhang Q., Zhang L., Yang Y., Tian Y., Weng L., Local Patch Discriminative Metric Learning for Hyperspectral Image Feature Extraction, *IEEE Geosci. Remote Sensing Lett.*, 2014, **11**(3), 612-616.
- [14] Wen J., Tian Z., Liu X., Lin W., Neighborhood Preserving Orthogonal PNMFFeature Extraction for Hyperspectral Image Classification, *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, 2013, **6**(2), 759-768.
- [15] Yin J., Gao G., Jia X., Using Hurst and Lyapunov Exponent For Hyperspectral Image Feature Extraction, *IEEE Geosci. Remote Sensing Lett.*, 2012, **9**(4), 705-709.
- [16] Kumar G., Bhatia P., A Detailed Review of Feature Extraction in Image Processing Systems, *2014 Fourth International Conference on Advanced Computing & Communication Technologies*, Rohtak, Haryana, India, 8-9 February 2014.
- [17] Jiang J., Li X., Zhang G., SIFT Hardware Implementation for Real-Time Image Feature Extraction, *IEEE Transactions on Circuits and Systems for Video Technology*, 2014, **24**(7), 1209-1220.
- [18] Chang C.-I., Du Q., Sun T.-L., Althouse M. L. G., A Joint Band Prioritization and Band Decorrelation Approach to Band Selection for Hyperspectral Image Classification, *IEEE Trans. Geosci. Remote Sens.*, 1999, **37**(6), 2631-2641.
- [19] Ifarraguerri A., Visual Method for Spectral Band Selection, *IEEE Geosci. Remote Sens. Lett.*, 2004, **1**(2), 101-106.
- [20] Backer S. D., Kempeneers P., Debruyn W., Scheunders P., A Band Selection Technique for Spectral Classification, *IEEE Geosci. Remote Sens. Lett.*, 2005, **2**(3), 319-323.
- [21] Bajcsy P., Groves P., Methodology for Hyperspectral Band Selection, *Photogramm. Eng. Remote Sens.*, 2004, **70**(7), 793-802.
- [22] Du Q. Yang H., Similarity-Based Unsupervised Band Selection for Hyperspectral Image Analysis, *IEEE Geosci. Remote Sens. Lett.*, 2008, **5**(4), 564-568.
- [23] Ojala T., Pietikainen M., Maenpaa T. T., Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Pattern, *IEEE Trans. Pattern Analysis Mach. Intell.*, 2002, **24**(7), 971-987.

- [24] URL-3: <http://jultika.oulu.fi/Record/isbn951-42-7076-2>, (Ziyaret tarihi: 06 May 2016).
- [25] Li W., Chen C., Su H., Du Q., Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification, *IEEE Trans. Geosci. Remote Sensing*, 2015, **53**(7), 3681-3693.
- [26] Li W., Du Q., Gabor-Filtering-Based Nearest Regularized Subspace for Hyperspectral Image Classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(4), 1012-1022.
- [27] Kang X., Li S., Benediktsson J., Feature Extraction of Hyperspectral Images with Image Fusion and Recursive Filtering, *IEEE Trans. Geosci. Remote Sensing*, 2014, **52**(6), 3742-3752.
- [28] Tan K., Li E., Du Q., Du P., Hyperspectral Image Classification Using Band Selection and Morphological Profiles, *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 2014, **7**(1), 40-48.
- [29] Singh A., Review Article Digital Change Detection Techniques Using Remotely-Sensed Data, *Int. J. Remote Sens.*, 1989, **6**(10), 989-1003.
- [30] Coppin P., Bauer M., Digital Change Detection in Forest Ecosystems with Remote Sensing Imagery, *Remote Sens. Rev.*, 1996, **13**(3-4), 207-234.
- [31] Wulder M. A., White J. C., Goward S. N., Masek J. G., Irons J. R., Herold M., Cohen W. B., Loveland T. R., Woodcock C. E., Landsat continuity: Issues and Opportunities for Land Cover Monitoring, *Remote Sens. Environ.*, 2008, **1**(12), 955-969.
- [32] Lambin E.F., Strahler A.H., Change-Vector Analysis in Multitemporal Space: A Tool to Detect and Categorize Landcover Change Processes Using High Temporalresolution Satellite Data, *Remote Sensing of Environment*, 1994, **48**(2), 231-244.
- [33] Fung T., LeDrew E., Application of Principal Components Analysis to Change Detection, *Photogrammetric Engineering and Remote Sensing*, 1987, **53**(12), 1649-1658.
- [34] Wu C., Zhang L., Du B., Targeted change detection for stacked multi-temporal hyperspectral image, *4th Workshop on Hyperspectral Image and Signal Processing (WHISPERS)*, Shanghai, China, 4-7 June 2012.
- [35] Wu C., Du B. Zhang L., A Subspace-Based Change Detection Method for Hyperspectral Images, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, **6**(2), 815-830.
- [36] Erturk A., Plaza A., Informative Change Detection by Unmixing for Hyperspectral Images, *IEEE Geoscience and Remote Sensing Letters*, 2015, **12**(60), 1252-1256.

- [37] Li Y., Davis C., Unsupervised Change Detection in High Resolution Satellite Imagery from Fusion of Spectral and Spatial Information, *IGARSS 2008 - IEEE International Geoscience and Remote Sensing Symposium*, Boston, Massachusetts, USA, 6-11 July 2008.
- [38] URL-4: https://en.wikipedia.org/wiki/Hyperspectral_imaging, (Ziyaret tarihi: 06 May 2016).
- [39] Qian S., Dimensionality Reduction of Multidimensional Satellite Imagery, *SPIE Newsroom*, DOI:10.1117/2.1201102.003560.
- [40] URL-5: <http://www.rncan.gc.ca/sciences-terre/surface-terrestre-vegetation/couverture-terrestre/9147>, (Ziyaret tarihi: 06 May 2016).
- [41] URL-7: http://ijiset.com/v1s4/IJSET_V1_I4_27.pdf, (Ziyaret tarihi: 07 Ocak 2017).
- [42] URL-8: <http://info.asprs.org/publications/proceedings/tampa2007/0081.pdf>, (Ziyaret tarihi: 14 January 2017).
- [43] Tan K., Jin X., Plaza A., Wang X., Xiao L., Du P., Automatic Change Detection in High-Resolution Remote Sensing Images by Using a Multiple Classifier System and Spectral–Spatial Features, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, **9**(8), 3439-3451.

KİŞİSEL YAYINLAR ve ESERLER

- [1] **Alraimi A.**, Ertürk S., Öznitelik Çıkartımı Ve Sınıflandırma Yönteminin Hiperspektral Imge Sınıflandırma Başarımına Etkisi, *IEEE 24th Signal Processing And Communications Applications Conference (SIU'2016)*, Zonguldak, Türkiye, 16-18 Mayıs 2016.



ÖZGEÇMİŞ

1990 yılında Yemen – Hodeidah şehrinde doğdu. İlk öğrenimi Elnahdhah İlköğretim okulunda, ve lise öğrenimini Almanar Lisesi'nde tamamladı. 2008 yılında Malezya'da girdiği Infrastructure University Kuala Lumpur (IUKL) Information Technology (Hons) in Network Technology bölümü'nden 2012 yılında mezun oldu. 2013 yılında başladığı Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda Yüksek Lisans Öğrenimini devam etmektedir.

