

**ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**DOKTORA TEZİ**

**HİPERSPEKTRAL VERİDE DOĞRUSAL OLMAYAN KARIŞMA DURUMU İÇİN  
BOLLUK HARİTALARININ ELDE EDİLMESİ**

**Yücel ÇİMTAY**

**ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ANKARA  
2018**


**Her hakkı saklıdır**

## TEZ ONAYI

Yücel ÇİMTAY tarafından hazırlanan “Hiperspektral Veride Doğrusal Olmayan Karışma Durumu İçin Bolluk Haritalarının Elde Edilmesi” adlı tez çalışması 08/06/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda **DOKTORA TEZİ** olarak kabul edilmiştir.

**Danışman** : Prof. Dr. Hakkı Gökhan İLK   
Ankara Üniversitesi / Elektrik-Elektronik Mühendisliği Anabilim Dalı

### Jüri Üyeleri:

**Başkan:** Prof. Dr. Gözde BOZDAĞI AKAR   
Orta Doğu Teknik Üniversitesi / Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Üye** : Prof. Dr. Hakkı Gökhan İLK   
Ankara Üniversitesi / Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Üye** : Doç. Dr. Hakkı Alparslan ILGIN   
Ankara Üniversitesi / Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Üye** : Dr. Öğr. Üyesi Osman Serdar GEDİK   
Yıldırım Beyazıt Üniversitesi / Bilgisayar Mühendisliği Anabilim Dalı

**Üye** : Dr. Öğr. Üyesi Selçuk TAŞCIOĞLU   
Ankara Üniversitesi / Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Yukarıdaki sonucu onaylarım.**

**Prof. Dr. Atila YETİŞEMİYEN**  
**Enstitü Müdürü**

## ETİK

Ankara Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

08.06.2018



Yücel ÇİMTAY

## ÖZET

Doktora Tezi

### HİPERSPEKTRAL VERİDE DOĞRUSAL OLMAYAN KARIŞMA DURUMU İÇİN BOLLUK HARİTALARININ ELDE EDİLMESİ

Yücel ÇİMTAY

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Hakkı Gökhan İLK

Hiperspektral görüntüleme, bir piksele ait spektrum tipik olarak birkaç farklı materyalin yansıma spektrumunun karışımından meydana gelmektedir. Hiperspektral ayrıştırma, karışımdaki son öğelerin bolluk değerlerinin belirlenmesi işlemidir. Hiperspektral karışım probleminin çözümü için birçok farklı model uygulanmıştır. En basit olanı doğrusal karışım modelidir. Fakat karışım olgusunun çoğunlukla doğrusal olmadığı tespit edilmiştir. Bu yüzden homojen karışım modeli ve bilinear modeller uygulanmıştır. Modellerin çoğunluğu materyallerden veya materyaller arasında sadece yansıma durumunu ele almışlardır. Fakat özellikle bitki ekili bölgeler düşünüldüğünde soğurma ve iletim özellikleri de spektral karışımı etkileyen önemli faktörler haline gelmektedirler. Bu nedenle soğurma ve iletim özellikleri de spektral karışım probleminde dikkate alınmalıdır. Tezde uygulanan ayrıştırmada materyallerin iletim ve soğurma spektrumları da ele alınmıştır. Bolluk haritalarının kestirimi bitki örtüsü sınıflandırmada yaygın olarak kullanılmıştır. Bu nedenle bolluk değer kestirimindeki hassasiyet, sınıflandırma hassasiyetini de etkilemektedir. Tezde hiperspektral görüntülerin spektral ayrıştırması ve bitki örtüsünün sınıflandırılması için yeni bir bilinear model geliştirilmiştir. Model, iletim, soğurma ve yansıma spektrumlarını dikkate alarak spektral ayrıştırma ile bitki örtüsü sınıflaması yapmaktadır. Tezde elde edilen sonuçlar, önerilen yöntemin piksel kestirim hatası yönünden doğrusal model ve en çok bilinen bilinear modellere üstünlük sağladığını göstermektedir. Bununla birlikte, yöntemin sınıflandırma başarısı anlamında Spektral Açık Eşleyici (Spectral Angle Mapper) ve Eşleşen Filtre (Matched Filter) gibi çok bilinen sınıflandırma yöntemlerine üstünlük sağladığı görülmüştür.

**Haziran 2018, 108 sayfa**

**Anahtar Kelimeler:** Spektral ayrıştırma, bilinear model, gürültülü bant eleme, iletim, bant seçimi, bitki örtüsü sınıflandırma

## ABSTRACT

Ph. D. Thesis

### OBTAINING ABUNDANCE MAPS IN THE CASE OF NONLINEAR SPECTRAL MIXING IN HYPERSPECTRAL DATA

Yücel ÇİMTAY

Ankara University  
Graduate School of Natural and Applied Sciences  
Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Hakkı Gökhan İLK

In hyperspectral imagery, the spectrum of one pixel typically consists of a mixture of the reflectance spectra of several materials. Hyperspectral unmixing is the task of identifying the abundances of end members. Different unmixing models have been implemented to solve the hyperspectral unmixing problems. The simplest one is the linear mixing model. However, it has been recognized that mixing phenomena is mostly nonlinear. Therefore, intimate mixture model and bilinear models have also been implemented. Most of the models consider only the reflection case from and between the materials. However, especially in regions like vegetated areas, absorption and transmittance are also important facts which affect the spectral mixture. So, they should be taken into account when dealing with unmixing problems in order to handle accurate results. In this thesis, for spectral unmixing, transmittance and absorption interactions are also handled. Estimation of abundance maps is widely used for classifying the land cover. Therefore the accuracy of abundance estimation affects the accuracy of classification. In this study, a novel bilinear mixing model is developed for unmixing of hyperspectral imagery and classifying the land cover. The model takes into account transmittance, absorption and reflection spectrum. The results obtained in the thesis show that the proposed model is superior, in terms of pixel reconstruction error, when compared to that of linear and other well-known bilinear models. Furthermore, the classification accuracy is much more successful than the well-known classification methods like Spectral Angle Mapper and Matched Filter.

**June 2018, 108 pages**

**Key Words:** Spectral unmixing, bilinear model, noisy band elimination, transmittance, band selection, land cover classification

## TEŐEKKÖR

Doktora eđitimime baŐladıđım ilk günden itibaren maddi ve manevi desteklerini esirgemeyen, engin akademik bilgisiyle, alıŐmalarımda yol gosteren sayın hocam Prof. Dr. Hakkı Gökhan İLK'e (Ankara Üniversitesi, Elektrik-Elektronik Mühendisliđi), alıŐmalarım boyunca her zaman yanımda olan eŐim Saliha İMTAY'a ve kızım Zeynep İMTAY'a, her zaman dualarıyla bana destek olan sevgili aileme, en derin duygularıyla teŐekkürlerimi sunarım.

Yücel İMTAY

Ankara, Haziran 2018

# İÇİNDEKİLER

## TEZ ONAY SAYFASI

ETİK .....	i
ÖZET .....	ii
ABSTRACT .....	iii
TEŞEKKÜR .....	iv
SİMGELER DİZİNİ .....	vii
ŞEKİLLER DİZİNİ .....	ix
ÇİZELGELER DİZİNİ .....	xi
1. GİRİŞ .....	1
1.1 Uzaktan Algılama Platformları .....	2
1.1.1 Yer platformu .....	2
1.1.2 Hava platformu .....	3
1.1.3 Aktif uzaktan algılama .....	3
1.1.4 Uydu platformu .....	4
1.2 Kullanılan Enerjiye Göre Uzaktan Algılama .....	5
1.2.1 Pasif uzaktan algılama .....	5
1.3 Bant Sayısına Göre Uzaktan Algılama Verileri .....	6
1.3.1 Tek bantlı veri .....	6
1.3.2 Çok bantlı veri .....	7
1.3.3 Hiper bantlı veri .....	7
1.4 Elektromanyetik Radyasyon .....	7
1.5 Hiperspektral Görüntüleme ve Özellikleri .....	10
1.6 Uzaktan Algılamada Çözünürlük Kavramı .....	13
1.6.1 Spektral çözünürlük .....	13
1.6.2 Radyometrik çözünürlük .....	14
1.6.3 Zamansal çözünürlük .....	15
1.6.4 Uzamsal çözünürlük .....	15
1.7 Spektral Karışma .....	16
1.8 Tezin Amacı ve Özgünlüğü .....	17
2. KAYNAK ÖZETLERİ .....	19
2.1 Spektral Ayrıştırma .....	19
2.1.1 Doğrusal yaklaşım .....	19
2.1.2 Doğrusal olmayan yaklaşım .....	20
2.2 Sınıflandırma .....	31
2.2.1 Piksel tabanlı sınıflandırma .....	32

2.2.2	Alt Piksel tabanlı sınıflandırma.....	33
2.3	Eleştiri ve Teori.....	34
3.	<b>MATERYAL VE YÖNTEM</b> .....	37
3.1	Hiperspektral Ham Verinin Anlamlandırılması.....	39
3.1.1	Radyometrik düzeltme .....	39
3.1.2	Atmosferik düzeltme .....	41
3.2	Spektral İmzalardan Gerçek Yansıma ve İletim Spektrumunun Hesaplanması .....	45
3.3	Bilineer Modelin Oluşturulması.....	49
3.4	Bolluk Değer Kestirimi.....	52
3.5	Piksel Spektrum Kestirimi.....	52
3.6	Kestirim Hatası Hesaplama .....	53
3.7	Önerilen Yöntemle Bitki Örtüsü Sınıflandırma .....	54
3.7.1	Gürültülü bant eleme .....	54
3.7.2	Bant seçimi .....	57
3.7.3	Gürültülü bant eleme ve bant seçimi algoritma akışı.....	60
3.7.4	Sınıflandırma yöntemi.....	62
4.	<b>ARAŞTIRMA BULGULARI</b> .....	64
5.	<b>TARTIŞMA VE SONUÇ</b> .....	80
	<b>KAYNAKLAR</b> .....	83
	<b>EK 1: Kullanıcı Ara Yüzü Uygulaması</b> .....	90
	<b>ÖZGEÇMİŞ</b> .....	94

## SİMGELER DİZİNİ

$\lambda$	Dalga boyu
f	Frekans
A	Genlik
c	Işık hızı
kW	Kilowatt
m	Metre
m <sup>2</sup>	Metrekare
$\mu$ m	Mikrometre
nm	Nanometre
T	Periyot
%	Yüzde
t	Zaman

### Kısaltmalar

ABA	Anlık Bakış Alanı
BA	Bakış Alanı
BAO_Max	Bands Add-On Maximum
BST	Bilineer Spektrum Terimleri
BNOK	Bolluk Değerleri Negatif Olamaz Koşulu
BT1OK	Bolluk Değerleri Toplamı 1 Olma Koşulu
CCD	Charge Coupled Device
CEM	Constrained Energy Minimization
Corr	Correlation
Cos	Cosinus
Cov	Covariance
ÇKP	Çok Katmanlı Perseptron
EKKH	En Küçük Kare Hata
GBM	Generalized Bilinear Model
ISODATA	Iterative Self-Organization Data Analysis
KKD	Kesikli Kosinüs Dönüşümü
MDC	Mahalanobis Distance Classifier
MDMC	Minimum Distance-to-Means Classifier
MF	Matched Filter
MLC	Maximum Likelihood Classifier
MVPCA	Multi View Principal Component Analysis
NDVI	Normalized Difference Vegetation Index
KNN	K-Nearest Neighbors
KOKH	Kök Ortalama Kare Hata
PPNM	Polynomial Post-Nonlinear Model
PCA	Principal Component Analysis
SAD	Spectral Angle Distance
SAR	Sentetik Açıklıklı Radar
SOM	Self Organizing Maps
SPABS	Sparse Band Selection
SAM	Spectral Angle Mapper
SID	Spectral Index Data

SNMF  
SSR  
VNIR  
TBA

Spectral Nonnegative Matched Filter  
Symmetric Sparse Representation  
Visible Near Infrared  
Temel Bileşen Analizi



## ŞEKİLLER DİZİNİ

Şekil 1.1 Yer platformunda uzaktan algılama ( <a href="https://eros.usgs.gov">https://eros.usgs.gov</a> 2015) .....	2
Şekil 1.2 Hava platformunda uzaktan algılama ( <a href="https://spar3d.com">https://spar3d.com</a> 2013) .....	3
Şekil 1.3 Aktif algılama .....	4
Şekil 1.4 Uzay platformunda uzaktan algılama ( <a href="http://rs.geo.tuwien.ac.at">http://rs.geo.tuwien.ac.at</a> 2014) .....	5
Şekil 1.5 Pasif algılama.....	6
Şekil 1.6 Pankromatik görüntü örneği ( <a href="http://cartospace.com.tr">http://cartospace.com.tr</a> 2016) .....	7
Şekil 1.7 Elektromanyetik dalga .....	8
Şekil 1.8 Dalga ve özellikleri.....	9
Şekil 1.9 Elektromanyetik spektrum.....	9
Şekil 1.10 Doğrusal dizin görüntüleme sistemi .....	11
Şekil 1.11 Görüntüleme sistemi içyapısı.....	12
Şekil 1.12 Piksel ışınma spektrumu ( <a href="https://belspo.be">https://belspo.be</a> 2010) .....	12
Şekil 1.13 Düşük (altta) ve yüksek (üstte) spektral çözünürlük.....	14
Şekil 1.14 Aynı sahnenin farklı radyometrik çözünürlüklü görüntüleri .....	15
Şekil 1.15 Aynı sahnenin farklı uzamsal çözünürlükleri ( <a href="https://hvkk.tsk.tr">https://hvkk.tsk.tr</a> 2012) .....	16
Şekil 1.16 Spektral karışımın oluşumu ( <a href="https://www.slideshare.net/">https://www.slideshare.net/</a> 2017) .....	17
Şekil 2.1 Doğrusal karışım modeli (Dobigeon vd. 2013) .....	19
Şekil 2.2 Homojen karışım modeli (Dobigeon vd. 2013) .....	21
Şekil 2.3 Bilineer karışım modeli (Dobigeon vd. 2013) .....	23
Şekil 2.4 Işık-Madde etkileşimi .....	34
Şekil 2.5 Spektrometre ve görüntü piksel imzası.....	36
Şekil 3.1 Sayısal değer-Işınma-Yansıma dönüşümü.....	39
Şekil 3.2 Örnek bir piksel için sayısal değer spektrumu .....	40
Şekil 3.3 Örnek bir piksel için ışınma (radyans) spektrumu .....	41
Şekil 3.4 Atmosfere ulaşan enerji spektrumu .....	42
Şekil 3.5 Atmosfer iletim spektrumu .....	42
Şekil 3.6 Atmosferik düzeltme fiziksel ifadesi .....	43
Şekil 3.7 Hiperspektral veri küpü .....	44
Şekil 3.8 Örnek bir piksel için yansıma (reflektans) spektrumu .....	45
Şekil 3.9 Kontak prop tekniğiyle spektrum ölçümü.....	46
Şekil 3.10 Siyah ve beyaz arka plan yansıma spektrumu .....	47
Şekil 3.11 Siyah ve beyaz arka plan üzerinde pamuk yaprağı spektrası.....	47
Şekil 3.12 Spektrometre ile spektrum ölçümü: Yaprak-siyah madde etkileşimi .....	48
Şekil 3.13 Spektrometre ile spektrum ölçümü: Yaprak-beyaz arka plan etkileşimi .....	48
Şekil 3.14 Yöntem bilineer model terimleri fiziksel gösterimi.....	50
Şekil 3.15 Bilineer model tek ve etkileşim spektrumları .....	51
Şekil 3.16 Korelasyon katsayıları 100-binlik histogram grafiği .....	56
Şekil 3.17 Örnek bir spektra için tüm spektra, sinyal bant vektörü ve sinyal bantları.....	57
Şekil 3.18 İki boyutlu uzayda iki vektör ve aralarındaki açı.....	58
Şekil 3.19 Gürültülü bant eleme ve bant seçimi işlemi.....	61
Şekil 3.20 Bitki ve toprak spektrasında gürültülü bant eleme ve bant seçimi sonucu .....	62
Şekil 3.21 Önerilen yöntem için sınıflandırma şeması .....	63
Şekil 4.1 Pamuk tarlaları yer fotoğrafları.....	64
Şekil 4.2 11 Haziran görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi.....	67
Şekil 4.3 25 Haziran görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi.....	67
Şekil 4.4 12 Ağustos görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi .....	68
Şekil 4.5 11 Haziran görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları .	69
Şekil 4.6 25 Haziran görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları .	69
Şekil 4.7 12 Ağustos görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları .	70

Şekil 4.8 Tüm görüntüde ortalama kestirim hataları.....	71
Şekil 4.9 Bölgeden alınan pamuk spektrası ve Gerede'den edinilen pamuk spektrası .....	72
Şekil 4.10 Pamuk ve mısır yaprağı spektral imzaları.....	78
Şekil 4.11 Pamuk görüntüsü sınıflandırma sonuçları. ....	79
Şekil 4.12 Mısır görüntüsü sınıflandırma sonuçları.....	79



## ÇİZELGELER DİZİNİ

Çizelge 4.1 Bilineer modeller, parametreler ve kısıtlamalar.....	65
Çizelge 4.2 Bölgeden alınan spektra ile Gerede'den edinilen spektra için kestirim sonuçları ...	73
Çizelge 4.3 Doğrusal ve bazı bilineer yöntemler için hesaplanan SAU hata değerleri.....	73
Çizelge 4.4 Doğrusal ve bazı bilineer yöntemler için hesaplanan KOKH değerleri.....	74
Çizelge 4.5 Doğrusal ve bazı bilineer yöntemler için hesaplanan bolluk değer haritası.....	75
Çizelge 4.6 Farklı pikseller için hesaplanan bolluk değer haritaları .....	76
Çizelge 4.7 Bant seçiminin ortalama kestirim hatasına etkisi.....	77



## 1. GİRİŞ

Gözlem yapma, insanlığın ilk varoluşundan beri en önemli ve ilgi çekici kavramlardan birisi olmuştur. Bilgi toplama, bilgiyi değerlendirme ve anlamlandırma canlılar için her zaman bir ihtiyaç olagelmıştır. Uzaktan algılama bu gözlem dünyasında kullanılan en önemli kaynaklardan ve yöntemlerden birisidir. Uzaktan algılama kavramı, cisimler hakkında uzaktan bilgi toplama bilimi olarak düşünülebilir. Arada fiziksel bir temas olmaksızın cisimler hakkında uzaktan bilgi toplanması veya arada mekanik bir temas olmaksızın bir cisimden yayılan ışınımın nitelik ve nicelik yönünden değerlendirilmesi ile cismin özelliklerinin uzaktan ortaya konması ve ölçülmesi şeklinde tanımlanabilir (Nebiye 2014). Uzaktan algılama elektromanyetik spektrumda hareket eden radar, ışık, termal dalgalar ile olabildiği gibi, cisimlerin titreşmesiyle meydana gelen ses vasıtasıyla da gerçekleşebilir. Uzaktan algılamanın avantajlarından bazıları şöyle sıralanabilir: Geniş kapsama alanı elde edilmesi, nesnelerin gözle görülemeyen özelliklerinin tespit edilebilmesi, hızlı ve güncel bilgi toplanabilmesi (Kavzoğlu 2016). Uzaktan algılama ilk olarak askeri alanda uygulanmıştır. İlerleyen zamanlarda uyduların kullanılmasıyla birlikte, haritacılıkta sayısal arazi modeli üretimi; hidrolojide su kaynakları yönetimi, su kalitesi analizleri; ziraat alanında bitki tipini ayırma, bitki gelişimi izleme, bitki yıllık ürün (rekolte) tahmini; jeolojide maden arama ve deprem araştırmaları; ormancılıkta orman türlerinin haritalanması, ağaç hastalıklarının izlenmesi; savunma alanında mayın, patlayıcı ve kamuflaj tespiti gibi alanlarda da kullanılagelmıştır. Optik uzaktan algılama, 1839 yılında fotoğrafın icadı ile başlayıp, 1980'li yıllarda hiperspektral sensörlerin üretilmesi ile günümüze kadar uzanır. Kısa süre içerisinde teknolojinin gelişimiyle birlikte çok hızlı ve büyük gelişim göstererek hayatın her alanında vazgeçilmez bir bilgi toplama teknolojisi haline gelmiştir. İlk fotoğraf makineleri siyah-beyaz görüntü ve çok düşük hızda video çekebilmesine rağmen, günümüzde çok yüksek çözünürlükte ve hızda görüntü ve video çekimi yapılabilmektedir. Bununla birlikte çok yüksek sayıda bantta görüntü çekebilmek mümkün hale gelmiştir. Bu durum, gözle görülemeyen ayrıntıların yakalanabilmesine ve işlenebilmesine olanak sağlamıştır.

## 1.1 Uzaktan Algılama Platformları

Uzaktan algılama, kullanılan platforma göre üç temel gruba ayrılmıştır. Bunlar: yer, hava ve uydu platformlarıdır.

### 1.1.1 Yer platformu


Yer platformunda uzaktan algılama, genellikle yüksekliği yere çok yakın platformlara monte edilen sensörler ile sağlanmaktadır. Yer platformları, detaylı analiz durumunda tercih edilmektedir. Yer platformunun avantajı görüntülerde elde edilen mekânsal çözünürlüğün genellikle yüksek olmasıdır. Çözünürlük yüksek olduğunda elde edilen verideki detay da fazla olmaktadır. Yer platformunun dezavantajı ise görüntülenebilen anlık alanın küçük olmasıdır. Elde edilen veri görece dar bir alanı kapsayabilmektedir. Kamera ve radar, yer platformunda kullanılan sensörlere örnekleridir. Bir yer platformu örneği Şekil 1.1’de gösterilmiştir.



Şekil 1.1 Yer platformunda uzaktan algılama (<https://eros.usgs.gov> 2015)

### 1.1.2 Hava platformu

Hava platformları, daha yüksekten veri elde edebilmek için kullanılırlar ve genel anlamda uçak, helikopter, insansız hava aracı gibi uçuş platformlarını ifade ederler. Hava platformlarına takılan görüntüleme sensörleriyle yer platformlarına göre daha az detayda ve buna karşılık daha geniş alanlarda görüntü verisi toplanabilmektedir. Hava platformlarından elde edilen görüntü çözünürlüğü ve detay seviyesi yer platformlarına göre daha düşük kalmasına rağmen, son yıllarda sensör teknolojisinin çok hızlı bir şekilde gelişme göstermesiyle birlikte artık çözünürlük anlamında çok değerli görüntü verileri elde edilebilmektedir. Hava platformu için bir örnek Şekil 1.2’de gösterilmiştir.



Şekil 1.2 Hava platformunda uzaktan algılama (<https://spar3d.com> 2013)

### 1.1.3 Aktif uzaktan algılama


Aktif uzaktan algılama, algılama platformunun enerjisi kendisinin sağladığı durumdur. Algılanacak olan nesneye çarpan bu enerjinin bir kısmı geri dönmektedir. Geri dönen enerji, sensör tarafından algılanarak nesne hakkında veriler elde edilmektedir. En önemli aktif sensör kaynağı örnekleri fluro-lazer ve SAR (Sentetik açıklıklı radar) dır. Aktif sensörlerin avantajları, istenilen herhangi bir zamanda kullanılabilmeleri ve

istenilen dalga boyunun ayarlanmasıyla özellikle güneş enerjisinde bulunamayan dalga boylarında bilgi verme özellikleridir. Dezavantajı ise kullanılması gereken enerjinin yüksek miktarda olma zorunluluğudur. Aktif uzaktan algılama şekil 1.4'te gösterilmiştir.



#### 1.1.4 Uydu platformu

Uydu üzerine monte edilen görüntüleme sensörleriyle, uzay platformlarından görüntü elde edilmektedir. LANDSAT ve SENTINEL uyduları bunun en önemli örneklerindedir. Türkiye’de GÖKTÜRK uydusu üzerinde milli görüntüleme aygıtları mevcut durumdadır ve bu aygıtlar askeri istihbarat, sivil alanda tarımsal analiz, zirai mücadele, çevre kirliliği, doğal afet izleme gibi birçok alanda kullanılmaktadır. Şekil 1.3’te bir uydu platformundan görüntü verisinin elde edilmesi gösterilmektedir. Uydu platformları sayesinde çok büyük alanlar görüntülenebilmekte ve birçok analiz hızlı bir şekilde gerçekleştirilebilmektedir. Buna karşılık elde edilen verinin çözünürlüğü ve detay seviyesi düşük kalmaktadır.




Şekil 1.4 Uzay platformunda uzaktan algılama (<http://rs.geo.tuwien.ac.at> 2014)

## 1.2 Kullanılan Enerjiye Göre Uzaktan Algılama

Uzaktan algılama, algılama sırasında kullanılan enerjiye göre aktif ve pasif algılama olarak iki gruba ayrılmaktadır.

### 1.2.1 Pasif uzaktan algılama

Pasif uzaktan algılama, algılama platformunun enerjiyi kendisinin sağlayamadığı ya da izlenebilirlik nedeniyle enerjiyi sağlamasının güvenli olmadığı ve doğal enerji kaynaklarına ihtiyaç duyulduğu durumdur. Güneş enerjisinin aktif olduğu zamanlarda, nesnelere yayılan enerji ölçülür ve nesnelere hakkında veri toplanır. Ayrıca güneş ışığının olmadığı fakat termal enerjinin var olduğu zamanlarda da bu enerjinin yeterli olması koşuluyla pasif sensörler ile algılama yapılabilmektedir. Kameralar pasif sensörlere en önemli örneklerden birisidir. Aktif uzaktan algılama şekil 1.5'te gösterilmiştir.



### 1.3 Bant Sayısına Göre Uzaktan Algılama Verileri

Uzaktan algılamada elde edilen veri bant sayısına göre tek bantlı, çok bantlı veya hiper bantlı olabilmektedir.

#### 1.3.1 Tek bantlı veri

Tek bantlı (pankromatik) veri elektromanyetik spektrumun belirli bir dalga boyu aralığını kapsayan tek bantlı veridir. Pankromatik görüntü sensörlerine bazı örnekler, Worldview-1, IKONOS PAN ve SPOT HRV-PAN'dır. Şekil 1.6 bir pankromatik görüntü örneğini göstermektedir.



Şekil 1.6 Pankromatik görüntü örneği (<http://cartospace.com.tr> 2016)

### **1.3.2 Çok bantlı veri**

Çok bantlı (multispektral) veriler, birden çok banttan (3-10) oluşan verilerdir. Multispektral veri elde edilen sensörlere Landsat 7 ETM, SENTINEL ve IKONOS MS örnek verilebilir (Alp Ertürk, Uzaktan Algılama Teknolojileri Notları).

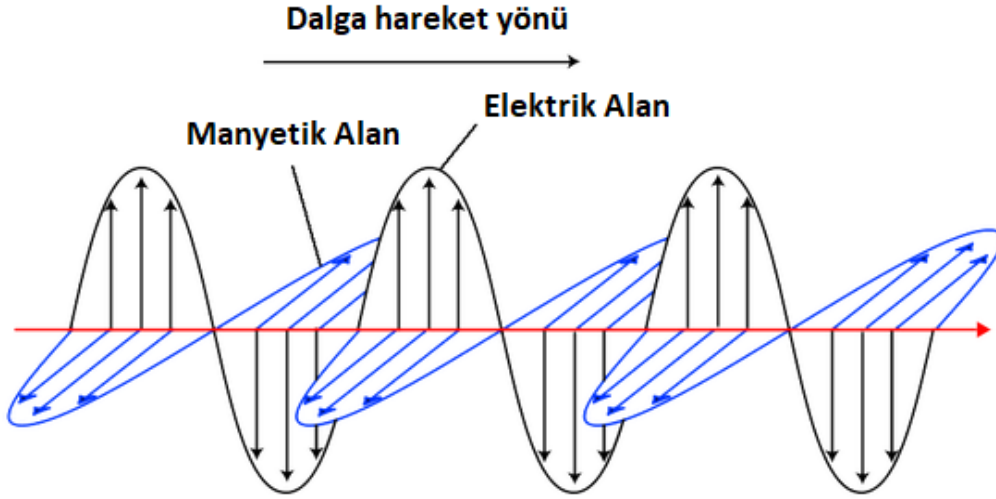
### **1.3.3 Hiper bantlı veri**

Hiper bantlı (hiperspektral) veriler, dar bant aralıklarıyla çok fazla sayıda (50 ve üzeri) banttan oluşan verilerdir. AVIRIS ve Hyperion EO1 uydu platformundaki hiperspektral görüntüleme sensörü örnekleridir. Ayrıca uçuş platformları için üretilmiş olan çok sayıda hiperspektral kamera mevcuttur.

## **1.4 Elektromanyetik Radyasyon**

Radyasyon (ışınım) genel anlamda enerjinin uzayda dalgalar ya da tanecikler (fotonlar) halinde yayılmasıdır. Isı, ışık ve radyo dalgaları günlük yaşamdan bildiğimiz ışınım yoluyla yayılma örnekleridir. Tüm nesnelere belli oranda enerji yayarlar ve başka

nesnelere gelen enerjileri yansıtırlar. Uzaktan algılamanın temeli nesnelere soğurduğu ve yansıttığı bu enerjilerin ölçümüne dayanmaktadır. Elektromanyetik enerji elektrik ve manyetik dalgalar halinde yayılmaktadır. Elektrik ve manyetik dalgalar birbirine dik konumda ve aynı yöne doğru hareket etmektedirler. Bir elektromanyetik dalga örneği şekil 1.7’de gösterilmiştir.




Şekil 1.7 Elektromanyetik dalga

şekil 1.8’de elektromanyetik dalgaların temel özellikleri olan hız, dalga boyu, genlik ve frekans kavramları gösterilmiştir. Dalganın ardışık iki tepe veya iki çukur noktası arasında kalan zaman dilimi dalganın periyodunu ( $T$ ) gösterir. Bu aynı zamanda dalganın kaç saniyede bir kendini tekrar ettiğini belirtir. Dalganın birim zamanda yaptığı tekrar sayısı dalganın frekansıdır ( $f$ ). Her elektromanyetik dalga ışık hızıyla hareket ederken, bir periyot boyunca aldığı mesafe dalganın dalga boyunu ( $\lambda$ ) vermektedir. Bu tanımlarla birlikte dalganın temel özellikleri arasındaki bağıntılar eşitlik 1.1 ve eşitlik 1.2’de verilmiştir.


$$T = 1/f \quad (1.1)$$

$$\lambda = c/f \quad (1.2)$$



Şekil 1.8 Dalga ve özellikleri

Elektromanyetik spektrum radyo dalga frekanslarından gama ray frekanslarına kadar çok geniş bir alanı kapsamaktadır. Aralarında ters orantılı bir ilişki bulunduğu için, frekansı yüksek olan dalganın, dalga boyu düşüktür. Elektromanyetik spektrum şekil 1.9'da verilmiştir.




Şekil 1.9 Elektromanyetik spektrum

Her maddenin kendine özgü enerjiyi yansıtma, iletme ve soğurma karakteristiği bulunmaktadır. Uzaktan algılama ile cisimlerin niteliklerinin tespit edilmesi ve cisimlerin birbirlerinden ayırt edilmesi amacıyla, elektromanyetik spektrumdaki soğurma, iletim ve yansıma ölçümleri kullanılmaktadır.


### **1.5 Hiperspektral Görüntüleme ve Özellikleri**

Hiperspektral görüntüleme, elektromanyetik spektrumda mor berisi ile uzak kızıl berisi aralığındaki farklı dalga boylarında elde edilen yüzlerce dar ve bitişik bant içeren yeni nesil uzaktan algılama teknolojisidir. Klasik görüntüleme aygıtları genellikle görünür dalga boylarındaki ışığı algılayabilirler. Bu aygıtlardan elde edilen görüntüler ise tek bantlı veya birkaç bantlı olabilmektedir. Her bir bandın kapsadığı dalga boyu aralığı genel anlamda çok geniş olmaktadır. Bu da görüntü verisinde spektral detay bilgisinin düşük olmasına neden olmaktadır. Hiperspektral görüntüleme ise çok daha geniş dalga boyu aralığında, birbirine çok yakın ve dar bant aralıklarıyla görüntü alınabilmektedir. Bu durum nesnelerin elektromanyetik dalgayı yansıtma özelliklerini çok daha detaylı bir şekilde inceleyebilmeye olanak sağlamaktadır. Böylece insan gözüyle görülemeyen birçok ayrıntı elde edilmiş olur. Hiperspektral görüntülerde kapsanan dalga boyu aralığı ve dalga boyu aralığındaki bant sayısı, kullanılan sensörün özelliği ve kabiliyeti ile ilgilidir. Hiperspektral görüntü elde edilmesinde en çok kullanılan tarayıcılardan birisi doğrusal dizili (pushbroom) tarayıcılardır. Şekil 1.10'da bir doğrusal dizili tarama sistemi gösterilmektedir. Görüntüleme aygıtının ve üzerine takılı olan lensin özelliğine göre bir BA (Bakış alanı) açısı oluşmaktadır. Görüntüleme optiğindeki doğrusal dizindeki algılayıcı (dedektör) sayısına göre sistemin ABA (Anlık bakış alanı) açısı oluşmaktadır. Bu bakış açısının görüntülenen yüzeyde karşılık gelen dörtgen alan yer pikselini oluşturur. Bu pikselin yeryüzünde kapsadığı alan, görüntüleme aygıtının yersel çözünürlük değerini oluşturmaktadır. Yersel çözünürlük, aynı kavram olmasa bile çoğunlukla uzamsal çözünürlük olarak ele alınmaktadır.



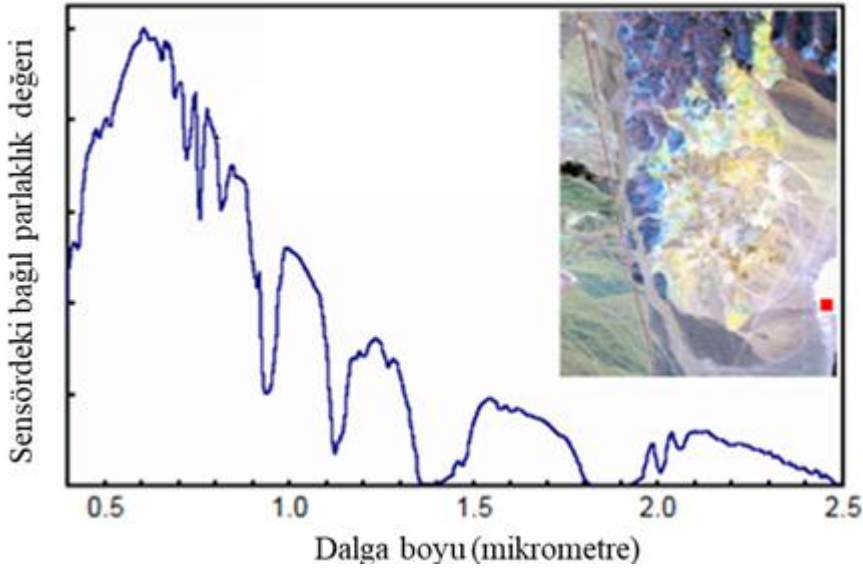
Şekil 1.10 Doğrusal dizin görüntüleme sistemi

Görüntünün her satırı, sistemin odak düzlemine yerleştirilmiş CCD (Charge coupled device) dedektörlerinin tek sıralı doğrusal dizisi üzerine doğrudan düşen ışınım ölçülerek elde edilir. Hiperspektral görüntüleme aygıtı içerisindeki optiksel yapı şekil 1.11’de gösterilmiştir. Bir pikselden yansıyan ışık, görüntüleme aygıtı içerisindeki tarama aynası vasıtasıyla prizmaya yönlendirilmektedir. Prizma ışığı renklerine (dalga boyu) göre kırarak, görüntüleme optiği üzerinden dedektörler üzerine düşürmektedir. Böylece pikselden yansıyan ışık, görüntüleme aygıtının çalıştığı dalga boyu aralığına göre tüm renk bileşenlerine (dalga boylarına) ayrılmış olmaktadır.



Şekil 1.11 Görüntüleme sistemi içyapısı

Dedektör dizisi üzerindeki her bir dedektör belirli dalga boyu arasındaki ışığı yakalayabilen özelleşmiş sensörlere sahiptir. Her bir sensörde ölçülen ışımaya değeri, ilgili pikselin dalga boyu bağımlı ışımaya spektrumunu göstermektedir. Örnek bir ışımaya spektrumu şekil 1.12’de gösterilmiştir.



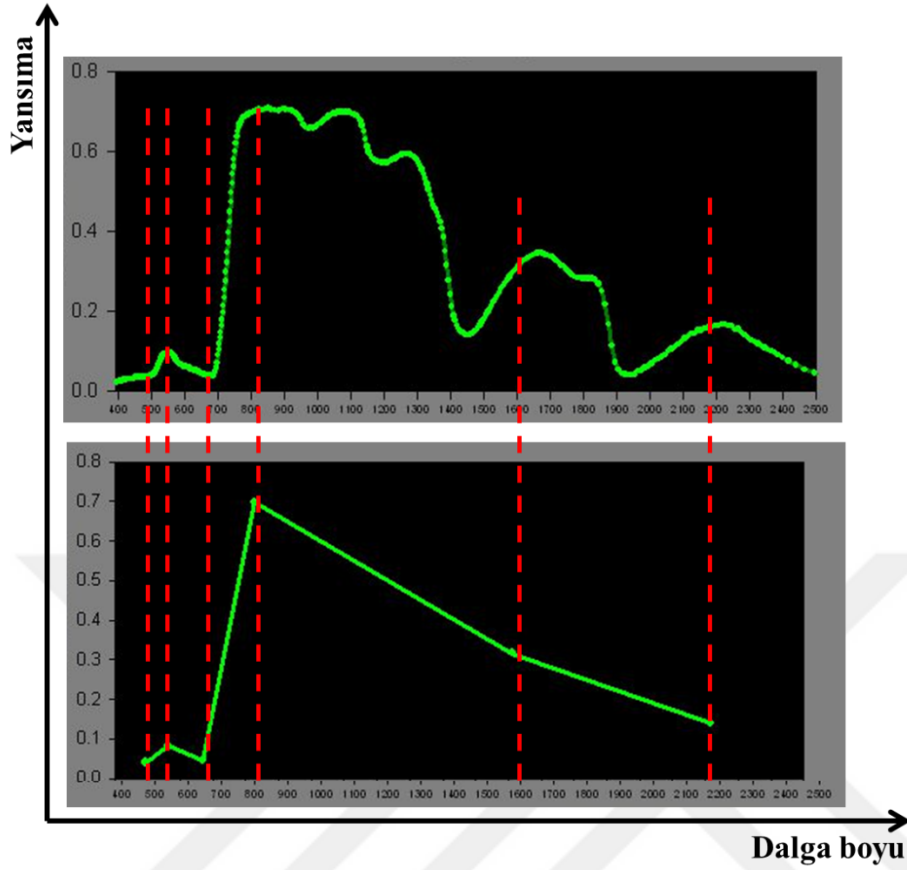
Şekil 1.12 Piksel ışımaya spektrumu (<https://belspo.be> 2010)

## 1.6 Uzaktan Algılamada Çözünürlük Kavramı

Uzaktan algılamada 4 çeşit çözünürlük kavramı bulunmaktadır. Bunlar; spektral, radyometrik, zamansal ve uzamsal çözünürlüktür.

### 1.6.1 Spektral çözünürlük

Spektral çözünürlük, görüntüleme aygıtındaki sensörün elektromanyetik spektrumunda dalga boyu bazında görüntü alabilme hassasiyet ve yeteneğinin bir ölçüsüdür. Belirli bir dalga boyu aralığı düşünüldüğünde, bu dalga boyu aralığında ne kadar dar aralıklarla bilgi alınabiliyorsa, sensörün spektral çözünürlüğü o kadar fazladır denilebilir. Uzaktan algılamada pankromatik (tek bantlı) görüntülerden, kırmızı-yeşil-mavi üç bantlı görüntülere, çok bantlı (multispektral) sensörlerden, hiper bantlı sensörlere kadar çok sayıda ve farklı spektral çözünürlüklerde görüntü ve sensörler kullanılmaktadır. Spektral çözünürlük arttıkça görüntüdeki spektral bilgi detayı da artmaktadır. Buna karşılık veri boyutu arttığı için görüntü işlem süresi de uzamaktadır. Hiperspektral görüntüleri diğer görüntü türlerinden ayıran en önemli nokta, hem fazla banda sahip olmaları hem de bantlar arasındaki dalga boyu aralığının dar olmasıdır. Bu durum spektral ayrıştırmada oldukça işe yaramaktadır. Birbirinden spektral imza olarak ayrılması zor olan birçok materyal, hiperspektral verideki en anlamlı bantların seçilmesi ve işlenmesiyle ayırt edilebilmektedir. Düşük ve yüksek spektral çözünürlükte veriler şekil 1.13'te gösterilmiştir. Görüleceği üzere, düşük spektral çözünürlükte spektral örnekleme aralığı çok yüksek ve veri detayı düşüktür. Buna karşılık, yüksek spektral çözünürlükte, örnekleme aralığı çok dar ve veri detayı yüksektir.



Şekil 1.13 Düşük (altta) ve yüksek (üstte) spektral çözünürlük

### 1.6.2 Radyometrik çözünürlük

Radyometrik çözünürlük, görüntüdeki her bir pikselin kaç bit ile ifade edildiğinin ölçüsüdür.  $b$  bit sayısını göstermek üzere,  $b$  bit ile ifade edilen bir görüntü için dinamik renk genişliği  $[0, 2^b - 1]$  aralığı olmaktadır. Örneğin tek bit ile ifade edilen (0 veya 1) bir görüntü siyah ve beyaz piksellerden oluşacaktır. Yine 8 bit ile ifade edilen bir görüntüdeki her bir piksel parlaklığı  $[0-255]$  aralığında ifade edilebilir. Dolayısıyla renk spektrumu birbirine yakın olan nesnelere, düşük radyometrik çözünürlükte aynı renkle ifade edilirken, yüksek radyometrik çözünürlükte birbirinden ayırt edilebilir duruma gelebilmektedir. Farklı radyometrik çözünürlükte olan görüntüler Şekil 1.14'te gösterilmiştir. Görüleceği üzere radyometrik çözünürlük arttıkça piksellerin birbirinden ayırımı net bir şekilde artmaktadır. Birbirine parlaklık olarak yakın olan piksellerin ayırımı düşük çözünürlüğe doğru gidildikçe azalmaktadır.



8 bit

4 bit

2 bit

1 bit

Şekil 1.14 Aynı sahnenin farklı radyometrik çözünürlüklü görüntüleri

### 1.6.3 Zamansal çözünürlük

Bir görüntüleme aygıtının bir bölgeyi çektiği ardışık iki zaman anı arasındaki zamansal mesafedir. Farklı sensörlerin farklı zamansal çözünürlükleri bulunmaktadır. Örneğin LANDSAT için zamansal çözünürlük, 16 ve 18 gün iken, MODIS için bu değer 2 gündür. Özellikle detaylı analiz çalışmalarında, sensörün zamansal çözünürlüğü, aynı bölgenin dar zaman aralıklarındaki görüntülerinin elde edilmesi amacıyla oldukça faydalı olabilmektedir.

### 1.6.4 Uzamsal çözünürlük


Uzamsal çözünürlük, sensörde oluşan görüntüde ayırt edilebilecek en küçük nesnenin alanı olarak ifade edilebilir. Aynı zamanda uzamsal çözünürlük değeri, görüntüleme yapan sensörün bulunduğu yükseklik ile ilişkili olmak üzere, sensörün ABA açısı değerinin yeryüzünde karşılık geldiği alanın ölçüsüdür. Aynı bölgenin farklı uzamsal çözünürlük değerlerinde alınmış görüntüleri şekil 1.15'te gösterilmiştir. Uzamsal çözünürlük arttıkça, görülebilen ayrıntı artmaktadır. Örneğin 10 m değerindeki çözünürlüğün anlamı, görüntüde 1 pikselin 100 m<sup>2</sup> lik bir alanı kapsadığı, diğer bir deyişle 100 m<sup>2</sup> lik alanın 1 pikselle ifade edilmesidir.



Şekil 1.15 Aynı sahnenin farklı uzamsal çözünürlükleri (<https://hvkk.tsk.tr> 2012)

## 1.7 Spektral Karışma

Uzaktan algılamada performans, hız ve donanım gereksinimlerinden dolayı kullanılan sensörlerin uzamsal çözünürlükleri genellikle düşük kalmaktadır. Bu durum, uzamsal çözünürlüğün yeryüzünde kapsadığı alan içerisine birçok farklı materyal girebilmesine neden olmaktadır. Görüntüleme aygıtından elde edilen görüntünün her bir pikselinde aslında, o pikselde fiziksel olarak bulunan materyallerin spektrumunun karışımı (ağırlıklı toplamı) gözlenmektedir. Spektral karışımındaki maddelerin tespit edilmesi, hangi maddeden hangi oranda karışımında bulunduğu belirlenmesi, literatürde sıklıkla yer almış ve günümüzde de önemini koruyan bir problemdir. Özellikle hedef tespiti gibi uygulamalarda, düşük uzamsal çözünürlüklü görüntüde alt piksele düşen hedeflerin bulunabilmesi için spektral karışım pikselinde, spektral ayrıştırma yapılması gerekmektedir. Spektral karışma yalnızca materyallerin yansıtma özelliğiyle ilgili değildir. Aynı zamanda, maddelerin soğurma ve iletim karakteristiklerinin de bir sonucudur. Şekil 1.16'da spektral karışımın fiziksel oluşumu basit bir yapıyla gösterilmiştir. Bir piksel içerisinde hem bitki hem de toprak bulunduğundan bu piksele denk gelen sensör ölçüm değeri bitki ve toprak yansıma spektrumunun ağırlıklı toplamı olacaktır.



Şekil 1.16 Spektral karışımın oluşumu (<https://www.slideshare.net/> 2017)

### 1.8 Tezin Amacı ve Özgünlüğü

Tezin amacı, temel olarak uzamsal çözünürlüğün düşüklüğü nedeniyle spektral karışım durumunda olan pikselde, spektral ayrıştırma yaparak, fiziksel temellere uygun biçimde, piksel içerisinde bulunan materyaller (son öğeler) için karışım içindeki oranlarını (bolluk değerleri) tespit etmektir. Bolluk değer üretiminde literatürde yer alan mevcut yöntemlere kestirim hatası ve doğru sınıflandırma açısından üstünlük sağlayan algoritmalar geliştirmektir.

Tezde, spektral karışım modellerinden bilineer karışım modeli temel alınmıştır. Literatürde bilineer model ile yapılan birçok spektral ayrıştırma çalışması bulunmakla birlikte, tezde, literatürde yer almayan veya eksik bırakılan durumlar dikkate alınmış ve modelleme buna göre yapılmıştır. Tezin özgün yönleri şu şekilde sıralanabilir:

1. Görüntü pikselinin doğal bir spektral karışım olduğunun vurgulanması ve doğru bir spektral ayrıştırma için yerden spektrometre ile alınan spektral imzalardan oluşan spektral kütüphanenin kullanılması gerektiğinin savunulması.

2. Görüntü pikselinde belirli bir materyalin yoğunluğunun çok yüksek olmasının pikselin saf piksele yaklaştığı anlamına gelmediğinin gösterilmesi.
3. Yansıma spektrumunun kullanılmasının yanı sıra, iletim ve soğurma spektrumlarının, siyah arka plan ve beyaz arka plan üzerinde ölçülen yansıma spektrumlarından hesaplanarak kullanılması.
4. Spektral karışımın oluşumu düşünülürken, yansıma-yansıma, iletim-yansıma gibi tüm bilinear etkileşim durumlarının ele alınması
5. Bilinear modeldeki bilinear etkileşim terimlerinin bolluk değerlerini de doğrusal terimlerin bolluk değerleriyle birlikte, bolluk değerlerin toplamı 1 olacak şekilde, hesaplanması.
6. Spektral karışımında, bir son ögenin fiziksel varlığı oranında karışıma katkı sağladığı yaklaşımının eksik bir yaklaşım olduğunun gösterilmesi.
7. Bitki ekim bölgeleri gibi sahnelerde, bitki gelişimiyle birlikte yansıma ve iletim etkileşim spektrumlarının bolluk değerlerinin de değiştiği, bu durumun bitkiye göre bir karakteristik içerdiği ve spektral ayrıştırma ile sınıflandırmada bu özelliğin kullanılabileceğinin gösterilmesi.


## 2. KAYNAK ÖZETLERİ

### 2.1 Spektral Ayrıştırma

Piksel içerisinde spektral karışım halinde olması muhtemel olan maddelerin bilindiği veya kestirilebildiği durumda, spektral ayrıştırma yaparak bolluk haritasının bulunması işlemi literatürde doğrusal ve doğrusal olmayan yaklaşımlarla gerçekleştirilmiştir.

#### 2.1.1 Doğrusal yaklaşım

Doğrusal yaklaşımda ilgili pikselde spektral yansıma olarak karışım halinde olan maddelerden sensöre gelen ışığın başka bir maddeye çarpmadan o maddeden doğrudan geldiği (tek yansıma) varsayılır. Doğrusal karışım modeli şekil 2.1’de gösterilmiştir. Şekilde iki son öge içeren bir pikselde doğrusal karışım modelinin yansıma şekli verilmiştir. Son öğelerden tek yansıma yapan güneş ışığı sensörde birleşmektedir. İki den fazla son öge bulunması durumunda yine ışığın her bir son öğeden tek yansıma yaparak sensöre ulaştığı kabul edilmektedir.



Şekil 2.1 Doğrusal karışım modeli (Dobigeon vd. 2013)

Doğrusal modellemenin matematiksel ifadesi eşitlik 2.1’de verilmiştir. Eşitlikte  $a_m$  ,  $m$ ’nci son öge bolluk değerini,  $S_m$ ,  $m$ ’nci son ögenin dalga boyu bağımlı spektrumunu,  $K$  karışım spektrumunu,  $M$  ise son öge sayısını göstermektedir. Karışım spektrası, son öge spektrumlarının ağırlıklı toplamı ile ifade edilmektedir ve eşitlik 2.2’de verilen şartlar geçerlidir.

$$K = \sum_{m=1}^M a_m S_m \quad (2.1)$$

$$\begin{aligned} \sum_{m=1}^M a_m &= 1 \\ a_m &\geq 0, \forall m \end{aligned} \quad (2.2)$$


Doğrusal modelleme ancak gerçekteki durumun, varsayılan duruma çok yakın olduğu zamanlarda başarılı sonuçlar üretebilmektedir. Fakat gerçek dünyada büyük olasılıkla bir maddeden yansıyan ışık başka maddelerden de yansyarak (çoklu yansıma) sensöre ulaşmaktadır. Yani sensörde bir pikselde karışım halinde olan spektral imzaların her biri, yine başka maddelerin yansıtma karakteristiğinden etkilenerek sensöre ulaşmış durumdadır. Bu durum doğrusal olmayan karışma durumunu meydana getirmektedir. Böyle bir durumda spektral karışım probleminin doğrusal modelleme ile çözülmeye çalışılması, eksik ve hatalı kestirim sonuçları üretmektedir. Doğru sonuçlara erişebilmek için doğrusal olmayan modeller kullanılması daha anlamlıdır. Doğrusal olmayan karışım modelleri genel anlamda iki kategoride düşünülmüştür. Bunlar bilineer karışım ve homojen karışım (intimate) modelleridir (Heylen vd. 2014).

### 2.1.2 Doğrusal olmayan yaklaşım

Doğrusal olmayan yaklaşımda, spektral karışım halindeki piksel içerisinde yer alan son öğelerin birbirleriyle iki ve daha fazla sayıda yansıma olacak şekilde spektral etkileşim terimleri oluşturdukları düşünülür. Bu nedenle, karışım problemi doğrusal olmayan yaklaşımlarla çözümlür.

### 2.1.2.1 Homojen karışım modeli

Homojen karışım modelinde, pikselin, birkaç bileşenin mikroskobik karışımından oluştuğu kabul edilir. Bu modelde karışım halinde olan bileşenlerin birbirine olan uzamsal ölçekteki mesafeleri, yansıyan fotonların sensöre kadar izlediği mesafeden çok daha kısadır. Homojen karışım modeli şekil 2.2’de gösterilmiştir. Bu modelde ışığın birçok yansıma sonucunda sensöre ulaştığı düşünülmektedir.



Şekil 2.2 Homojen karışım modeli (Dobigeon vd. 2013)

Homojen karışım modelinde bolluk haritasının çıkarılması için yapılan çalışmaların birçoğu Hapke modeli (Hapke 1993) temelinde geliştirilmiştir. Hapke modelinde, izotropik çoklu saçılma yaklaşımı kullanılarak homojen karışımın dağınık yansıtma modeli türetilmiştir. Bu yaklaşımda, bileşenlerdeki tekil yansıtmanın spektral katkısı net bir şekilde verilir ve çoklu yansıtma uğramış ışık, izotropik şekilde yansıyan partiküller için ışıma transfer denkleminde bulunan yaklaşık bir çözüm ile ifade edilir. Bu çözümde karışım halinde olan yüzey için ve son öğelerin farklı yansıtma koşullarında, dalga boyu bağımlı yansıtma değeri ( $s(\lambda)_m$ ) ve dalga boyu bağımlı tek yansıtma beyazlık (albedo) ( $\alpha(\lambda)_m$ ) değeri arasında eşitlik 2.3’teki gibi bir bağlantı verilmektedir (Heylen vd. 2014).

$$\sqrt{1 - \alpha(\lambda)_m} = \frac{[(\mu + \mu_0)^2 s(\lambda)_m^2 + (1 + 4\mu\mu_0 s(\lambda)_m)(1 - s(\lambda)_m)]^{\frac{1}{2}} - (\mu + \mu_0) s(\lambda)_m}{1 + 4\mu\mu_0 s(\lambda)_m} \quad (2.3)$$

Yansıma düzleminde, gelen ışık ve yansıyan ışığın yüzey normaliyle yaptıkları açılar sırasıyla  $\theta_i$  ve  $\theta_e$  olmak üzere  $\mu_0 = \cos(\theta_i)$ ,  $\mu = \cos(\theta_e)$ , olarak verilmektedir. Eşitlik 2.3 kullanılarak son öğelerin ve homojen karışım halinde olan yüzeyin, albedo değerleri hesaplanabilir. Belirtilen yüzeyde farklı bileşenler yansıtma olarak doğrusal karışmıyor olmasına rağmen, tek yansıtma albedo değerleri doğrusal olarak karışmaktadır (Hapke 1981, Hapke 1993). Bu doğrusal karışım, eşitlik 2.4'teki gibi ifade edilebilir. Burada  $a_m$  karışım halindeki bileşenlerin bolluk değerlerini,  $\alpha(\lambda)_{mix}$  albedo karışımını ifade etmektedir. Albedo için bu doğrusal davranışın fiziksel nedeni, tek yansıtma albedo değerinin, yalnızca gelen ışığın ilk kez çarparak yansıdığı bileşene bağlı olmasıdır (Heylen vd. 2014). Bolluk değeri bileşenin karışım içerisindeki kesit alanıyla orantılı durumdadır.

$$\alpha(\lambda)_{mix} = \sum_{m=1}^M a_m \alpha(\lambda)_m \quad (2.4)$$

Eşitlik 2.4 ile ifade edilen doğrusal karışım modeli çözülerek, homojen karışım modelinde olduğu düşünülen tüm bileşenler için bolluk haritası kestirimi yapılabilir.

### 2.1.2.2 Bilineer model


Bilineer modelde, homojen modeldeki çoklu yansıma durumu en çok 2 yansıma sayısına indirilmektedir. Bu modelde iki durum söz konusudur. Birincisi doğrusal modelleme kısmı, diğeri ise bilineer etkileşimlerin ifade edildiği kısımdır. Bilineer modelde, son öğelerin doğrusal karışımı modeline, iki kez yansıma etkileşimi de eklenmektedir. Bilineer modelin matematiksel ifadesi eşitlik 2.5'te verildiği gibidir.

$$K = \sum_{m=1}^M a_m s_m + \sum_{m=1}^M \sum_{k=1}^M b_{mk} s_m \odot s_k \quad (2.5)$$

$K$ , spektral karışım yansıtma spektrumunu;  $a$ , bileşen bolluk değerini;  $s$ , son öğelerin dalga boyu bağımlı spektrumlarını;  $b_{mk}$  etkileşim terimlerinin bolluk değerini;  $\odot$  ise Hadamard çarpımını göstermektedir. Bilineer modelde eşitlik 2.6'da verilen şartlar geçerlidir.

$$a_m \geq 0, b_{mk} \geq 0, m \geq k \quad (2.6)$$

Bilineer modelde iki veya daha fazla sayıda son öğe bulunabilir fakat makroskobik boyutta en fazla iki yansıtma olduğu kabul edilir. Bilineer modelleme iki son öğeli durum için şekil 2.3'te gösterilmiştir.



Şekil 2.3 Bilineer karışım modeli (Dobigeon vd. 2013)

Bilineer modelde iki son öğe olduğu bir durumda, yansıtma değeri dalga boyu bağımlı şekilde eşitlik 2.7'de gösterildiği gibi hesaplanacaktır.

$$K = a_1s_1 + a_2s_2 + b_{11}s_1 \odot s_1 + b_{21}s_2 \odot s_1 + b_{22}s_2 \odot s_2 \quad (2.7)$$

Eşitlik 2.5'te ifade edilen bilineer karışım problemi çözülerek doğrusal modellemeye göre daha doğru bolluk haritalarına ulaşılmıştır. Eşitlik 2.5'te ifade edilen bilineer karışım denklemi, bilineer etkileşim terimi üçüncü bir son öge olarak düşünülerek, EKKH (En küçük kare hata) yöntemi gibi doğrusal sistem çözümleriyle çözülebilir. Bilineer karışım modelinde etkileşim sayısının en çok ikiye indirgenmesi temelde önemli ve çoğu durumda doğru sayılabilecek bir yaklaşımdır. Çünkü dalga boyuna bağımlı biçimde 0 ile 1 arasında değişen yansıma spektrumunun ikiden fazla çarpılması sonucu 0'a yakınsatmaktadır. Elde edilecek olan küçük değerlerin bazı özel durumlar dışında karışım spektrumunu çok fazla etkilemeyeceği düşünülebilir (Heylen vd. 2014)

Literatürde son yıllarda yapılmış bilineer modelleme çalışmaları incelendiğinde Fan (Fan vd. 2009), Nascimento (Nascimento ve Bioucas-dias 2009), GBM (Generalized bilinear model) (Halimi vd. 2011) ve PPNM (Polynomial post-nonlinear model) (Altmann 2012) en önemli ve popüler bilineer modellerdir.

Fan (Fan vd. 2009) yönteminde eşitlik 2.5 çözülürken eşitlik 2.8 ve eşitlik 2.9'daki kabul geçerli kılınmıştır. Fan (Fan vd. 2009) modelinde, bilineer modelin doğrusal kısmındaki bolluk değerlerinin toplamı 1 olarak alınmıştır. Karışım pikseli içerisindeki her materyalin fiziksel varlığı oranında karışıma katkı yaptığı kabul edilmektedir. Bu nedenle bilineer etkileşim terimlerinin her biri için bolluk değeri, etkileşimi oluşturan her son ögenin doğrusal kısımda kestirilmiş bolluk değerlerinin çarpımı olarak kabul edilmiştir. Bununla birlikte son ögelerin öz etkileşim durumu ihmal edilmiştir. Yani herhangi bir son ögenin sadece kendisinden iki kez yansıma durumu dikkate alınmamıştır.

$$\sum_{m=1}^M a_m = 1 \quad (2.8)$$

$$b_{mk} = a_m a_k, \forall m < k ; \text{değilse } 0 \quad (2.9)$$

Nascimento (Nascimento ve Bioucas-dias 2009) modelinde, Fan (Fan vd. 2009) modelinden farklı olarak tüm doğrusal ve etkileşim terimlerinin bolluk değerleri toplamı 1 olarak alınmıştır. Bu modelde eşitlik 2.10 geçerli olmaktadır. Fan (Fan vd. 2009) modelindeki gibi bu modelde de öz etkileşim terimleri ihmal edilmektedir.

$$\sum_{m=1}^M a_m + \sum_{m=1}^{M-1} \sum_{k=m+1}^M b_{mk} = 1 \quad (2.10)$$

PPNM (Altmann 2012) modelinde, Fan (Fan vd. 2009) modelinde olduğu gibi eşitlik 2.8 geçerlidir. \* çarpma işlemini temsil etmek üzere, eşitlik 2.11’de gösterildiği gibi tüm etkileşim terimleri aynı değerde bir ağırlık katsayısı ile çarpılmaktadır. Bu modelde öz etkileşim terimleri de içerilmektedir.

$$b_{mk} = c * a_m a_k \quad (2.11)$$

GBM modelinde, PPNM (Altmann 2012) modelindeki ağırlık katsayısı her bir etkileşim terimi için istatistiksel olarak modellenmektedir.

(Huete vd. 1985) ve (Ray vd. 1996)’da yapılan çalışmalarda, toprak ve bitkiden oluşan bir karışımda, karışımın yansıtma değerinin son öge spektrumlarıyla doğrusal bir ilişkiden uzak olduğu gösterilmiştir. Karışım yansıtma değerinin toprak çeşidi değişimine bağlı olarak doğrusal olmayan bir şekilde değiştiği tespit edilmiştir. %100’e yakın bir değerde bitki içeren bir durumda bile, toprak çeşidinin değişmesinin gözlenen spektrumu değiştirdiği görülmüştür. Bu nedenle, spektral ayrıştırmada toprak ve bitki arasındaki etkileşimin de hesaba katılması sonucuna ulaşılmış ve çözüme yönelik olarak bilineer karışım modeli uygulanarak daha doğru bolluk haritaları elde edilebilmiştir.

(Nascimento ve Bioucas-dias 2009)'daki çalışmada bilineer model, ağaç ve çayır içeren bir sahnede uygulanmış, EKKH yöntemiyle bolluk haritası elde edilmiş, bolluk haritası hatası ve yeniden oluşturma hatası doğrusal karışım modeline göre daha düşük olarak elde edilmiştir. Bilineer model ikiden fazla son öge için de geçerlidir. Çoklu son öge durumunda, yansıtma değeri hesabı eşitlik 2.5'e göre modellenenir.

Literatürde spektral karışımı bilineer olarak modelleme çalışmaları, genel anlamda yansıma bileşeni üzerinde yoğunlaşmış durumdadır. Karışım halindeki maddeler ne olursa olsun, bu maddeler arasındaki etkileşimin yalnızca yansıma durumuna bağlı olduğu varsayılmış ve bilineer modelde sadece yansıma terimleri yer almıştır (Nascimento ve Bioucas-dias 2009, Fan vd. 2009, Halimi vd. 2011, Altmann vd. 2012, Meganem vd. 2014). Hâlbuki herhangi maddenin ışıkla etkileşiminde üç temel durum söz konusudur. Bunlar; yansıma, soğurma ve iletimdir. Bu özellikler her madde özelinde dalga boyuna bağımlı şekilde değişiklik göstermektedir. Bir maddeden geçen ışık diğer maddeden yansiyarak sensöre ulaşabilir. Dolayısıyla bilineer modellemede, sadece yansıma durumunun düşünülmesinin, bolluk haritalarının doğru kestirimi konusunda eksik kalacağı değerlendirilmektedir. Özellikle tarım noktasında değerlendirilecek olursa, bitki yapraklarından geçen ışığın toprağa çarparak sensöre ulaşabilir olma ihtimali de doğru bir bilineer modelleme için değerlendirmeye alınmalıdır. İletim durumunun ele alındığı çalışmalardan birisi (Zhang vd. 1998)'de yapılan çalışmadır. Bu çalışmadaki eksiklik ise yansıma-yansıma veya iletim-yansıma etkileşim terimlerinin bolluk değerlerinin eşit olarak düşünülmesidir. Ancak, bitki yaşam döngüsünde, bitki gelişimi arttıkça; yansıma, yansıma-yansıma, iletim-yansıma durumlarının ve karışımdaki oranlarının değişiklik göstereceği değerlendirilmektedir. Bu durum her bitki çeşidinde farklılık gösterecektir. Çünkü her bitki yaprak ve gelişim yapısında diğer bir bitkiye göre farklılıklar göstermektedir. Bitki büyüdükçe, bitki yapraklarının birbiri içerisine yaptığı fiziksel girişim farklılığı, bilineer modeldeki yansıma, yansıma-yansıma ve iletim-yansıma etkileşim terimlerinin ağırlığını değiştirecektir. Yani bolluk değerleri sabit değil, bitkinin olgunluk düzeyiyle ilişkili bir şekilde değişecektir. (Zhang vd. 1998) dışında yaprak iletim durumunun ele alındığı (Borel ve Gerst, 1994) çalışmasında doğrusal olmayan karışımın hem yansıma hem de iletim kaynaklı olduğu vurgulanmıştır. Spektral karışım modellenirken yaprak ve arka

plan (toprak ve gölge) çoklu yansıma ve iletim durumları göz önüne alınmıştır. (Roberts vd. 1993)'teki çalışmada ise görüntülerde spektral ayrıştırma için doğrusal modelleme uygulanmış, doğrusal modelde kalan hata miktarı analiz edilerek farklı bitki tipleri ayırt edilmiştir. İletim durumunun kestirim hatasını etkilediğinin değerlendirildiği bu çalışmalardaki eksiklik ise iletim spektrumunun ölçülmemesi veya hesaplanmamasıdır. İletim spektrumunun spektral ayrıştırma modelinde kullanılmasından ziyade, iletim durumunun piksel kestirim hatasını değiştirdiği gösterilmiştir. Piksel kestirim hatası, pikselde bulunan materyallerin bolluk değerleri kestirildikten sonra, bulunan bolluk değerleri ile pikselin yeniden oluşturulması sonucunda elde edilen piksel spektrumu ile orijinal piksel spektrumunun birbirinden farkının alınması sonucu elde edilen hata değeridir.

Doğrusal olmayan karışma durumunda spektral ayrıştırma için kullanılan bilineer modelleme yöntemi, fiziksel olarak açık bir şekilde yorumlanabilmesine karşın, bazı dezavantajları da beraberinde getirmektedir. Bunlardan birincisi, bilineer yöntemde son öge yansıma spektra değerleri çarpılırken, çarpım değeri gittikçe küçülmektedir ve son ögelerin yansıma değerinden daha düşük değerlere ulaşmaktadır. Bu değer bazı çalışmalarda küçük katsayılarla çarpıldığından, daha da küçülerek, idealde sıfır değerinde son öge olarak bulunması gereken gölgeli bölgelerin spektral katkısıyla karışmaktadır (Heylen vd. 2014). Bu durum başarıyı olumsuz yönde etkilemektedir. Bir başka problem, birçok bilineer modelde, bileşenlerin öz etkileşimlerinin hesaba katılmamasıdır. Fakat bazı çalışmalarda, öz etkileşimlerin karışım spektrasına önemli miktarda etki ettiği belirtilmiştir (Altmann vd. 2012). Bununla birlikte Nascimento (Nascimento ve Bioucas-dias 2009) modeli gibi bazı bilineer modellerde, son öge spektraları oldukça fazla sayıda serbest katsayıyla, (örneğin  $M$  tane son öge için,  $M^2$  tane) çarpılmaktadır. Bu durum sistemi aşırı uyuma (overfitting) götürebilmektedir. (Chen vd. 2010, Chen vd. 2011)'de yapılan çalışmalarda bilineer etkileşim teriminin büyük derecelerde korelasyon ifade ettiği ve bu durumun ayrıştırma prosedürünü, gürültüye karşı daha duyarlı hale getirdiği belirtilmiştir.

### 2.1.2.3 Diğer yöntemler

Doğrusal olmayan karışım durumunda, bolluk haritasının elde edilmesine yönelik, başka yöntemler de geliştirilmiş ve uygulanmıştır. Bunlar, yapay sinir ağları, çekirdek yöntemleri (kernel trik, destek vektör makineleri), parçalı doğrusal ayrıştırma, veri tabanı yaklaşımı, karışım ayırma analizi şeklinde sıralanabilir (Heylen vd. 2014). Doğrusal olarak modellenemeyen ve gürültü içeren sistemlerin çözümünde başarılı bir yöntem olarak uygulanan ÇKP (Çok katmanlı perseptron) modeli, bolluk haritası tespitinde de sıklıkla kullanılmıştır (Foody 1996, Atkinson vd. 1997, Plaza vd. 2008, Licciardi ve Frate 2010, Licciardi ve Frate 2011) ve hâlihazırda güncel kullanımını korumaktadır (Mitraka ve Frate 2015, Li vd. 2016, Mitraka vd. 2016). (Foody 1996)'da yapılan çalışmada girdi olarak yansıma imzası verilmiş, çıkışta ise üç sınıfa göre bolluk değerleri üretilmiştir. (Licciardi ve Frate 2010)'da ÇKP kullanılarak hiperspektral veri üzerinde piksel tabanlı spektral ayrıştırma yapılmıştır. Sekiz son öge içeren bir sahnede ÇKP ve EKKH sonuçları karşılaştırılmıştır. Yer doğruluk verisindeki son öge bolluk değerleri ÇKP kullanıldığında EKKH'a göre çok daha az bir hata ile elde edilebilmiştir. (Licciardi ve Frate 2011)'de ise ÇKP modeli iki aşamalı bir şekilde uygulanmıştır. İlk aşamada, ÇKP ile hiperspektral veride boyut indirgemesi yapılırken, ikinci aşamada ise birinci aşamada elde edilen veriler ile ÇKP ağı eğitilerek, oniki son öge bulunan bir test verisinde bolluk haritası hesaplaması yapılmıştır. Elde edilen sonuçlar EKKH sonucu ile karşılaştırılmıştır. Yer doğruluk verisine göre, ÇKP kullanılarak elde edilen sonuçlar EKKH sonuçlarına çok ciddi bir üstünlük sağlamıştır. (Licciardi ve Frate 2010) ve (Licciardi ve Frate 2011)'de elde edilen sonuçlar, kullanılan hiperspektral veride doğrusal olmayan karışım durumunun olduğunu, bu durumda doğrusal yöntemin yeterince başarılı bir sonuç üretmediğini ve ÇKP'nin doğrusal olmayan karışım problemini, doğrusal yöntemle göre çok daha başarılı bir şekilde çözdüğünü açık bir şekilde ortaya koymaktadır. (Atkinson vd. 1997)'deki çalışmada sinir ağı modeli, doğrusal karışım modeli ve fuzzy c-means yöntemi sonuçları karşılaştırılmıştır. Bu karşılaştırmaya göre, ÇKP'nin diğer iki yöntemle üstünlük sağladığı görülmüştür. (Plaza vd. 2008)'de yapılan çalışma ise ÇKP ve doğrusal ayrıştırma birlikte kullanılmıştır. Öncelikle doğrusal ayrıştırma yapılmış ve sonrasında ÇKP ile doğrusal olmayan ayrıştırma yapılarak daha başarılı sonuçlara ulaşılmıştır.

Literatürde doğrusal ve doğrusal olmayan spektral ayrıştırma işlemlerinde yansıma katsayılarının doğrudan kullanılması ve/veya doğrusal ayrıştırma işlemi yansıma spektrasının KKD (Kesikli kosinüs dönüşümü) ve dalgacık dönüşümü katsayılarının kullanıldığı görülmektedir. Bolluk haritasının kestirimi ve piksel temelli sınıflandırmada, yansıma sinyalinin dönüşüm katsayılarından öznitelik çıkarılarak bu özniteliklerin kullanılmasının, sinyal yansıtma değerlerinin doğrudan kullanılmasından daha başarılı sonuçlar üretebileceği belirtilmiştir (Li 2002, Li 2004, Almog vd. 2007). Bu durumun nedeni olarak, Li (2002)'deki çalışmada, bolluk haritası kestirim hatasının son öge ayrıştırılabilirliği ile ters orantılı olduğu, bir sinyal dönüşüm biçimi olan dalgacık dönüşümü katsayılarından çıkarılan anlamlı özniteliklerin bu ayrıştırılabilirliği artırabildiği ve dolayısıyla bolluk haritası kestirim hatasını azalttığı belirtilmiştir. (Li 2004)'te yapılan çalışmada, son öge bolluk değerlerinin EKKH yöntemiyle hesaplanışında, teorik ve deneysel olarak dalgacık dönüşümü ve geleneksel olmayan KKD bağımlı özniteliklerin kullanılmasının kestirim hatasını % 30-50 oranında azalttığı gösterilmiştir. Aynı zamanda, değişik oranlarda gürültü ve/veya saf olmayan son öge spektrası içeren karışım pikselinde, dalgacık dönüşümü bağımlı özniteliklerin kullanılmasının, spektrum analiz işlemindeki gürbüzlüğü sayısal olarak ispatlanmıştır. Bu durumun nedeni olarak, kullanılan dönüşüm özniteliklerinin son öge ayrıştırılabilirliğini artırması durumu gösterilmiştir. Almog, (2007)'deki çalışmada ise, sinyal yansıtma değerlerinin dalgacık dönüşüm katsayılarıyla birlikte kullanılarak, sınıflandırma başarısının artırılabilirliği belirtilmiştir. Benzetim verisi üzerinde, yalnızca yansıtma değerleriyle yapılan sınıflandırmada ortalama doğruluk %75-76 değerlerindeyken, yansıtma katsayısı ve dalgacık dönüşüm katsayılarının birlikte kullanılmasıyla % 100'e yaklaştığı söylenmiştir. (Cimtay ve İlk 2017) çalışmasında, görüntü ve spektral imzaların birinci dereceden türev katsayıları üretilmiş, üretilen katsayıların büyüklüklerine göre sıralanışında, mısır, pamuk ve buğday için farklı karakteristikler olduğu görülmüştür. Başka materyallerde de bu durumun ayırt edici bir özellik olduğu düşünülmüştür. Gerçekleştirilen çalışmada elde edilen sınıflama sonucu, MF (Matched Filter), SAM (Spectral Angle Mapper), CEM (Constrained Energy Minimization) gibi yöntemlerle karşılaştırılmıştır. Hem kesinlik hem de geri getirme skorlarında önerilen yöntemin çok daha iyi sonuçlar ürettiği görülmüştür. Bu çalışmada türev katsayılarının, yansıma katsayılarına göre sinyalin ayırt edici özelliklerini daha iyi

tuttuğu vurgulanmış, aynı zamanda türev katsayılarının doğrudan kullanılmasından daha çok, türev katsayılarının belirli bantlar için büyüklük sıralamasına bakılmıştır. Yapılan çalışma aynı zamanda doğrudan türev katsayılarını kullanan çalışmalarla karşılaştırılmış ve bu çalışmalardan sınıflama sonucu olarak daha iyi değerler ürettiği gösterilmiştir.

Hiperspektral karışma ve karışımın çözülmesi konusunda incelenen çalışmalara dayanılarak, salt sinyalin yansıma katsayılarının kullanılmasından ziyade, sinyal dönüşüm katsayılarından öz nitelikler çıkararak bu öz niteliklerin belirli kurallarla kullanılması, spektral ayrıştırma problemi çözümünde başarıyı artırıcı bir etken olarak karşımıza çıkmaktadır. Bu önemli başarıya rağmen, bu çalışmalarda temelde doğrusal yöntem çözümleri kullanılmıştır. Fakat pikselde doğrusal olmayan karışım durumu oluşturabilecek bir sahnede ve çekim koşullarında, doğrusal yöntem çözümü kullanmak yine başarıyı kısıtlayıcı bir neden olarak karşımıza çıkacaktır ve istenilen başarı düzeyine ulaşmak mümkün olmayacaktır.

Bolluk haritasının en az hatayla elde edilebilmesi ve daha doğru sınıflandırma için, son öge ayrıştırılabilirliğini artıran öz niteliklerin çıkarılması ve kullanılması tek başına yeterli değildir. Bu öz niteliklerin doğru yöntemlerle kullanılması da oldukça önemlidir. Özellikle pikselde doğrusal olmayan karışım durumu meydana getirecek olan bir sahne yapısı ve çekim koşulları söz konusu olduğunda, başarılı bir sonuç elde edebilmek için doğrusal olmayan yöntemlerin kullanılması gerekmektedir. Doğrusal olmayan çözüm yöntemlerinden birisi olan yapay sinir ağını kullanarak öğrenme tabanlı yapılan spektral ayrıştırma çalışmaları, gerek gürültüye az hassas oluşları ve diğer modellerde hesaba katılan birçok parametrenin hesaplanma zorunluluğu olmaması nedeniyle daha tercih edilebilir gibi gözükmektedir. Fakat tüm modellerde olduğu gibi, sinir ağının eğitimi aşamasında da ağın doğru ve ayrıştırılabilirliği artırıcı öz nitelikler ile eğitilmesi çok önemlidir. Literatür incelendiğinde, yapay sinir ağının eğitilmesinde çoğu çalışmada sinyal yansıma katsayılarının doğrudan kullanıldığı görülmektedir. Bu durum daha başarılı olabilecek bir yöntemin (ÇKP) istenilen seviyede başarıyı sağlayamamasına neden olabilmektedir. ÇKP'nin sinyal dönüşüm katsayılarından elde edilen öz nitelikler ile eğitilmesi fikri (Hsu ve Yang 2007)'de yapılan çalışmada kullanılmıştır ve sinir ağının önüne, dalgacık düğümlerinden oluşan bir dalgacık ağı

eklenmiştir. Hiperspektral sinyalden yapılan örneklemelemlerin dalgacık düğümlerinde dalgacık ayrıştırması yapıldıktan sonra elde edilen sonuç ile yapay sinir ağı beslenmektedir. Dolayısıyla geri yayılım hata değerine göre yalnızca sinir ağındaki ağırlıklar değil, aynı zamanda dalgacık düğümlerindeki ağırlıklar da güncellenmektedir. Böylece hata miktarı azaltılmaktadır. Ayrıca aynı çalışmada, dalgacık ağı çözümü, “dalgacık katsayılarından doğrusal olarak çıkarılan özniteliklerle sinir ağının eğitilmesi”, “dalgacık katsayılarından doğrusal olmayan yolla elde edilen özniteliklerle sinir ağının eğitilmesi” ve “TBA (Temel bileşen analizi) katsayılarıyla sinir ağının eğitilmesi” sonuçlarıyla karşılaştırılmıştır. Elde edilen sonuçlara göre, dalgacık ağının sinir ağı ile birlikte kullanımının sonucunun diğer yöntemlere göre sınıflandırma doğruluğu sonuçlarını %30-40 değerlerinden %70-80 değerlerine kadar çıkardığı görülmüştür. Bu çalışma, dalgacık ağının (ve dolayısıyla dalgacık dönüşüm katsayılarından elde edilen özniteliklerin) ÇKP'ye girdi olarak kullanılmasının sınıflandırma sonuçlarının iyileşmesine yaptığı katkıyı gösterme açısından çok önemlidir. Ancak, uzamsal çözünürlüğün genellikle düşük kaldığı ve spektral ayrıştırmaya ihtiyaç duyulan hiperspektral veride, bir spektral ayrıştırma yapmadığı için, daha doğru sınıflandırma sonuçları elde etme noktasında eksik kaldığı söylenebilir.

Doğrusal ve doğrusal olmayan spektral ayrıştırma konusunda yapılan çalışmalar ışığında, doğrusal olmayan karışım durumunda, bolluk haritası üretimi ve sınıflandırma başarısını artırabilmek için yeni bir bakış açısının gerekliliği ortaya çıkmaktadır. Bu kapsamda önerilen tezin amacı, bilineer modellemede iletim ve soğurma durumunun da göz önüne alınarak, bolluk değer kestirimi başarısını artırarak ayrıştırma doğruluğu yüksek ve sınıflandırmada geleneksel yöntemlere üstünlük kurabilecek algoritmalar geliştirmektir.

## **2.2 Sınıflandırma**

Güvenlik, narkotik ve tarım gibi birçok önemli alanda, arazi kullanımının belirlenmesi oldukça önemli bir konudur (Homer vd. 2007, Lu ve Weng 2007, Jensen 2009). Bu amaca yönelik olarak 1980'li yıllardan beridir uzaktan algılama görüntüleri üzerinde

sınıflama çalışmaları yapılmaktadır. Böylece görüntüleme yapılan alandaki türler belirlenebilmekte ve bu türlerin yeryüzünde kapsadığı alanlar ölçülebilmektedir.

### **2.2.1 Piksel tabanlı sınıflandırma**

Klasik uzaktan algılama görüntü sınıflandırması olarak, piksel temelli sınıflandırma teknikleri, her bir pikselin saf piksel olduğunu ve tek bir tür olarak etiketlendiğini kabul etmektedir (Fisher 1997, Xu vd. 2005). Bu durumda uzaktan algılama görüntüleri uzamsal ve spektral bilgi içeren piksel toplulukları olarak düşünülmektedir. Bu nedenle spektral değişkenler ve bunların dönüşümleri (örneğin ana bileşenler, bitki örtüsü endeksleri) piksel temelli sınıflandırıcılara girdi olarak verilirler. Genel olarak piksel tabanlı sınıflandırma algoritmalarının iki gruba ayrılmaktadır: denetimsiz sınıflandırma ve denetimli sınıflandırma.

Denetimsiz sınıflandırmada, uzaktan algılama görüntüsü, eğitim verileri ve çalışma alanı ile ilgili önceden bir bilgi olmadan görüntü değerlerinin doğal gruplamasına dayanan bir dizi sınıfa bölünmektedir (Lillesand vd. 2004, Puletti vd. 2014). Denetimsiz iki sınıflama algoritması, k-means (Rollet vd. 1998, Blanzieri ve Melgani 2008) ve onun varyantı olan ISODATA (Iterative Self-Organization Data Analysis) tekniği, en yaygın kullanılan sınıflandırıcılardır (Dhodhi vd. 1999). Son zamanlarda SOM (Self Organizing Maps) ve hiyerarşik kümeleme yöntemleri de geliştirilmiştir (Gonçalvez vd. 2008).

Denetimli sınıflandırmada, bir görüntü analisti bilinen sınıf türlerine (eğitim örnekleri) sahip temsili örnek sahalarını seçer ve görüntüdeki her bir pikselin spektral özelliklerini eğitim numuneleriyle karşılaştırır. Daha sonra da görüntü piksellerini, belirli karar kurallarına göre sınıf tipine etiketler (Lillesand vd. 2004). Literatürde çok sayıda denetimli sınıflandırma algoritması geliştirilmiştir. Bunlardan en önemlileri, SAM (Spectral Angle Mapper), MF (Matched Filter), MLC (Maximum Likelihood Classifier) (Settle ve Briggs 1987, Shalaby ve Tateishi 2007), MDMC (Minimum Distance-to-Means Classifier) (Atkinson ve Lewis 2000, Dwivedi vd. 2004), MDC (Mahalanobis

Distance Classifier) (Deer ve Eklund 2003, Dwivedi vd. 2004), Parallelepiped (Perakis vd. 2000) ve KNN (K-Nearest Neighbors) (Zhu ve Basir 2005, Zhang vd. 2008) algoritmalarıdır. Son zamanlarda bilgi öğrenme sürecini iyileştirmek ve sınıflandırma performansını artırmak amacıyla makine öğrenmesi teknikleri uygulanmıştır. Bu yöntemler, yapay sinir ağı (Kavzoğlu ve Mather 2003), sınıflandırma ağacı (Friedl ve Brodley 1997, McIver ve Freidl 2002, Jiang vd. 2012), rastgele ormanlar (Gislason vd. 2006), destek vektör makineleri (Gualtieri ve Crompt 1999, Huang vd. 2002, Pal ve Mather 2005, Marconcini 2009) ve genetik algoritmalar (Ishibuchi vd. 1994, Tseng vd. 2008) ile örneklenebilir.

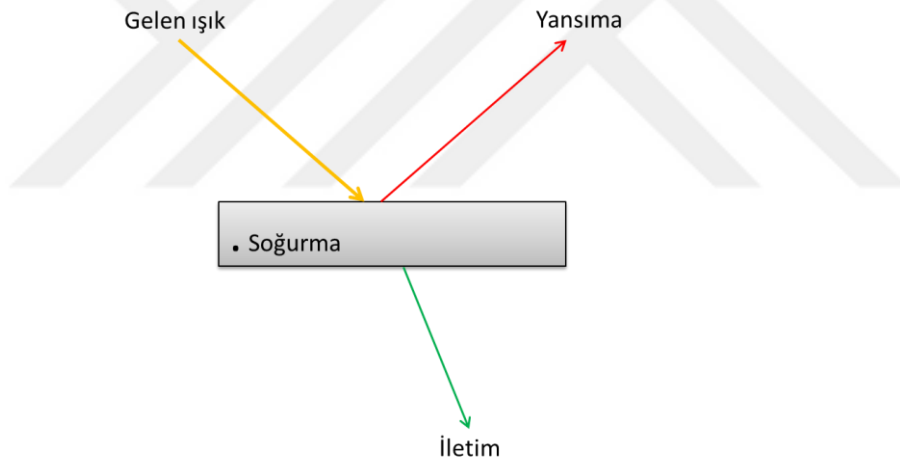
### **2.2.2 Alt piksel tabanlı sınıflandırma**

Piksel tabanlı sınıflandırma yöntemleri her bir görüntü pikselinde yalnızca bir tip materyal olduğunu kabul etmektedir. Bununla birlikte bu tür bir varsayım, büyük ölçüde uzaktan algılama imgesinin uzamsal çözünürlüğü ile karşılaştırıldığında, sahnedeki heterojenlikten dolayı düşük ve orta çözünürlükteki görüntüler için geçersiz olmaktadır. Bu nedenle bu tip görüntülerde piksel tabanlı sınıflandırma yöntemlerinin kullanılması sınıflama doğruluğunu düşürmektedir (Zhang ve Foody 1998, Shanmugam vd. 2006). Daha iyi bir alternatif olarak alt piksel sınıflandırma teknikleri kullanılarak sınıflandırma başarısı artırılmaktadır (Foody ve Cox 1994, Zhang ve Foody 1998, Woodcock ve Gopal 2000). Spektral karışma problemini adresleyerek alt piksel yaklaşımıyla sınıflandırma yapan birçok yöntem geliştirilmiştir. Bulanık sınıflama, sinir ağları (Foody 1999, Kulkarni ve Kamlesh 1999, Mannan ve Ray 2003), regresyon modelleme (Yang ve Liu 2005, Yuan vd. 2005), regresyon ağacı analizi (Xian ve Crane 2005) ve spektral karışım analizi (Adams vd. 1995, Roberts vd. 1998, Wu ve Murray 2003, Wu 2004) bunlardan en önemlileridir. Spektral analiz yapılarak pikselde olması muhtemele tüm maddelerin karışımdaki oranları (bolluk değeri) tespit edilerek sınıflama yapılır. Hiperspektral görüntülerde spektral analiz ile gerçekleştirilen çalışmalar bölüm 2.1’de detaylı olarak anlatılmıştır.

## 2.3 Eleřtiri ve Teori

Tez alıřmasında, literatürde genel anlamda oka yer almıř bazı kabuller ve yaklařımlar deęerlendirilmekte ve eleřtirel yaklařılmaktadır.

- Kaynak özetleri bölümünde anlatılan birok spektral ayrıřtırma yöntemi kullandıkları test verileri ve test senaryolarına göre iyi sonuçlar üretmektedirler. Bilineer modelleme, dięer modelleme yöntemlerine göre daha sadedir ve başarısından dolayı tercih edilmektedir. Fakat bilinear modellerin büyük bir oęunluęunda, sadece yansıma etkileřimi ele alınmıřtır. Fakat fiziksel olarak ispatlanmıřtır ki ıřığın madde ile olan etkileřiminde yalnızca yansıma deęil, iletim ve soęurma etkileřimleri de bulunmaktadır (řekil 2.4).



řekil 2.4 Iřık-Madde etkileřimi

- Yansıma, iletim ve soęurma etkileřimleri her madde özelinde farklılıklar gösterir. Spektral karıřım durumunda, yansıma etkileřimiyle birlikte ıřığın bir maddeden geip dięer maddeden yansıyarak sensöre ulařabilme durumu da oldukça olasıdır. Bu nedenle spektral ayrıřtırmada iletim spektrumunu hesaba katmayan bilinear modellerin eksik olduęu deęerlendirilmektedir.
- Literatürde (Zhang vd. 1998) gibi ok nadir alıřmalar iletim spektrumunu da hesaba katmaktadır. Fakat Zhang (Zhang vd. 1998), iletim spektrumunu

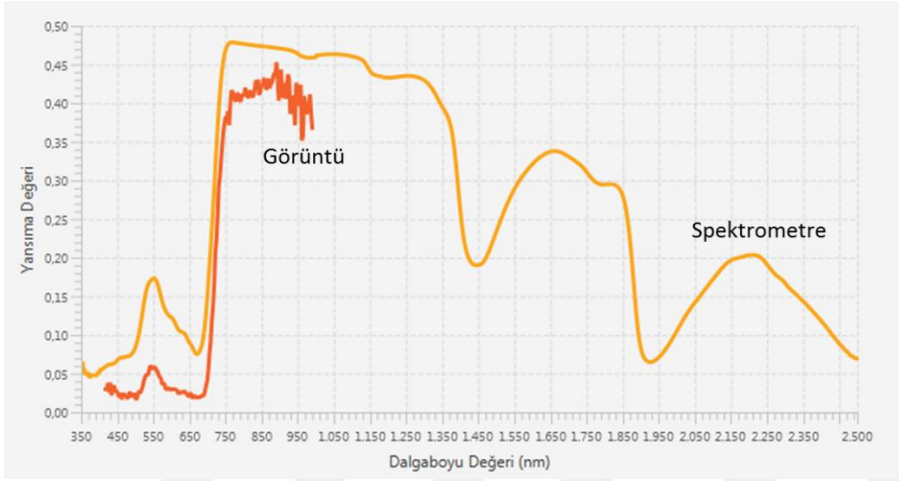
ölçmemiş veya hesaplamamıştır. İletim spektrumunu yansıma spektrumu ile eşit kabul etmiştir. Ayrıca bilinear modeldeki doğrusal olmayan etkileşim terimlerinin bolluk değerlerini eşit kabul etmiştir. Tezde bu kabullerin eksik ve başarıyı sınırlandırıcı oldukları gösterilmiştir.

✚ Bir diğer ortak yaklaşım ise her bir materyalin pikseldeki fiziksel varlığı oranında karışıma katkı yaptığı kabulüdür. Bu kabul eksiktir, çünkü her şeyden önce karışım işlemi doğrusal bir işlem değildir. Materyallerin fiziksel yapısı ve pikseldeki yerleşimi karışımı doğrusal olmayan bir biçimde etkileyebilmektedir. Bir son öge fiziksel anlamda pikselin çoğunluğunu oluşturmuyor olsa bile, çoğunluğu oluşturan materyal kadar karışıma etki ediyor olabilir. Örneğin, üzeri tamamen yaprakla örtülü bir toprak bölgesinde, toprağın sensörde ölçülen karışım değerine katkı vermediği garanti edilemez. Çok basitçe, yapraktan geçen ışık topraktan yansır ve yapraktan tekrar geçerek sensöre ulaşır. Bu ihtimal dahilindedir ve mümkün olduğunca spektral ayrıştırma işleminde ihmal edilmemelidir.

✚ Multispektral ve hiperspektral analizde, sıkça görüntüdeki piksellerin son öge olarak tespit edildiği ve kullanıldığı görülmektedir. Bu son öge spektrumlarının ayrıca bir materyali temsilen saf spektrum olduğu düşünülür. Son ögelerin bilinmediği bir durumda görüntüden son öge çıkarımı ve kullanılması kaçınılmaz olabilir. Fakat saf piksel yaklaşımı doğru bir yaklaşım değildir. Nedenleri şunlardır:

- Spektral karışım yalnızca “alt piksel” durumlarına özel değildir. Aynı zamanda “saf piksel” olarak kabul edilen pikseller de bir spektral karışımın sonuçlarıdır. Hiçbir madde yoksa dahi en azından öz etkileşim durumu bir pikseli rahatlıkla saf pikselden uzaklaştırabilmektedir. Bu durum ve bu olasılık göz ardı edilmemelidir.
- Spektral ayrıştırmada doğru bir modelleme için mutlak surette spektrometre ile hassas alınmış madde spektral imzaları kullanılmalıdır. Şekil 2.5 belirli bir koordinattan spektrometre ile alınmış bitki spektral imzası ile aynı koordinatın radyometrik düzeltilmesi yapılmış görüntüden alınan spektral

imzalarını göstermektedir. Görüntüden elde edilen piksel spektrasi, piksel içinde fiziksel olarak bulunan materyallerin spektral karışımıdır. Yer spektrasi'nin görüntü spektrasi'nden ne kadar farklı olduđu gözükmemektedir. Dolayısıyla karışım probleminin çözümünde görüntü piksellerinden elde edilen spektral imzaların son öge spektrasi olarak kullanılması doğru bir yaklaşım ifade etmemektedir.



Şekil 2.5 Spektrometre ve görüntü piksel imzası

- Genellikle alt piksel durumları için spektral ayrıştırma yapılır. Çünkü herhangi bir piksel saf pikselden uzaklaştıkça geleneksel yöntemler yanlış alarmlar üretmeye başlarlar. Spektral ayrıştırma bu tarz problemlerin çözümünde etkili bir yöntem olarak karşımıza çıkar. Bu nedenle görüntüdeki pikseli saf spektrum olarak ele alıp kullanan yöntemler aslında, saf spektrumu değil, bir spektral karışım spektrumu kullanmaktadırlar.

### 3. MATERYAL VE YÖNTEM

Tez çalışmasında belirlenen amaca uygun olarak, kullanılan materyaller şu şekildedir:

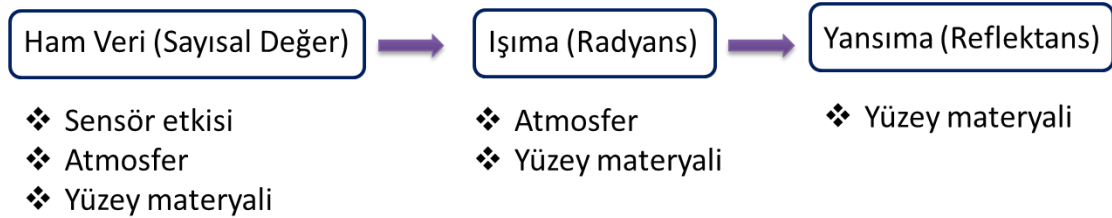
- ✚ Hiperspektral analiz, veri sınıflandırma ve spektral karışım probleminin çözülerek bolluk haritalarının elde edilmesi konusunda literatürde yayınlanmış kitap, bildiri ve yayınlar
- ✚ İşaret, görüntü işleme, lineer cebir konusunda yayınlanmış kitap ve diğer kaynaklar
- ✚ VNIR (Visible Near Infrared) (400-1000 nm) bant aralığında çalışan sensöre sahip hiperspektral kamera ile uçak platformundan çekilmiş olan hiperspektral görüntüler.
  - Hiperspektral görüntülerin elde edilmesinde kullanılan kamera, HySpex firması tarafından üretilen VNIR bant aralığında çalışan doğrusal dizili (pushbroom) kameradır. Çekimler 2016 yılının Haziran ve Ağustos aylarında *Şanlıurfa Harran* bölgesinde yapılmıştır. Kameranın monte edildiği uçak yere göre 3000 m yükseklikten uçurulmuştur. Bu yükseklik ve kamera açısına göre elde edilen verinin uzamsal çözünürlüğü (60x60) cm<sup>2</sup> olarak oluşmakta ve 3.2 nm spektral çözünürlükte 182 tane bant elde edilmektedir.
- ✚ Ham görüntülerin radyometrik düzeltmesinde sensör etkisinin giderilmesi için kamera firmasının sağlamış olduğu çalıştırılabilir program kullanılmıştır.
- ✚ Ham görüntülerin radyometrik düzeltmesinde atmosferik düzeltme için ENVI yazılım aracının “QUick Atmospheric Correction (QUAC)” fonksiyonu kullanılmıştır.
- ✚ Spektrometre ile mısır ve pamuk bitkilerinden alınmış spektral imzalar
- ✚ Algoritma geliştirme için MATLAB (R2014b) programı ve sinyal/görüntü işleme kütüphaneleri

Tez çalışmasında kullanılan yöntemler şu şekildedir:

- ✚ Mısır ve pamuk ekili alanların farklı zamanlarda görüntülenmesiyle elde edilen hiperspektral görüntülerde NDVI (Normalized difference vegetation index) hesaplaması
- ✚ Bitki alanlarında, bir pikselde yaprak ve toprak etkileşimi olduğu düşünülerek, spektral karışımın bilineer olarak iki son öge ile modellenmesi
- ✚ Bilineer modelin tek yansıma, ikili yansıma ve tek iletim-tek yansıma etkileşim terimleriyle oluşturulması.
- ✚ Hava aracıyla havadan görüntü çekimiyle eş zamanlı olarak, yerden spektrometre ile mısır, pamuk, toprak, siyah arka plan ve beyaz arka plan spektral imzalar toplanması.
- ✚ Toplanmış imzaların kullanılmasıyla, bitki yaprak ve toprak için (gerçek) yansıma ve iletim spektrumunun hesaplanması.
- ✚ Bulunan spektrumlar ile bilineer modeldeki tek ve etkileşim terimlerinin spektrumunun hesaplanması.
- ✚ Hiperspektral görüntünün her bir pikseli için elde edilen spektrum ile bilineer modeldeki terimlerin spektrumunun EKKH yöntemine sokularak, doğrusal etkileşim ve bilineer etkileşim terimlerin bolluk değerlerinin kestirilmesi.
- ✚ Kestirilen bolluk değerlerinin bilineer modelde kullanılarak, görüntü piksel spektrumlarının kestirilmesi.
- ✚ Spektral karışımda yalnızca yansıma etkileşimi olduğunu varsayan doğrusal model ve en önemli bilineer modellerin kodlanması ve görüntü piksel spektrumlarının bu yöntemlerle kestirilmesi.
- ✚ Önerilen yöntemin, yalnızca yansıma etkileşiminin varsayıldığı bilineer modeller ve doğrusal modelle kestirim hatası olarak karşılaştırılması.
- ✚ Önerilen yöntemin, bitki büyüklüğü ve olgunluğunun düşük olduğu zaman diliminde çekilmiş ve bitkinin alt piksele düştüğü hiperspektral görüntülerde, geleneksel sınıflandırma yöntemleriyle sınıflandırma sonuç doğruluk oranına göre karşılaştırılması

### 3.1 Hiperspektral Ham Verinin Anlamlandırılması

Hiperspektral görüntüleme sensörlerinde ölçülen ışık şiddeti, doğrudan olarak atmosfere girip yüzeyden yansıyan ışık şiddetini ifade etmemektedir. Esasen ölçülen ışık şiddeti, yüzeyin yansıtma özelliği ile birlikte, atmosferik etkilere ve sensör tabanlı etkilere maruz kalmış olan güneş enerjisini ifade eder. Spektrometre ile ölçülen spektrumda ise bu etkiler çok büyük oranda temizlenebilmekte ve cismin yansıtma spektrumu elde edilebilmektedir. Elde edilen yansıtma spektrumu ile karşılaştırma ve işlem yapabilmek için hiperspektral ham veriye de radyometrik ve atmosferik düzeltme adımları uygulanarak yansıtma görüntüleri elde edilmektedir. Sensör tarafından ölçülen ölçeklenmiş parlaklık (Sayısal değer), sensörün en uç noktasına ulaşan ışık şiddeti (radyans) ve yüzey yansıtma değeri (yansıtma) arasındaki ilişki ve her değer üzerindeki etkiler şekil 3.1’de verilmiştir. Sensörde ölçülen ham veri, öncelikle sensör etkisinin kaldırılmasıyla ışıtma değerine, daha sonra atmosfer etkisinin kaldırılmasıyla yansıtma değerine çevrilerek anlamlandırılmış olur. Dönüşümler sonunda yüzeyin yansıtma özelliği elde edilir.



Şekil 3.1 Sayısal değer-Işıma-Yansıtma dönüşümü


#### 3.1.1 Radyometrik düzeltme

Her sensörden elde edilen ışıtma değeri sensörün kazanç (gain) ve yanlılık (bias) değerinden etkilenmektedir. Cisimlerden spektrometre ile elde edilen yansıtma ölçümü ile spektral karşılaştırma ve analiz yapabilmek için görüntüleme sensöründe ölçülen ışık şiddeti (Sayısal değer)'nin öncelikle ışıtım (radyans) değerlerine çevrilmesi gerekmektedir. Sensör etkisinin giderilmesi anlamına gelen bu işleme radyometrik

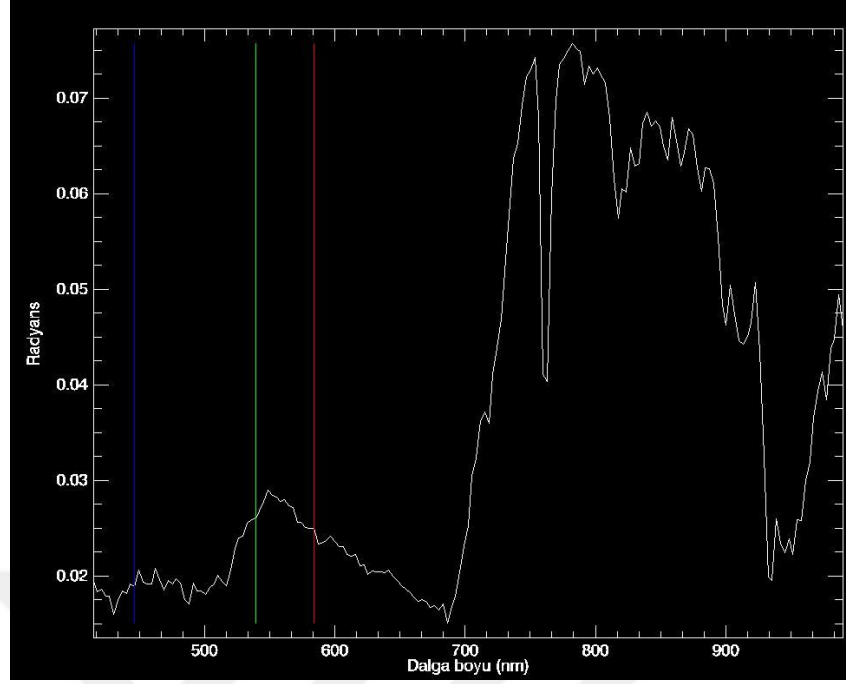
düzeltilme denilmektedir. Temel amaç yüzeyden sensörün başlangıç noktasına gelen ışımayı elde edebilmektir. Bu amaçla, sensör etkisiyle birlikte ölçülen dalga boyu bağımlı sayısal değer, sensörün kazanç ve yanlılık değerlerine göre yine dalga boyu bağımlı ışıma (radyans) değerine dönüştürülmektedir. Sayısal değer-radyans dönüşüm formülü eşitlik 3.1’de verilmiştir. Kazanç değeri sensör tipine göre değişmekle birlikte (0-1) aralığındadır.

$$Radyans_{\lambda} = Sayısal\ deęer_{\lambda} \times Kazanç + yanlılık \quad (3.1)$$

Şekil 3.2’de sayısal deęer spektrumu ve şekil 3.3’te bu spektrumdan sensör etkisinin kaldırılmasıyla elde edilen ışıma spektrumu gösterilmiştir.



Şekil 3.2 Örnek bir piksel için sayısal deęer spektrumu




Şekil 3.3 Örnek bir piksel için ışınım (radyans) spektrumu

Tez çalışmasında, VNIR (400-1000 *nm*) bant aralığında çalışan sensörlere sahip hiperspektral kamera ile yılın farklı zamanlarında uçak platformundan çekilmiş olan hiperspektral görüntülerin radyometrik düzeltilmesi için hiperspektral kamera firmasının sağlamış olduğu çalıştırılabilir program kullanılmıştır. Böylece ham görüntülerden, sensör etkisi giderilmiş ve ışınım (radyans) görüntüleri elde edilmiştir.

### 3.1.2 Atmosferik düzeltme

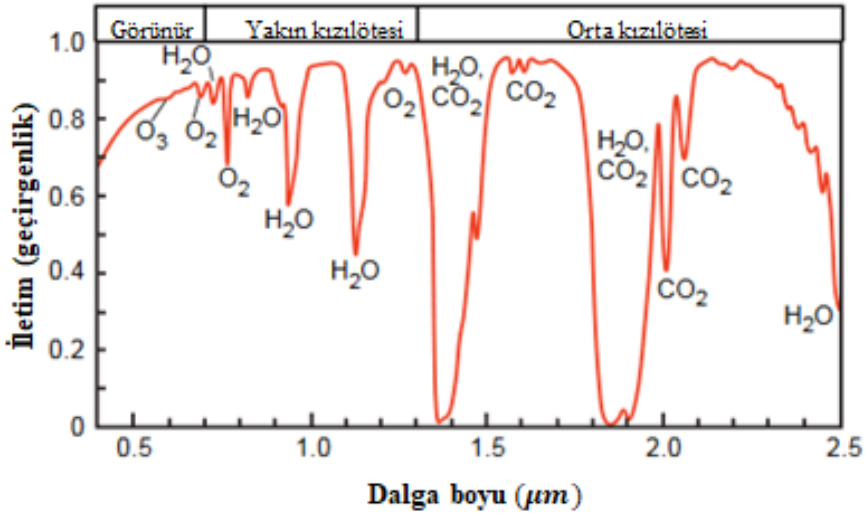
Güneşten yeryüzüne ulaşan elektromanyetik enerji atmosferde su buharı, karbondioksit ve oksijen nedeniyle saçılmaya ve soğurulmaya uğramaktadır. Havadaki su buharı, oksijen ve karbondioksit gazları belirli dalga boylarında güneş enerjisini soğurmaktadır ve saçılmaya uğratmaktadır. Ayrıca havadaki su buharından yansıyan enerji sensöre ulaşarak, cisimden gelen ışınım üzerine eklenmektedir. Sensörde gözlenen piksel değeri aslında sadece cisimden yansıyan enerjiyi ölçmemektedir. Cisimden gelen ışınım ile birlikte saçılmalar yoluyla gelen ışınımın toplamını ölçmektedir. Bu nedenle sensördeki

ışınım değeri, cismin yansıtma karakterini tam olarak ortaya koyamamaktadır. Atmosfere giren enerjinin dalga boyuna göre değişimi şekil 3.4’te gösterilmiştir.




Şekil 3.4 Atmosfere ulaşan enerji spektrumu

Atmosfer etkisi nedeniyle yeryüzüne ulaşan enerji değişmektedir. Atmosferin dalga boyuna bağımlı iletim spektrumu şekil 3.5’te gösterilmiştir.



Şekil 3.5 Atmosfer iletim spektrumu


Spektral karşılaştırma yapabilmek için ışımaya spektrumunun yansıtma (reflectance) spektrumuna dönüştürülmesi gerekmektedir. Bu, sensörde ölçülen ışımın değerinin atmosferik etkilerden kurtarılması anlamına gelmektedir. Bu etkilerin giderilmesinden sonra geriye cismin yansıtma karakteristiği (yansıtma imzası) çıkmaktadır. Atmosferik etkilerin kaldırılmasına ise atmosferik düzeltme denilmektedir. Güneşten yeryüzüne gelen ve yeryüzünden yansıyan enerji Şekil 3.6'da gösterilmiştir. Şekle göre sensörde ölçülen ışımın değeri ile yüzeyin yansıtma özelliği arasında eşitlik 3.2'de verilen ilişki bulunmaktadır. Eşitlikte  $\pi \cdot L_\lambda \cdot d^2$  yeryüzünden ayrılan ışımın enerjisini,  $E_{sun\lambda} \cdot \cos\theta_z$  ise yeryüzüne ulaşan güneş ışımın enerjisini göstermektedir.  $\rho_\lambda$  yüzeyin dalga boyu bağımlı yansıtma spektrumunu,  $d$  güneş ile dünya yüzeyi arasındaki uzaklığı,  $L_\lambda$  sensörün önüne ulaşan dalga boyu bağımlı ışımın enerjisini,  $E_{sun\lambda}$  güneşten gelen dalga boyu bağımlı atmosfer dışındaki enerjiyi,  $\theta_z$  ise güneş doruk açısını göstermektedir.



Şekil 3.6 Atmosferik düzeltme fiziksel ifadesi

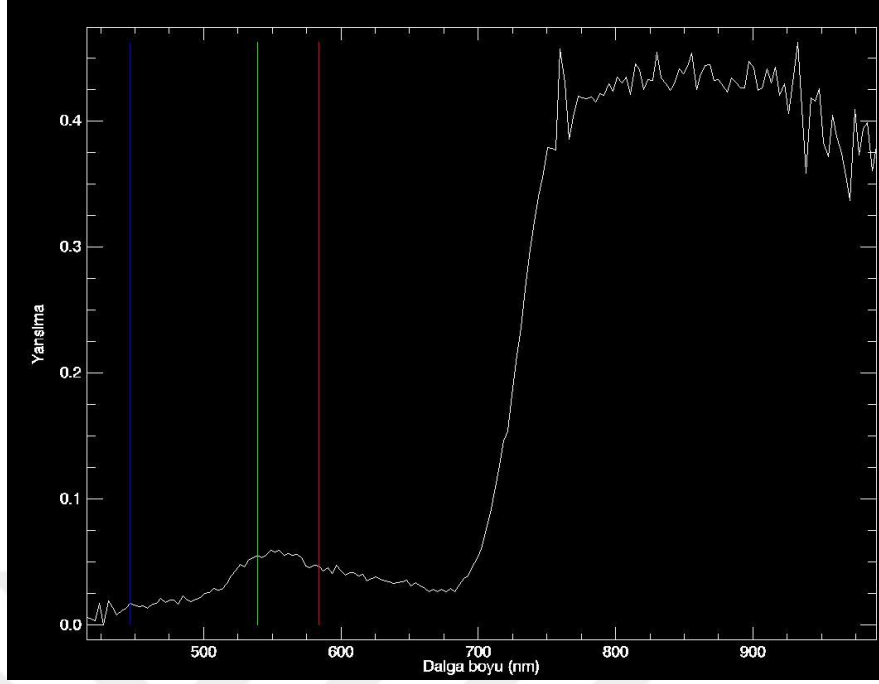
$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{E_{sun_{\lambda}} \cdot \cos \theta_s} \quad (3.2)$$

Tez çalışmasında atmosferik düzeltme için ENVI programı kullanılmıştır. Atmosferik düzeltme sonucunda, atmosferik etkinin kaldırılmış olduğu yansımaya (reflectance) görüntüleri elde edilmiştir. Elde edilen görüntüler üç boyutlu bir hiperspektral veri küpü oluşturmaktadırlar. İki boyut uzamsal boyut ve diğer boyut ise spektral boyuttur. Hiperspektral veri küpü ve boyutlar şekil 3.7’de gösterilmiştir. Şekilde, hiperspektral veri küpündeki bir piksel için dalga boyuna bağımlı spektrum da verilmiştir. Elde edilen spektrum, sürekli bir spektrumun, örnekleme dalga boyu değerine göre örneklenmiş halini ifade etmektedir.



Şekil 3.7 Hiperspektral veri küpü

Atmosferik düzeltme işleminden sonra elde edilen yansımaya spektrumu şekil 3.8’de gösterilmiştir.



Şekil 3.8 Örnek bir piksel için yansıtma (reflektans) spektrumu

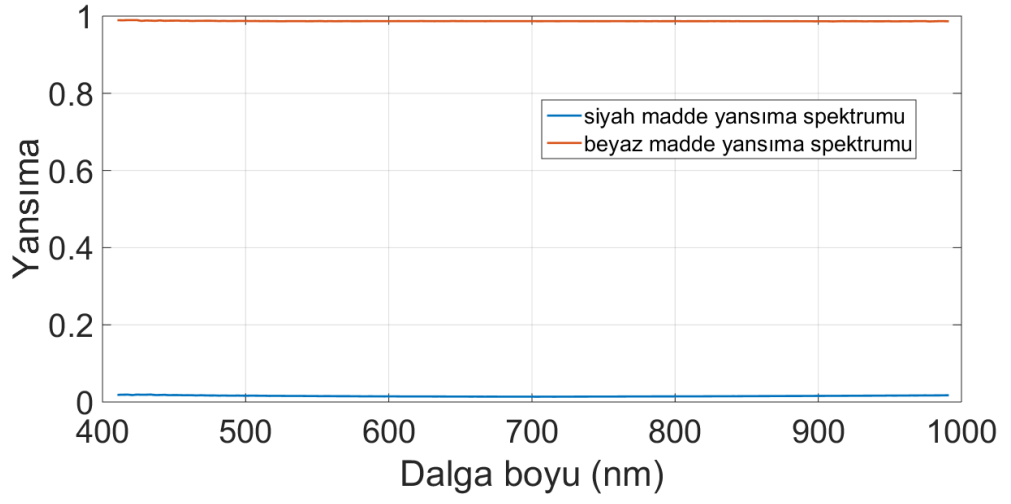
### 3.2 Spektral İmzalardan Gerçek Yansıtma ve İletim Spektrumunun Hesaplanması

Herhangi bir maddenin spektrometre ile yansıtma spektrumunun ölçümünde, bu maddenin altındaki veya üstündeki ortam yapılan ölçümü etkiler. Çünkü elde edilen spektrum yalnızca o maddenin öz spektrumunu temsil etmez. Etrafındaki ortamların yansıtma, soğurma ve iletim spektrumlarını da hesaba katmak gerekir. Bu nedenle tez çalışmasında, yaprakların spektral imzaları elde edilirken, yaprak altına beyaz arka plan ve yaprak altına siyah arka plan koyularak kontak prop tekniğiyle ölçümler alınmıştır. Ölçüm alma görüntüsü şekil 3.9’da gösterilmiştir. Spektrometrenin yaprak altında kalan kısmında siyah ve beyaz arka plan maddesi seçimleri bulunmaktadır.

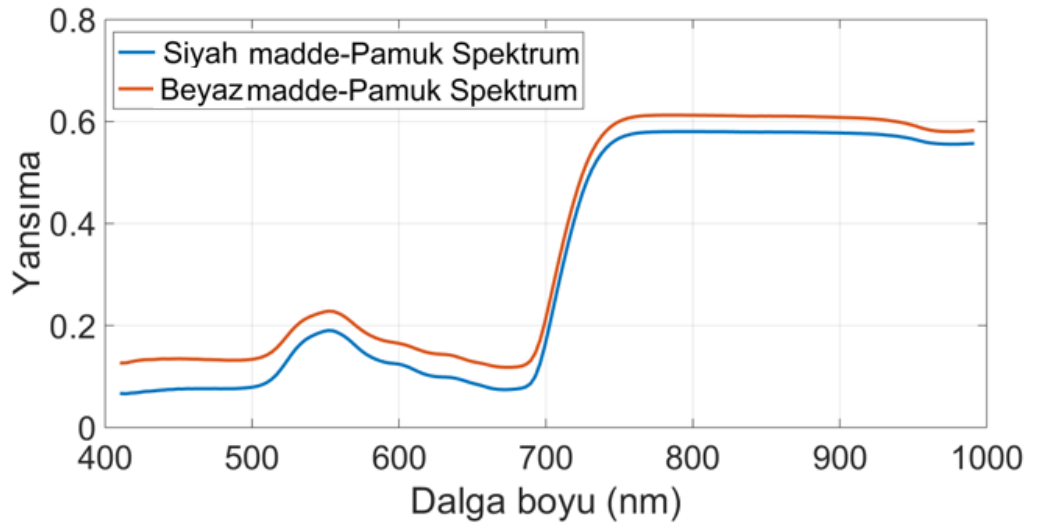


Şekil 3.9 Kontak prop tekniğiyle spektrum ölçümü

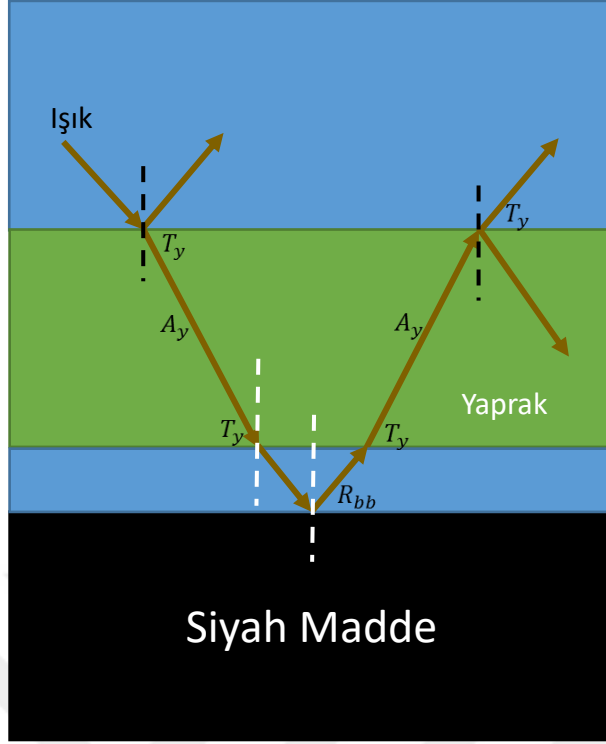
Beyaz arka plan idealde tam beyaz (tüm dalga boylarında tam yansıtma) ve siyah arka plan idealde tam siyah (tüm dalga boylarında tam soğurma) olmadığı için, bu maddelerden bol miktarda üst üste konularak ideal beyaz ve ideal siyah yansıtma spektrumuna yakınsamaya çalışılmıştır. Beyaz ve siyah arka plan yansıtma spektrumları şekil 3.10'da gösterilmiştir. Bu şekilde her bir durum için spektrometre ile kontak prop yapılarak 10 ar tane imza alınmış ve bu imzaların ortalaması hesaplanmıştır. 10 ölçüm üzerinden elde edilen ortalama spektrumlar ( $S_w$  ve  $S_b$ ) şekil 3.11'de verilmiştir. Spektrum ölçümünde şekil 3.12-3.13'te gösterildiği üzere yapraktan doğrudan yansıtma ile beyaz ve siyah arka plan ile etkileşim terimleri düşünülmüştür. Yaprığın iletimi  $T_y$ , yaprağın soğurması  $A_y$  olmak üzere,  $R_{bb}$  ve  $R_{wb}$  olarak ölçülen siyah arka plan ve beyaz arka plan yansıtma spektrumları kullanılarak, yaprak için gerçek yansıtma ( $R_y$ ) ve gerçek iletim ( $T_y'$ ) spektrumları eşitlik 3.3-3.8'e göre hesaplanmıştır. Işığın izlediği yol snell yasasına uymakta (Marcelo ve Paulo 2013) ve hesaplamalar Fresnel eşitliklerinin uyarlaması olarak ele alınmaktadır (Lvovsky 2013).



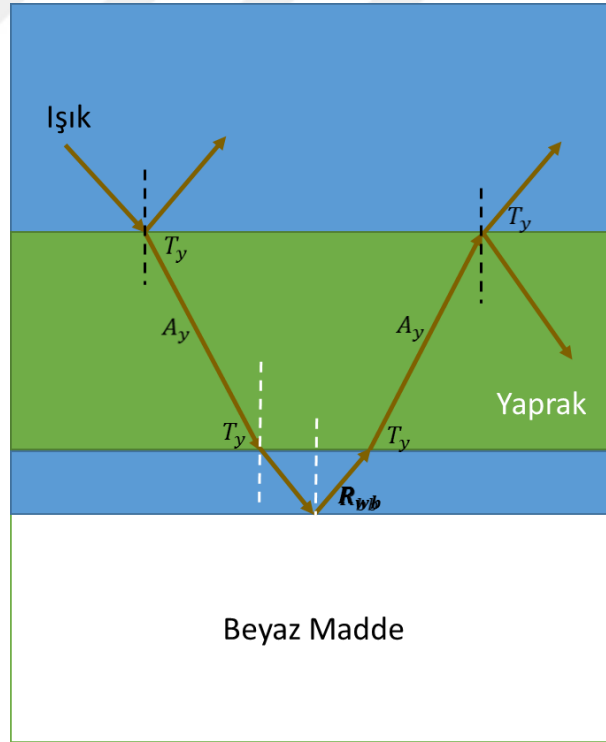
Şekil 3.10 Siyah ve beyaz arka plan yansima spektrumu



Şekil 3.11 Siyah ve beyaz arka plan üzerinde pamuk yaprağı spektrası



Şekil 3.12 Spektrometre ile spektrum ölçümü: Yaprak-siyah madde etkileşimi



Şekil 3.13 Spektrometre ile spektrum ölçümü: Yaprak-beyaz arka plan etkileşimi

$$R_y + T_y A_y T_y R_{wb} T_y A_y T_y = S_w \quad (3.3)$$

$$R_y + T_y A_y T_y R_{bb} T_y A_y T_y = S_b \quad (3.4)$$

$$R_y + T_y^4 A_y^2 R_{wb} = S_w \quad (3.5)$$

$$R_y + T_y^4 A_y^2 R_{bb} = S_b \quad (3.6)$$

$T_y' = T_y^2 A_y$  olmak üzere;

$$T_y' = \sqrt{(S_w - S_b)/(R_{wb} - R_{bb})} \quad (3.7)$$

$$R_y = S_w - T_y^4 A_y^2 R_{wb} \quad (3.8)$$

### 3.3 Bilineer Modelin Oluşturulması

Tez çalışmasında yansıma etkileşimlerine iletim etkileşimi eklenmesi, son öğelerin yer doğruluk spektral ölçümlerinden gerçek yansıma ve toplam iletim spektrumunun hesaplanması ve bilinear modelde kullanılması ile geleneksel bilinear model geliştirilmiştir. Geliştirilen bilinear model eşitlik 3.9 ile ifade edilmektedir. Eşitlikte  $r_m$ , ( $m$ )'nci son öğe için gerçek yansıma spektrumunu,  $t_n$ , ( $n$ )'nci son öğe için hesaplanan toplam iletim spektrumunu ifade etmektedir. Geliştirilen bilinear model genel bir modeldir ve her sayıda son öğe için her sahnede geçerlidir.

$$S = \sum_{m=1}^M a_m r_m + \sum_{m=1}^M \sum_{k=1}^M b_{mk} r_m \odot r_k + \sum_{n=1}^M \sum_{l=1}^M c_{nl} t_n \odot r_l \quad (3.9)$$


Sadelik açısından ve kavramın ispatı için pamuk ve mısır bitki örtülerinin yer aldığı hiperspektral görüntüler kullanılmıştır. Bu nedenle görüntülerdeki her bir pikselde yaprak ve toprak son öğelerinin yer aldığı düşünülmüştür. İki son öğeli durumda bilinear modelde iki doğrusal ve beş doğrusal olmayan etkileşim terimi yer almaktadır.

Bunlar:

1. Yapraktan doğrudan (tek) yansıma ( $R_y$ )
2. Topraktan doğrudan (tek) yansıma ( $R_t$ )

3. Yapraktan tek yansıma sonrası topraktan tek yansıma ( $R_y \odot R_t$ )
4. Yapraktan tek yansıma sonrası yaprakdan tek yansıma ( $R_y \odot R_y$ )
5. Yapraktan iletim sonrası topraktan tek yansıma ( $T'_y \odot R_t$ )
6. Yapraktan iletim sonrası yaprakdan tek yansıma ( $T'_y \odot R_y$ )
7. Toprakdan tek yansıma sonrası topraktan tek yansıma ( $R_t \odot R_t$ ) durumlarıdır.

Sahnede toprak bitkinin altında yer aldığı ve görüntüde arka plan olarak gözüktüğü için, “toprakdan iletim sonrası topraktan tek yansıma” ve “toprakdan iletim sonrası yaprakdan tek yansıma” etkileşim terimleri, spektral karışıma etki etmeyeceği düşünülerek modele dahil edilmemiştir. Doğrusal ve etkileşim terimlerinin fiziksel oluşumları şekil 3.14’te gösterilmiştir.




Şekil 3.14 Yöntem bilineer model terimleri fiziksel gösterimi

Bilineer modelin ağırlıklı toplam spektrumu kullanılan görüntüdeki piksel spektrum değerine ( $P_s$ ) eşitlenmektedir (Eşitlik 3.10). Bütün terimlerin bolluk değerlerinin toplamı ise 1 olarak alınmıştır (Eşitlik 3.11).

$$\alpha_1 R_y + \alpha_2 R_t + \alpha_3 R_y \odot R_t + \alpha_4 T'_y \odot R_t + \alpha_5 T'_y \odot R_y + \alpha_6 R_y \odot R_y + \alpha_7 R_t \odot R_t = P_s \quad (3.10)$$

$$\alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 + \alpha_5 + \alpha_6 + \alpha_7 = 1 \quad (3.11)$$

Şekil 3.15'te önerilen bilineer modelin tek ve etkileşim spektrum bileşenleri gösterilmiştir.



Şekil 3.15 Bilineer model tek ve etkileşim spektrumları

### 3.4 Bolluk Değer Kestirimi

Bilineer modeldeki son öge bolluk değerlerinin kestirilmesi amacıyla eşitlik 3.12 yazılabilir. Matris çarpımı EKKH yöntemi kullanılarak BNOK (Bolluk değeri negatif olamaz koşulu) ve BT1OK (Bolluk değerleri toplamı 1 olma koşulu) yaklaşımıyla çözülmüştür. Matris sisteminde,  $R_{y(i)}$  yaprak gerçek yansıma spektrumunun  $i$ . banttaki değerini,  $R_{t(i)}$  toprak gerçek yansıma spektrumunun  $i$ . banttaki değerini göstermektedir. Benzer şekilde  $T'_{y(i)}$  yaprak toplam iletim spektrumunun  $i$ . banttaki değerini,  $T'_{t(i)}$  toprak toplam iletim spektrumunun  $i$ . banttaki değerini göstermektedir. Gerçek yansıma ve toplam iletim spektrumları görüntüye bağımlı değildir. Spektrometre ile yerden ölçülen spektrumlar kullanılarak hesaplanmışlardır. Matris sisteminde  $\alpha$  bilinmeyen bolluk değerleri vektörünü,  $\alpha_i$   $i$ . bilineer terimin bolluk değerini ifade etmektedir.  $P_{s(i)}$  ise analiz edilen pikselin görüntüde ölçülen yansıma spektrumunun  $i$ . banttaki değerini temsil etmektedir.

$$\begin{bmatrix} R_{y(1)} & R_{t(1)} & R_{y(1)}R_{t(1)} & T'_{y(1)}R_{t(1)} & T'_{y(1)}R_{y(1)} & R_{y(1)}R_{y(1)} & R_{t(1)}R_{t(1)} \\ R_{y(2)} & R_{t(2)} & R_{y(2)}R_{t(2)} & T'_{y(2)}R_{t(2)} & T'_{y(2)}R_{y(2)} & R_{y(2)}R_{y(2)} & R_{t(2)}R_{t(2)} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ R_{y(N)} & R_{t(N)} & R_{y(N)}R_{t(N)} & T'_{y(N)}R_{t(N)} & T'_{y(N)}R_{y(N)} & R_{y(N)}R_{y(N)} & R_{t(N)}R_{t(N)} \end{bmatrix}_{N \times 7} * \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_7 \end{bmatrix}_{7 \times 1} = \begin{bmatrix} P_{s(1)} \\ \vdots \\ P_{s(N)} \end{bmatrix}_{N \times 1} \quad (3.12)$$

### 3.5 Piksel Spektrum Kestirimi

Kestirilen bolluk değerleri eşitlik 3.10'da kullanılarak piksel spektrumları kestirilmiştir. Ayrıca doğrusal yöntem, Nascimento (Nascimento ve Bioucas-dias 2009), Fan (Fan vd. 2009), Zhang (Zhang vd. 1998) ve PPNM (Altmann 2012) yöntemleri için de spektral ayrıştırma ve piksel kestirimi gerçekleştirilmiştir. 11 Haziran, 25 Haziran ve 12 Ağustos (2016) tarihlerinde elde edilen hiperspektral görüntü verileri için belirtilen kestirimler yapılmıştır. Sonuçlar, Bölüm 4: "Araştırma Bulguları" bölümünde detaylandırılmıştır.

### 3.6 Kestirim Hatası Hesaplama

Piksel spektrum kestirimi işleminden sonra, ilgili piksel için önerilen yöntem ve karşılaştırma yapılan doğrusal ve bilineer yöntemler için kestirim hatası ( $e$ ) hesaplanmıştır.  $P_s$  görüntüden elde edilen orijinal piksel spektrumu ve  $P'_s$  kestirilen spektrum olmak üzere, kullanılan tüm bantlar için yüzde ortalama mutlak hata değeri ve spektral açı uzaklık hata değeri hesaplanmıştır.  $N$  bant sayısını,  $k$ , 1 ile  $N$  arasında değişen bant numarasını ifade etmektedir. Buna göre her bant için mutlak kestirim hatasının yüzde değeri eşitlik 3.13'e göre hesaplanmıştır.

$$e(k) = \frac{100 * |P_{s(k)} - P'_{s(k)}|}{P_{s(k)}} \quad (3.13)$$

Bir piksel için ortalama mutlak yüzde kestirim hatası  $e_{ort}$  ise eşitlik 3.14'e göre hesaplanmıştır.

$$e_{ort} = \frac{\sum_{k=1}^N e(k)}{N} \quad (3.14)$$

$\|... \|$  Öklidiyan normunu,  $\langle ... , ... \rangle$  nokta çarpımını göstermek üzere spektral açı uzaklık (SAU) hata değeri ise eşitlik 3.15 kullanılarak hesaplanmıştır.

$$\emptyset(P_s, P'_s) = \arccos \frac{\langle P_s, P'_s \rangle}{\|P_s\| \|P'_s\|} \quad (3.15)$$

Piksel kestirim hatası hesaplamada kullanılan bir başka hata türü KOKH (Karekök ortalama kare hata) ise eşitlik 3.16 kullanılarak hesaplanmıştır.

$$e_{ort} = \sqrt{\frac{\sum_{k=1}^N (P_{s(k)} - P'_{s(k)})^2}{N}} \quad (3.16)$$

### 3.7 Önerilen Yöntemle Bitki Örtüsü Sınıflandırma

Tez çalışmasında önerilen spektral ayrıştırma yöntemi kullanılarak, bitkinin çok genç olduğu, alt piksele düştüğü ve dolayısıyla spektral karışım oranının yüksek olduğu zaman anlarında alınmış hiperspektral görüntülerde sınıflandırma işlemi yapılmıştır. Hedef bitki alt piksele düştüğü için geleneksel piksel tabanlı yöntemler çoğu zaman yanlış alarm vermekte veya çok düşük doğrulukta sınıflandırma yapabilmektedirler. Tezde önerilen yöntem ile sınıflandırma yaparken öncelikli olarak, hiperspektral veride gürültülü bant eleme ve bant seçim işlemleri uygulanmıştır. Bu işlemler bölüm 3.7.1 “Gürültülü bant eleme” ve bölüm 3.7.2 “Bant seçimi” bölümlerinde detaylandırılmaktadır.

#### 3.7.1 Gürültülü bant eleme

Gürültülü bant eleme işlemi spektral ayrıştırma öncesinde yapılması gereken önemli bir ön işlemdir. Çünkü gürültülü bantlar yansıma spektrumunu değiştirip bozarak eşleştirme sonuçlarının başarısını düşürebilmektedir. Tez çalışmasında gürültülü bant eleme işlemi için Nguyen ve Hakil (2009)’daki çalışmada kullanılan yöntem uygulanmıştır. Bu yöntem bantlar arasındaki korelasyon değerine bağlı istatistiksel bir gürültülü bant eleme tekniği kullanmaktadır. Korelasyon katsayısı iki rastgele değişken arasındaki benzerliğin bir ölçümüdür. Hiperspektral verinin her bir bantı rastgele bir değişken olarak düşünüldüğünde, bantlar birbirine spektral olarak çok yakın olduğundan, ardışık bantlar arasındaki korelasyon katsayısının normal olarak yüksek çıkması beklenir. Fakat gürültülü bir bant, komşuluğundaki bantlarla düşük bir korelasyon değeri üretir. Nguyen ve Hakil (2009)’da gürültülü bant eleme işlemi uygulanmış veri ile orijinal verinin SAM (Spectral Angle Mapper) ve SID (Spectral Index Data) gibi yöntemler kullanılarak, sınıflandırma başarısı karşılaştırılmıştır. Sonuç


olarak gürültülü bant eleme işleminin son öge ayrıştırılabilirliğini ve sınıflandırma sonucu doğruluğunu artırdığı belirtilmiştir. Tez çalışmasında aynı yöntem, çalışılan hiperspektral görüntülere uygulanmıştır. Böylece son öge ayrıştırılabilirliği ve spektral ayrıştırma başarısının artırılması, spektral kestirim hatasının azaltılması amaçlanmıştır. Gürültülü bant eleme işlemi şu şekilde çalışmaktadır:

**Adım 1:**  $X$  ve  $Y$  rastgele değişkenleri arasındaki korelasyon katsayısının değeri eşitlik 3.17 ve 3.18'de verildiği gibi hesaplanmaktadır.  $Cov(X, Y)$ ,  $X$  ve  $Y$  değişkenleri arasındaki kovaryans değerini,  $\sigma_x$  ve  $\sigma_y$  rastgele değişkenlerin standart sapma değerlerini,  $E$  beklenen değeri,  $\mu_x$  ve  $\mu_y$  ortalama değerleri göstermektedir. Tez çalışmasında hiperspektral görüntünün her bir bandı rastgele değişken olarak düşünülerek ( $i$ ). ve ( $i - 1$ ). bantlar arasındaki korelasyon katsayısı  $\rho_{i-1,i}$  hesaplanmış, [0 100] aralığına normalize edilmiş ve 100 birimlik histogram oluşturulmuştur.

$$\rho_{xy} = Corr(X, Y) = \frac{Cov(X, Y)}{\sigma_x \sigma_y} \quad (3.17)$$

$$Cov(X, Y) = E[(X - \mu_x)(Y - \mu_y)] \quad (3.18)$$

Ardışık bantlar normal durumda bir maksimum değer etrafında yüksek değerlerde korelasyon değeri üretir. Gürültülü bantlar arasında veya gürültülü ve sinyal bantları arasında ise korelasyon değeri düşük çıkacak ve rastgele dağılım gösterecektir. Şekil 3.16'da görüldüğü üzere histogram, bir maksimum değerde tepe yapmaktadır.



Şekil 3.16 Korelasyon katsayıları 100-binlik histogram grafiği

Histogramdan, maksimum değere yakın olan değerlerden adaptif bir eşik değeri seçilir ve aşağıdaki kurallara göre sinyal bantları belirlenir. Sinyal bantları dışında kalan bantlar gürültü bantları olarak ele alınır ve bu bantlar toplam hiperspektral veriden çıkartılır.

**Adım 2:** Potansiyel bantlardan sinyal bantlarını bulma

- Eğer  $\rho_{i-1,i} > eşik$  ve  $\rho_{i,i+1} > eşik$  ise  $(i)$ . bant sinyal bandıdır.
- Değilse,  $(i)$ . bant potansiyel gürültü bandıdır.


**Adım 3:** Potansiyel gürültü bantlarının artırılması

Her potansiyel gürültü bandı  $k$  için,

- Gerideki eden en yakın sinyal bandı  $(k - m)$  bulunur.
- Takip eden en yakın sinyal bandı  $(k + n)$  bulunur.

- Eğer  $\rho_{k-m,k} > eşik$  veya  $\rho_{k,k+n} > eşik$  ise ( $k$ ). bant sinyal bandı olarak güncellenir.
- Değilse ( $k$ ). bant gürültülü banttır.

Şekil 3.17 bitki spektrası için tam spektrum, sinyal bant vektörü ve sinyal bantlarını göstermektedir. Tezde kullanılan hiperspektral veri özelinde, 182 tane bant toplam 112 sinyal bandına indirgenmiştir.




Şekil 3.17 Örnek bir spektra için tüm spektra, sinyal bant vektörü ve sinyal bantları

### 3.7.2 Bant seçimi

Bant seçimi hiperspektral veri işlemede, işleme zamanını ve doğruluğunu doğrudan etkileyen önemli adımlardan birisidir. Spektral ayrıştırmada ve sınıflandırmada, son öğelerin spektral ayrımının fazla olması yöntemin başarılı olması için önemli bir nedendir. Şimdiye kadar yapılan çalışmalarda kullanılan bazı bant seçimi yöntemleri SID, PCA (Principal component analysis), MVPCA (Multi view principal component analysis), SNMF (Spectral nonnegative matched filter), SPABS (Sparse band selection) ve SSR (Symmetric sparse representation) olarak örneklenebilir. Her bir bant seçiminin

birbirlerine göre üstünlükleri bulunmaktadır. Ayrıca her yöntem, farklı sınıflandırıcılarla farklı başarıda sınıflandırma sonuçları üretebilmektedir. (Sun vd. 2016). Buradaki temel nokta kullanılan hiperspektral veri özelinde hangi yöntemin daha iyi sonuç ürettiğini tespit etmek ve uygulamada o yöntemi kullanmaktır. Tez çalışmasında ise hiperspektral görüntülerin piksellerini oluşturduğu düşünülen yaprak ve toprak son öge spektrumlarına BAO\_Max (Bands Add-On Maximum) yöntemiyle bant seçim işlemi uygulanmıştır (Stefan 2010). BAO\_Max yöntemi, hiperspektral verilerde bant seçimi işlemi için literatürde sıklıkla kullanılmıştır. Bu yöntemdeki amaç, spektral ayrıştırılabilirliği maksimum yapan bant dizisini tespit etmektir. Tez çalışmasında BAO\_Max yöntemi spektral açığı bulma temelinde uygulanmıştır. Temel amaç, iki vektör arasındaki açığı ölçerek bu açının en büyük olduğu boyut dizisini belirlemektir. İki boyutlu uzayda iki vektör örneği ve aralarındaki açının ( $\emptyset$ ) gösterimi şekil 3.18’de verilmiştir.



Şekil 3.18 İki boyutlu uzayda iki vektör ve aralarındaki açı

İki vektör arasındaki açının hesaplanmasında eşitlik 3.19 kullanılabilir. Eşitlikte  $\|... \|$  Öklidiyan normu,  $V_1$  ve  $V_2$  vektörleri,  $\langle V_1, V_2 \rangle$  ise nokta çarpımı göstermektedir.

$$\emptyset(V_1, V_2) = \arccos \frac{\langle V_1, V_2 \rangle}{\|V_1\| \|V_2\|} \quad (3.19)$$

Açı uzaklığına bağlı BAO\_Max yöntemi tez çalışmasında, bitki ve toprak bütün dalga boyu spektrum imzaları için, bu imzaları birbirinden en fazla ayırt edecek olan bantları belirlemeye yönelik olarak kullanılmıştır. BAO\_Max yönteminin seçtiği bantlardaki değerlerden oluşan bitki ve toprak spektrum vektörleri arasındaki “ $N$ ” boyuttaki açı değeri maksimize edilmiş olmaktadır. Bu durum son öğeler arasındaki aykırılığın en üst seviyeye çıktığı bantları belirlediği için, bu son öğelerin oluşturmuş olduğu karışım pikselini de daha kesin biçimde ve daha az hatayla ayırt etmeyi sağlamaktadır.

İki vektör arasındaki açı, bu iki vektörün nokta çarpımlarının *arccos* değeri bulunarak hesaplanmıştır. Düşük değerdeki açı, bu iki vektörün çok benzeştiğini, yüksek değerdeki açı ise vektörlerin daha az benzeştiğini veya benzeşmediğini göstermektedir. Bu nedenle, benzeşimin en yüksek olduğu bant dizisinin bulunması spektral ayrıştırma ve sınıflandırma başarısının artmasını sağlamaktadır. BAO\_Max bant seçim yöntemi, son öğe spektrumlarında, hiperspektral veride gürültülü bant eleme işlemi sonucunda sinyal bandı olarak tespit edilen bantlar için uygulanmıştır. İki son öğe spektrası  $x$  ve  $y$ , açısal uzaklık  $d$  olmak üzere  $d$  nin hesaplanması eşitlik 3.20’de gösterilmiştir.

$$d(x, y) = \arccos \frac{\langle x, y \rangle}{\|x\| \|y\|} \quad (3.20)$$

$\langle x, y \rangle$  nokta çarpımı, ve  $\|.\|$  Öklidiyan normu göstermektedir.  $x$  ve  $y$  nin bir küme spektral bant ( $B$ ) değerleri, ve spektral uzaklık  $d$  için, bant seçiminin amacı iki vektör arasındaki spektral açığı maksimum yapan alt bant kümesi olan  $B_1$ ’i bulmaktır.

U Küme birleşim işlemini göstermek üzere, BAO\_Max yöntemi şöyle çalışmaktadır:

$N$  boyutundaki  $x$  ve  $y$  vektörleri (son öge spektrumu) için;

**Adım 1:** 1 ve  $N$  arasında aşağıdaki şartı sağlayan  $k_1$  ve  $k_2$ 'yi bul.

$$[k_1, k_2] = \arg \max_{\substack{1 \leq k_1 \leq N \\ 1 \leq k_2 \leq N \\ k_1 \neq k_2}} d(x_{[k_1, k_2]}, y_{[k_1, k_2]})$$

**Adım 2:**  $B_1 = \{k_1, k_2\}$

**Adım 3:**  $j = \arg \max_{\substack{1 \leq k_1 \leq N \\ k \notin B_1}} d(x_{[B_1, j]}, y_{[B_1, j]})$  şartını sağlayan 1 ve  $N$  arasındaki  $j$  değerini

bul.

**Adım 4:** Eğer  $d(x_{[B_1, j]}, y_{[B_1, j]}) > d(x_{B_1}, y_{B_1})$  ise  $B_1 = B_1 \cup \{j\}$  ve üçüncü adıma dön.


**Adım 5:** Değilse durdur.

Tez çalışmasında, pamuk ve mısır bitkileri için önerilen spektral ayrıştırma yöntemi ile sınıflandırma çalışması yapılmıştır. Bu nedenle, pamuk-toprak ve mısır-toprak spektra çiftlerine BAO\_Max uygulandıktan sonra, elde edilen bantlar önerilen bilineer ayrıştırma için kullanılmıştır. Aynı bantlar hiperspektral veriden de seçilmiştir. Pamuk-toprak için BAO\_Max yöntemine göre seçilen bantlar [19, 20, 41, 84, 132], mısır-toprak için ise [24, 31, 44, 49, 79, 81, 134] olarak belirlenmiştir. Bu bant dizileri pamuk-toprak ve mısır-toprak spektrumunu açısız olarak birbirinden en uzak tutan bant dizisidir denilebilir.

### 3.7.3 Gürültülü bant eleme ve bant seçimi algoritma akışı

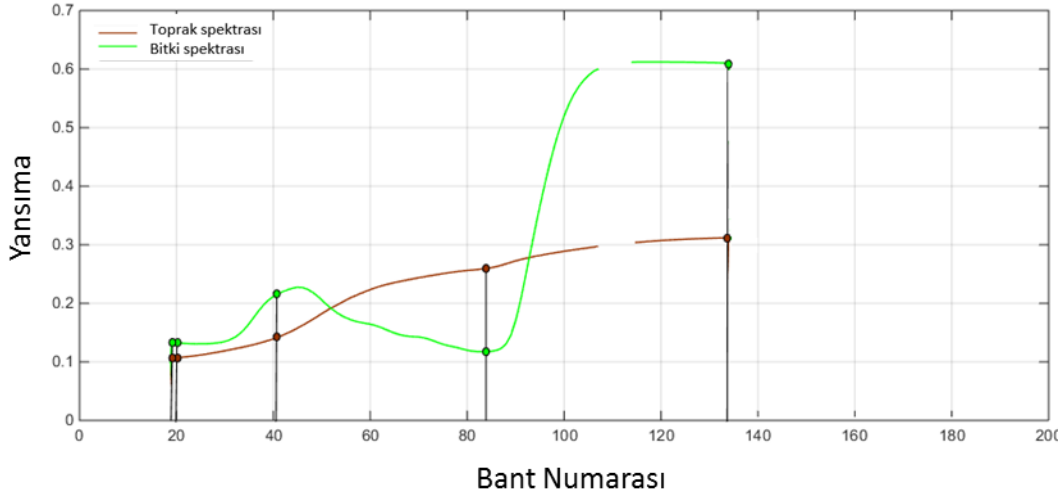
Gürültülü bant eleme ve bant seçim yöntemlerinin tezde uygulama şeması şekil 3.19'da gösterilmiştir. Öncelikli olarak hiperspektral veride gürültülü bant eleme işlemi uygulanmış ve sinyal bantlarından oluşan indirgenmiş hiperspektral görüntü elde edilmiştir. Aynı zamanda ayrıştırmada kullanılacak olan sinyal bantları belirlenmiştir. Görüntüde olduğu bilinen veya tahmin edilen son öğelerden elde edilmiş olan spektral imzalar, görüntüde gürültülü bant işlemi sonucunda kalan sinyal bantları üzerinden,

bant seçimi işleminden geçirilmiştir. Bant seçiminde ayrıştırılabilirliği en yüksek değerde sağlayan bantlar bulunmuştur. Hiperspektral veride sadece bu bantlar seçilerek, son öge spektrumları ile tezde önerilen spektral ayrıştırma yöntemine sokulmuştur.



Şekil 3.19 Gürültülü bant eleme ve bant seçimi işlemi


Bir toprak örneği ve pamuk yaprağının spektrometre ile ölçülmüş spektra örnekleri (182 bant) için gürültülü bantların elenmiş ve bant seçimi uygulanmış durumu şekil 3.20’de verilmiştir. Kiremit rengi ve yeşil renkteki noktalar BAO\_Max yöntemine göre seçilen bantların konumunu göstermektedir. Bu bantların son öge spektrumlarındaki ve hiperspektral görüntüdeki yansıma değerleri önerilen spektral ayrıştırma yönteminde kullanılmıştır.



Şekil 3.20 Bitki ve toprak spektrasında gürültülü bant eleme ve bant seçimi sonucu

### 3.7.4 Sınıflandırma yöntemi

Tez çalışmasında, önerilen spektral ayrıştırma yöntemi kullanılarak bitki örtüsü sınıflandırma işlemi yapılmıştır. Sınıflandırma işlemi gösteren algoritma akışı şekil 3.21’de verilmiştir. Bu duruma göre, sınıflandırma işleminin yapılacağı yeryüzünde olması muhtemel tüm son öğelerin spektrometre ile yerden spektral imzaları toplanır. Görüntüsü çekilen arazide her bir pikselin bitki ve toprak spektral karışımı olduğu düşünülür. Her bir son öğe spektrası ve toprak spektrası ile bir spektral kütüphane oluşturulur. Bilinmeyen bir pikselin hangi sınıfa ait olduğunu bulabilmek için tüm bitki-toprak spektra çiftleri ile bilinmeyen piksel önerilen spektral ayrıştırma yöntemine tabi tutulur. Analiz sonucunda spektral kestirim yapılarak kestirim hataları hesaplanır. Kestirim hataları minimum hata sınıflama işlemine tabi tutulur. Hangi son öğe ile daha az kestirim hatası elde edildiye, bilinmeyen piksel o son öğe sınıfına atanır. Şekil 3.21’deki “Önerilen spektral ayrıştırma yöntemi” kutusunun içeriği ise şekil 3.19’da verilmiştir. Önerilen sınıflandırma yönteminde, görüntü pikselinde ikiden fazla son öğe bulunabileceği öngörülebilir. Böyle bir durumda diğer son öğeler de bilinear model içerisine dahil edilmelidir.



Şekil 3.21 Önerilen yöntem için sınıflandırma şeması

#### 4. ARAŞTIRMA BULGULARI

Çalışmada kullanılan görüntüler 11 Haziran, 25 Haziran ve 12 Ağustos 2016 tarihlerinde VNIR bant dalga boyunda (400-1000 nm) çalışan hiperspektral kamera ile yere göre 3000 m yükseklikte uçuş yapan uçak platformu üzerinden *Şanlıurfa Harran* bölgesinden çekilmiştir. Görüntü çekilen alandan Pamuk ekili tarlalarda Haziran ve Ağustosta alınan yer fotoğrafı örnekleri şekil 4.1.a, b'de gösterilmiştir. Haziran ayında bitki boyu ve taç alanı oldukça küçüktür ve bu durumda sensördeki herhangi bir pikselde yüksek oranda spektral karışım oluşmaktadır. Ağustos görüntüsünde görüldüğü üzere, bitki gelişmiş ve 1 pikselin içini çok büyük oranda tek başına dolduracak büyüklüğe erişmiştir. Fakat bu durumda bile sensördeki 1 pikselde yine yüksek oranda spektral karışım bulunacaktır. Çünkü bu defa yapraklar sıklaştığı için çoklu etkileşim (yansımaya-yansımaya ve/veya iletim-yansımaya) durumu meydana gelmektedir.



Şekil 4.1 Pamuk tarlaları yer fotoğrafları  
a. Haziran ayı görüntüsü , b. Ağustos ayı görüntüsü

Her bir görüntü için önerilen yöntem ve karşılaştırma yapılacak olan doğrusal yöntem ve literatürde yer alan en önemli bilineer modeller test edilmiştir. Bu bölümde piksel kestirim hatası için test sonuçları sırasıyla 11 Haziran, 25 Haziran ve 12 Ağustos görüntüleri için verilmektedir. Ayrıca aynı bölgeden elde edilmiş olan pamuk ve mısır tarlalarının görüntüleri için, önerilen yöntem ile piksel kestirimi yapılarak, kestirim hatasına göre sınıflama işlemi yapılmıştır. Sınıflama işlemine ait sonuçlar da bu bölümde verilmektedir. Karşılaştırması yapılan modellerin kullandığı parametrelerin ve kısıtlamaların özeti çizelge 4.1'de verilmiştir.

Çizelge 4.1 Bilineer modeller, parametreler ve kısıtlamalar

Modeller	Bilineer parametreler	Kısıtlamalar	İletim spektrumu
Fan	$\forall m \geq k: b_{mk} = 0$ $\forall m < k: b_{mk} = a_m a_k$	$\sum_{m=1}^M a_m = 1$	X
PPNM	$\forall m, k: b_{mk} = c a_m a_k$	$\sum_{m=1}^M a_m = 1$	X
Nascimento	$\forall m \geq k: b_{mk} = 0$ $\forall m < k: b_{mk} \geq 0$	$\sum_{m=1}^M a_m + \sum_{m=1}^{M-1} \sum_{k=m+1}^M b_{mk} = 1$	X
Zhang	$\forall m \geq k: b_{mk} = 0$ $\forall m < k: b_{mk} \geq 0$ $\forall n \leq l: c_{nl} \geq 0$	$\sum_{m=1}^M a_m + d \sum_{m=1}^{M-1} \sum_{k=m+1}^M b_{mk} + d \sum_{n=1}^M \sum_{l=1}^M c_{nl} = 1$	$\sqrt$
Önerilen	$\forall m \geq k: b_{mk} = 0$ $\forall m < k: b_{mk} \geq 0$	$\sum_{m=1}^M a_m + \sum_{m=1}^{M-1} \sum_{k=m+1}^M b_{mk} + \sum_{n=1}^M \sum_{l=1}^M c_{nl} = 1$	$\sqrt$


Tüm modellerde,  $\forall m: a_m \geq 0$ ,

X: Hesaba katılmaz,  $\sqrt$ : Hesaba katılır


Zhang yönteminde iletim spektrumu, yansıma spektrumuna eşit kabul edilmiştir.

Önerilen yöntem piksel kestirimi ve piksel kestirim hatası için doğrusal yöntem ve literatürdeki en önemli bilineer yöntemler olan Fan (Fan vd. 2009), Nascimento (Nascimento ve Bioucas-dias 2009), PPNM (Altmann 2012) ve Zhang (Zhang vd. 1998) yöntemleriyle karşılaştırılmıştır. Önerilen yöntemde spektral karışmanın fiziksel yapısına uygun olarak yansıma etkileşimlerine, iletim etkileşimleri de eklenmiştir. Bununla birlikte spektrometre imzaları için beyaz ve siyah arka plan ile olan etkileşimler hesaba katılarak gerçek yansıma ve toplam iletim spektrumu hesaplanmıştır. 11 Haziran, 25 Haziran ve 12 Ağustos görüntüleri için en başarılı kestirim sonuçları önerilen yöntemle elde edilmiştir. Şekil 4.2-4.4 örnek bir piksel için tüm spektrum boyunca (411-992 nm bant aralığı) kestirim sonuçlarını göstermektedir. Tüm görüntüler için doğrusal yöntem ve Fan (Fan vd. 2009) yöntemi genel anlamda kötü sonuç vermektedirler. Doğrusal yöntemin doğrusal olmayan bir karışma durumunu başarılı şekilde modelleyemeyeceği düşünülebilir. Fakat benzer şekilde Fan (Fan vd. 2009) yöntemi de iyi sonuç vermemektedir. Bunun iki sebebi olabilir. Birincisi, Fan (Fan vd. 2009) yönteminde, bolluk değeri hesaplanırken BNOK ve BT1OK yalnızca doğrusal terimler için hesaba katılmaktadır. İkincisi ise lineer terim toplam spektrumuna


bilineer etkileşim teriminden gelen spektrum değeri ekstra olarak eklenmektedir. Bu yaklaşımın eksik ve aynı zamanda kısıtlayıcı olduğu hesaplanan sonuçlardan anlaşılmaktadır. Aynı durum PPNM (Altmann 2012) yönteminde de geçerli olmakla birlikte, PPNM (Altmann 2012) yönteminde öz etkileşimlerin de hesaba katılması ve bilineer terimlerin adaptif bir katsayıyla çarpılma esnekliği vardır. Bu durum bu çalışma özelinde adaptif bir değer ile kullanılmış ve Fan (Fan vd. 2009) yöntemine göre daha iyi sonuçlar alınabilmiştir. Fan (Fan vd. 2009), PPNM (Altmann 2012) ve GBM modellerindeki mantık, lineer karışım spektrumuna bilineer toplamı eklemek veya çıkarmaktır. Fiziksel gerçeklikte ise sensör ışığı toplarken, ışığın lineer terim toplamından veya bilineer terimlerden gelip gelmediğini bilmemektedir. Bu nedenle herhangi bir t anında, sensörün topladığı ışığın bilineer veya lineer terimlerden gelme durumu tamamen rastgeledir. Dolayısıyla BNOK ve BT1OK durumlarının bilineer modeldeki tüm etkileşim terimleri için düşünülmesi gerektiği değerlendirilmektedir. Nitekim Nascimento (Nascimento ve Bioucas-dias 2009), geliştirdiği yöntemde bu durumu dikkate almıştır. Nascimento (Nascimento ve Bioucas-dias 2009) yöntemi sadece yansıma etkileşimin varlığını düşünse de yine de iyi sonuçlar vermektedir. Zhang (Zhang vd. 1998) yöntemi, önerilen yöntemle en fazla benzeyen yöntemdir. Fakat yöntem bazı noktalarda eksik kalmıştır. Birincisi, yöntemde iletim ve yansıma spektrumunun eşit olduğu kabul edilir. BNOK ve BT1OK ise yalnızca doğrusal etkileşim terimleri için uygulanır. Bu çalışmada BNOK ve BT1OK tüm etkileşim terimlerine uygulanarak Zhang (Zhang vd. 1998) için düzeltme yapılmıştır. Düzeltmelerle birlikte Zhang (Zhang vd. 1998) için daha başarılı sonuçlar elde edilebilmiştir.



Şekil 4.2 11 Haziran görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi




Şekil 4.3 25 Haziran görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi




Şekil 4.4 12 Ağustos görüntüsünde rastgele seçilen bir piksel için spektrum kestirimi


Şekil 4.5-4.7’de görüntülerden rastgele seçilen 100 tane piksel için tüm spektrumda ortalama yüzde kestirim hatası sonuçları verilmiştir. Önerilen yöntemin en iyi sonuçları ürettiği ve diğer yöntemlere göre farklı pikseller için çok daha az dalgalanma yaşadığı görülmektedir.



Şekil 4.5 11 Haziran görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları




Şekil 4.6 25 Haziran görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları



Şekil 4.7 12 Ağustos görüntüsünde rastgele seçilen yüz piksel için ortalama kestirim hataları

Şekil 4.8 oldukça önemli bir sonucu göstermektedir. 12 Ağustos görüntüsünde, bitki olgun durumda ve gelişimini hemen hemen tamamlamıştır. Taç alanı büyük ve yukarıdan bakışta alınan görüntüde, bitki, bir pikseli neredeyse tamamen doldurabilmektedir. Buna rağmen kestirim hata değerleri, piksellerin saf pikselden çok daha uzak olduğu düşünülen Haziran görüntüsüne göre daha fazla çıkmıştır. Bu durum öncelikle “saf piksel” yaklaşımının daha iyi kestirim yapılması anlamına gelmediğini göstermektedir. Bitki büyüdükçe yaprakların sayısı ve bitki taç alanı artmaktadır. Bu durum yan yana olan bitkiler arasındaki mesafeyi daraltmakta veya kapatmaktadır. Bitki yaprakları birbiri içerisine girişim yapmaktadır. Bitkinin görüntüde karşılık geldiği pikselin bitki oranı ve bitki indeks değeri artmaktadır. Bu durum pikselin saf piksele yaklaştığını düşündürse de gerçekteki durum farklıdır. Pikseldeki bitki oranı arttıkça çoklu (İkiden fazla sayıda) yaprak yansıma-yaprak yansıma veya yaprak iletim-yaprak yansıma etkileşim terimleri karışım içerisinde çok daha fazla oranda gözükmemektedir. Bu durumda piksel kestirim hatasını azaltmak için, daha yüksek sayıda etkileşim terimleri ile modelleme yapmak gerekmektedir. Bu durum ise doğrusal ve bilineer modellemede ihmal edilmektedir. Bu nedenle de doğrusal ve bilineer modeller ile elde edilen kestirim


hatası yüksek çıkabilmektedir. Bununla birlikte önerilen yöntemin kestirim hatası görece daha düşük çıkmıştır. Bunun nedeni, doğrusal yöntem ve karşılaştırma yapılan bilineer yöntemlerin yapmadığı şekilde, spektral karışımındaki olası tüm bilineer etkileşimlerin hesaba katılmasıdır. Yani önerilen yöntem en azından spektral karışım durumunda olan pikseldeki bilineer etkileşimleri çok düşük hata ile hesaplamakta ve sadece ikiden fazla etkileşim durumlarını doğru modelleyememektedir. Bu nedenle de kestirim hatası 11 ve 25 Haziran kestirim hatası değerlerine göre fazla olmakla birlikte diğer yöntemlerden çok daha iyi bir oranda kalabilmektedir.



Şekil 4.8 Tüm görüntüde ortalama kestirim hataları

Tez çalışmasında, görüntü çekim bölgelerinde yerden alınan spektral imzalar kullanılmıştır. Aynı bitki çeşitlerinde bile bitkinin yetiştiği bölgeye ve imza alınan döneme göre spektral imzalar değişebilmektedir. Bu değişimin kestirim sonuçlarına nasıl yansıdığını tespit etmek amacıyla *Bolu, Gerede* bölgesinden alınmış olan bir

pamuk yaprađı spektra örneđi tez alıřmasında pamuk yaprađı imzası olarak alınarak, ortalama mutlak hata sonuçları hesaplanmıřtır. Görüntü ekim bölgelerinden alınan spektral imza ile Gerede'den edinilen spektra örneđinin üst üste grafiksel gösterimi řekil 4.9'da verilmiřtir.



řekil 4.9 Bölgeden alınan pamuk spektrası ve Gerede'den edinilen pamuk spektrası

Belirtilen test 11 Haziran görüntüsünde denenmiřtir ve izelge 4.2'de belirtilen sonuçlar alınmıřtır. Bölge dıřından edinilen bir pamuk yaprađı spektrası kullanıldıđında tüm yöntemlerde kestirim hatası artmaktadır. Bu durum, bitki spektral imzalarının bölgeden bölgeye ve spektra toplama zamanına göre deđiřkenlik gösterdiđini ispatlamaktadır.

Çizelge 4.2 Bölgeden alınan spektra ile Gerede'den edinilen spektra için kestirim sonuçları

Yöntemler	İmza-Diğer	İmza-Bölge
Fan	85,88	66,40
PPNM	63,19	35,01
Nascimento	28,74	19,71
Zhang	104,67	71,24
Doğrusal	86,18	68,24
Önerilen	<b>7,79</b>	<b>6,13</b>

Çizelge 4.3 11 Haziran, 25 Haziran ve 12 Ağustos görüntüleri için görüntüden elde edilen orijinal piksel spektrumu ile tezde karşılaştırılması yapılan yöntemlerle kestirilen piksel spektrumu arasındaki ortalama SAU hata değerlerini (derece cinsinden) göstermektedir. Tablodan görüleceği üzere önerilen yöntemle elde edilen hata değerleri diğer tüm yöntemlere üstünlük kurmaktadır.

Çizelge 4.3 Doğrusal ve bazı bilineer yöntemler için hesaplanan SAU hata değerleri

Yöntemler	11 Haziran	25 Haziran	12 Ağustos
Fan	6,60	12,64	16,96
PPNM	7,43	14,23	20,34
Nascimento	9,45	1,99	12,55
Zhang	3,34	8,67	24,02
Doğrusal	6,58	13,09	17,98
Önerilen	<b>2,41</b>	<b>1,83</b>	<b>4,04</b>

Çizelge 4.4 11 Haziran, 25 Haziran ve 12 Ağustos görüntüleri için görüntüden elde edilen orijinal piksel spektrumu ile tezde karşılaştırılması yapılan yöntemlerle kestirilen piksel spektrumu arasındaki kök ortalama kare hata (KOKH) değerlerini göstermektedir. Hata değerleri ile birlikte yanlarında, standart sapma değerleri de verilmiştir. Ortalama mutlak hata ve spektral açı uzaklık hata değerlerinde olduğu gibi KOKH için de önerilen yöntemde diğer yöntemlere göre daha düşük hata sonuçları elde edilmektedir. Ayrıca hatanın dağılımı da diğer yöntemlere göre ortalama değerden daha

az sapma göstermektedir. Bu durum önerilen yöntemin başarısının piksele ya da görüntüye bağımlı olmadığını göstermektedir.

Çizelge 4.4 Doğrusal ve bazı bilineer yöntemler için hesaplanan KOKH değerleri

Yöntemler	11 Haziran	25 Haziran	12 Ağustos
Fan	11,89±0,50	6,47±0,82	11,61±0,45
PPNM	8,28±0,47	4,99±0,85	10,00±0,55
Nascimento	3,48±0,52	0,87±0,20	5,87±1,22
Zhang	14,27±0,55	6,70±0,99	12,76±1,81
Doğrusal	11,89±0,50	6,16±0,80	10,37±0,35
Önerilen	<b>0,60±0,05</b>	<b>0,70±0,11</b>	<b>1,81±0,26</b>

Çizelge 4.5, 25 Haziran görüntüsünden rastgele seçilen bir piksel için bolluk değerlerini göstermektedir. Yaprak iletim-toprak yansıma etkileşim teriminin %43'lük bir oranla spektral karışımı domine ettiği görülmektedir. Fakat bu etkileşim, diğer yöntemler tarafından ihmal edilmektedir. Bu nedenle bu yöntemlerin bulduğu kestirim hataları, önerilen yönteme göre yüksek çıkmaktadır.

Çizelge 4.5 Doğrusal ve bazı bilineer yöntemler için hesaplanan bolluk değer haritası

Bilineer Terimler	Yöntemler					
	Fan	PPNM	Nascimento	Zhang	Doğrusal	Önerilen
Yapraktan tek yansımaya	0,207	0,2072	0,0447	0	0,207	0,1156
Topraktan tek yansımaya	0,793	0,7928	0,185	0,779	0,793	0,1683
Yapraktan yansımaya sonrası topraktan yansımaya	0,164	-0,296	0,7713	0,055	NA	0
Yapraktan iletim sonrası topraktan yansımaya	NA	NA	NA	0,055	NA	0,4335
Yaprak iletim sonrası yapraktan yansımaya	NA	NA	NA	0,055	NA	0
Yapraktan yansımaya sonrası yapraktan yansımaya	NA	-0,077	NA	0,055	NA	0,2406
Topraktan yansımaya sonrası topraktan yansımaya	NA	-1,121	NA	NA	NA	0,0420
<b>Ortalama Hata (%)</b>	<b>78,53</b>	<b>29,44</b>	<b>6,34</b>	<b>42,07</b>	<b>74,65</b>	<b>4,31</b>

Çizelge 4.6 önerilen yöntemin farklı tarihler için bolluk değeri sonuçlarını göstermektedir. 25 Haziran ve 12 Ağustos görüntülerinden rastgele seçilen bir örnek piksel için kestirilmiş bolluk değerleri gösterilmektedir. Modelde beklenen bazı durumlar çizelgede görülebilmektedir. 12 Ağustos görüntüsünde pikseldeki yaprak sıklığı daha fazla olmasından dolayı yapraktan doğrudan yansımaya teriminin bolluk değeri 25 Hazirana göre daha fazladır. Yine toprak alan daha az olduğundan topraktan doğrudan yansımaya oranı çok daha düşüktür. 25 Haziranda yaprak iletim-yaprak yansımaya ve yaprak iletim-toprak yansımaya terimlerinin bolluk değeri yüksek çıkmaktadır. 12 Ağustosta ise yapraklar o kadar sıktır ki yapraktan iletilen ve yaprağın altına geçen ışık toprağa veya alttaki yaprağa çarptıktan sonra sensöre ulaşmadan birçok yansımaya veya iletim daha yapmaktadır. Bu nedenle yaprak iletim-yaprak yansımaya veya yaprak iletim-toprak yansımaya ikili etkileşimlerinin bolluk değerleri sıfıra yakınsamaktadır. Bir başka

çarpıcı sonuç ise yaprak yansıma-yaprak yansıma (öz etkileşim) teriminin 12 Ağustosta çok büyük oranla karışımı domine etmesidir. Fiziksel olarak düşünüldüğünde oldukça doğru bir sonuç elde edilmiştir. Çünkü yaprakların sık oluşu ve birbirine yakınlaşması, güneşten gelen ışığın yapraktan yansıdıktan sonra bir başka yapraktan tekrar yansiyıp sensöre ulaşma ihtimalini oldukça artırmaktadır.

Çizelge 4.6 Farklı pikseller için hesaplanan bolluk değer haritaları

Bilineer Terimler	Önerilen Yöntem	
	25 Haziran	12 Ağustos
Yapraktan tek yansıma	0,156	0,3469
Topraktan tek yansıma	0,309	0,0121
Yapraktan yansıma sonrası topraktan yansıma	0	0
Yapraktan iletim sonrası topraktan yansıma	0,251	0
Yaprak iletim sonrası yapraktan yansıma	0,2836	0
Yapraktan yansıma sonrası yapraktan yansıma	0	0,6410
Topraktan yansıma sonrası topraktan yansıma	0	0


Çizelge 4.7 tüm spektrum, tüm spektrum üzerinde gürültülü bant eleme ve tüm spektrum üzerinde gürültülü bant elemeye birlikte bant seçiminin uygulanma durumları için elde edilen piksel yüzde kestirim hatalarını göstermektedir. Gürültülü bantların spektrumdan çıkarılmasının kestirim hatasını azalttığı görülmektedir. Bununla birlikte, bant seçiminde kullanılan BAO\_Max yöntemi kestirim hatasını neredeyse sıfıra kadar indirebilmektedir. Bant seçimi işlemi tez çalışmasında karşılaştırılması yapılan diğer bilinear yöntemlerin kestirim sonucuna ise ancak %50 civarında bir iyileştirme yapabilmıştır. Bu durum, önerilen spektral ayrıştırma yönteminin başarısı ve doğruluğu hakkında önemli bir bilgi daha vermektedir.

Çizelge 4.7 Bant seçiminin ortalama kestirim hatasına etkisi

Görüntü Tarihleri	Ortalama Kestirim Hatası (%)		
	Tüm spektrum	Tüm spektrum üzerinde gürültülü bant eleme	Gürültülü bant eleme ve BAO_Max bant seçimi
11 Haziran	6.13	6.04	9.67x10e-15
25 Haziran	5.04	3.89	1.35x10e-4
12 Ağustos	16.62	13.61	2.4810e-14

Tez çalışmasında, önerilen yöntem, mısır ve pamuk tarlalarının hiperspektral görüntülerinde, arazi sınıflandırması için uygulanmıştır. Sınıflandırmada belirleyici unsur, her bitki çeşidinin büyüme yapısına göre farklı şekilde yansıma ve iletim etkileşimleri üreteceğidir. Yani görüntü pikselinde aynı NDVI değeri üretseler bile farklı bitkiler, farklı yapıda spektral karışım üreteceklerdir. Bu durumda spektral karışımın ve bolluk değer değişiminin bitki çeşidine göre bir karakteristiği olacaktır. Dolayısıyla pikselin spektral ayrıştırılması ve yeniden oluşturulmasında bitki çeşidinin farklılığı kestirim hatasını değiştirecektir. Pikselde bulunan bitki çeşidi imzası ile yapılan spektral ayrıştırmada kestirim hatası, bir başka bitki imzası ile yapılan ayrıştırmaya göre daha düşük çıkacaktır. Önerilen yöntemle yapılan sınıflandırmaya ait akış şeması şekil 3.21’de verildiği gibidir. Hiperspektral görüntüleme ile elde edilmiş olan pamuk ve mısır tarlalarının görüntüleri için, önerilen yöntem, pamuk ve mısır spektral imzaları için ayrı ayrı çalıştırılmıştır ve ilgili piksel için ortalama kestirim hataları hesaplanmıştır. İlgili piksel için hangi hata değeri daha küçük ise, piksel o sınıfa atanmıştır. Bu algoritma, Haziran ayında alınan mısır ve pamuk tarla görüntüleri üzerinde uygulanmıştır. Bu tarihte her iki bitki de oldukça küçük ve görüntü pikselinde alt piksele düşmektedirler. Dolayısıyla geleneksel sınıflandırma yöntemleri spektral benzerlik gösteren bitki türlerinde veya spektral karışım nedeniyle benzer piksel spektrumu oluşan durumlarda büyük oranlarda yanlış alarm üretebilmektedirler. Pamuk ve mısır bitkilerinin yapraklarından elde edilmiş yansıma spektrumları şekil 4.10’da gösterilmiştir. Spektrumlar arasındaki korelasyon katsayısı değeri 0,99 ve SAU değeri 5,64° olarak hesaplanmıştır. Korelasyon katsayısının 1 değerine yakınlığı ve SAU


benzerlik deęerinin dūşüklüęü mısır ve pamuk spektralarının yüksek oranda benzeřtiklerini göstermektedir.



Şekil 4.10 Pamuk ve mısır yapraęı spektral imzaları


Aynı görüntülerde sınıflandırmada karşılaştırma yapmak amacıyla SAM (Spectral Angle Mapper) ve MF (Matched Filter) sınıflandırma yöntemleri de uygulanmıştır. Önerilen yöntem sonucu, SAM ve MF sonuçları ile karşılaştırılmıştır. Şekil 4.11 ve 4.12’de sonuçlar verilmiştir. Sınıflandırma sonuçlarında pamuk ve mısır tarlaları için yöntemlerin bulmuş olduęu mısır oranı sonucu yazılmıştır. Örneęin MF algoritması 11 Haziran pamuk görüntüsünde %49 oranında mısır, %51 oranında pamuk bulurken, SAM %96 oranında mısır, %4 oranında mısır bulmuştur. Önerilen yöntem ise %95.58 oranında pamuk bulmuş ve %4.42 oranında bir yanlış alarm ile mısır tespit etmiştir. Aynı şekilde 25 Haziran mısır görüntüsünde MF %49.54, SAM %97.01 oranlarında mısır bulurlarken, Önerilen yöntem %99.79 oranında mısır bulmuştur.

Şekil 4.11-4.12’de verilen sınıflandırma sonuçları, bitki türünün alt piksele düřtüęü erken dönemlerinde bilineer spektral ayrıştırmaya dayanan (önerilen) yöntemin kullanılmasının gereklilięini, avantajını ve başarısını gözler önüne sermektedir.



Şekil 4.11 Pamuk görüntüsü sınıflandırma sonuçları.

a. 11 Haziran görüntüsü MF sonucu (%49.63), b. 11 Haziran görüntüsü SAM sonucu (%96.59), c. 11 Haziran görüntüsü önerilen yöntem sonucu (%4.42), d. 25 Haziran görüntüsü MF sonucu (%47.94), e. 25 Haziran görüntüsü SAM sonucu (%53.03), f. 25 Haziran görüntüsü önerilen yöntem sonucu (%0.23)



Şekil 4.12 Mısır görüntüsü sınıflandırma sonuçları.

a. 11 Haziran görüntüsü MF sonucu (%43.33), b. 11 Haziran görüntüsü SAM sonucu (%78.32), c. 11 Haziran görüntüsü önerilen yöntem sonucu (%90.12), d. 25 Haziran görüntüsü MF sonucu (%49.54), e. 25 Haziran görüntüsü SAM sonucu (%97.01), f. 25 Haziran görüntüsü önerilen yöntem sonucu (%99.79)

## 5. TARTIŞMA VE SONUÇ

Hiperspektral görüntüleme ve analiz, 1980’li yıllardan itibaren gittikçe gelişen bir teknoloji alanı haline gelmiştir. Zaman içerisinde hiperspektral görüntüleme aygıtlarının sayısı, hassasiyeti ve kabiliyeti sürekli artmıştır. Günümüzde artık her türlü platforma rahatça takılabilecek kadar küçük ve hafif kameralar üretilmektedir. Gözle veya geleneksel görüntüleme aygıtlarıyla elde edilemeyen ayrıntıda verilerin, hiperspektral görüntüleme teknolojisiyle birlikte yakalanması mümkün hale gelmiştir. Görünür ve kızıl berisi, orta kızıl berisi, uzak kızıl berisi dalga boylarında çalışabilen hiperspektral kameralar piyasada bulunmaktadır. Sensör teknolojisindeki bu gelişmeyle birlikte, elde edilen verilerin spektral çözünürlükleri de artmıştır. Birbirine çok yakın ve dar bant aralıklarıyla görüntü alabilmek mümkündür.

Hiperspektral görüntünün spektral bilgisi oldukça zenginleştirilmesine rağmen, uzamsal çözünürlük, kamera sensörlerinin çokluğu ve kalitesi ile beraber kameranın görüntüleme yapmak için monte edildiği platformun görüntülenen yüzeyden uzaklığına ve sensörün bakış alanı açısına bağlıdır. Genel anlamda bakıldığında, hiperspektral sensörlerin uzamsal çözünürlükleri çok iyi seviyede değildir. Bu durum, görüntülenen alandaki hedef materyallerin çoğunlukla alt piksele düşmesine neden olmaktadır. Elde edilen hiperspektral görüntünün her bir pikseli fiziksel olarak birden fazla materyalden oluşmaktadır. Bu maddelerden yansıyan ışık, sensördeki pikselde bir spektral karışım meydana getirmektedir. Spektral karşılaştırma, hedef tespiti, sınıflama ve diğer spektral incelemelerde, pikseldeki bu karışımın çözülmesi ve piksel içerisinde bulunan veya bulunması muhtemel olan materyallerin bolluk değerlerinin hesaplanması gerekmektedir.

Spektral ayrıştırma anlamında en basit ve ilkel model doğrusal modeldir. Doğrusal modelde, ışığın her bir materyalden tek yansıma yaparak sensöre ulaştığı düşünülmektedir. Gerçek dünyadaki durum ise bu kadar basit değildir. Işık sensöre ulaşmadan önce pikselin karşılık geldiği fiziksel alan içerisinde birçok sayıda yansıma yapmaktadır. Bu nedenle doğrusal model çözümünde piksel kestirim hatası genel olarak yüksek çıkmaktadır. Bu durum araştırmacıları doğrusal olmayan modellere yöneltmiştir.

Doğrusal olmayan modellerden birisi piksel içerisindeki karışımın homojen olduğu kabulüdür. Yani ışık küçük boyutlarda birçok yansıma yaptıktan sonra sensöre ulaşmaktadır. Bu kadar fazla yansıma durumunda, karışım probleminin çözümü oldukça zorlaşmaktadır. Genellikle bu modellemede Hapke modeli temel alınarak çalışmalarda uygulanmıştır. Bunun dışında yine destek vektör makineleri, çekirdek metotları, sinir ağları gibi birçok yöntem kullanılmıştır.

Homojen karışımındaki çözümün zor olması ve hesap yükünün fazla olmasından dolayı, araştırmacılar yansıma sayısını en fazla ikiye indirerek yeni bir model kullanmışlardır. Bu model bilineer modeldir. Bu modeldeki en çok iki yansıma sayısının kabulü, mantıksal olarak çoğu durumda doğru sayılabilir. Çünkü yansıma değerleri (0,1) aralığında olduğundan, bu değerlerin ikiden fazla çarpımı, sonucu sifıra yaklaştırmakta ve spektral karışımındaki etki miktarının azalmasına neden olmaktadır. Araştırmacılar bu yüzden ikiden fazla yansıma durumunun düşünülmesinin pek gerekli olmadığını düşünmüşlerdir.

Yapılan çalışmalar incelendiğinde, her modellemenin başarılı sonuç ürettiği bir veri dizisi bulmak mümkündür. Tez çalışmasında ise şu ana kadar yapılan çalışmalarda yapılan bazı kabullerin doğru olmadığı vurgulanmakta ve ortaya bir teori konulmaktadır. Literatürde bilineer ve diğer modellerde çok büyük oranda sadece yansıma etkileşiminin dikkate alınması, etkileşim terimlerine eşit ağırlık değeri verilmesi, bolluk değeri toplamının 1'e eşitlenme durumunun sadece doğrusal etkileşim için düşünülmesi, son öğelerin fiziksel varlığı oranında spektral karışıma etki ettiğinin kabul edilmesi, etkileşim spektrumlarının bolluk değerlerinin fiziksel varlık oranına göre ayarlanması, görüntüden piksel seçilerek bu pikselin son öğe spektrumu olarak düşünülerek spektral ayrıştırmada kullanılması gibi durumlar eleştirilmiştir.

Fiziksel anlamda, spektral karışım meydana gelirken, pikseldeki materyaller arasında sadece yansıma etkileşimi meydana gelmez. Bununla birlikte, iletim ve soğurma spektrumları da spektral karışımında çok önemli belirleyici faktörler olarak karşımıza çıkmaktadır. Tezde önerilen model, bilineer modelleme temelinde bütün ikili etkileşimleri dikkate almakta ve karışımı buna göre modellemektedir. Bitki örtüsü

sahnelerinde, bitki gelişimiyle birlikte, spektral karışımdaki son öğelerin ve etkileşim spektrumlarının bolluk değerleri de değişmektedir. Örneğin yapraktan doğrudan yansıma ve/veya yapraktan yansıdıktan sonra başka bir yapraktan yansıma oranlarının spektral karışımdaki değerlerinin fazla olması, bitkinin gelişmiş ve büyümüş olduğunu, piksel içinde fazlaca yer kapladığını göstermektedir. Aynı zamanda her bitki çeşidinin bolluk değer değişimi kendine has bir özellik taşımaktadır. Örneğin aynı değerde NDVI üreten mısır ve pamuk görüntü pikseli ayrıştırıldığında, bilineer modeldeki her terimin bolluk değeri bitki çeşidine göre farklılık gösterebilmektedir.

Tezde önerilen yöntem mevcutta literatürdeki doğrusal ve en önemli bilineer modeller ile kestirim hatası bakımından karşılaştırılmıştır. Yöntemin doğrusal modele ve önemli bilineer modellere kestirim hatası anlamında üstünlük sağladığı görülmüştür. Ayrıca önerilen yöntemle bitki örtüsü sınıflaması yapılmıştır. Görüntüde alt piksele düşülen ve spektral karışma oranının çok yüksek olduğu durumlarda oldukça iyi sınıflandırma sonuçları elde edilmiştir.

Geliştirilen yöntemin, gelecekte spektral ayrıştırma konusunda yapılacak çalışmalarda farklı bir pencere açacağı, çalışmalara önemli bir referans kaynağı olacağı değerlendirilmektedir.

## KAYNAKLAR

- Adams, J.B., Sabol, D.E., Kapos, V., Almeida, R., Roberts, D.A., Smith, M.O. and Gillespie, A.R. 1995. Classification of multispectral images based on fractions of endmembers application to land-cover change in the Brazilian amazon. *Remote Sensing of Environment*, 52, 137-154.
- Almog, O., Shoshany, M. and Alchanatis, V. 2007. Improving Hyperspectral Classification based on Wavelet Decomposition. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol 37, 443-446
- Altmann, Y., Halimi, A., Dobigeon, N. and Tourneret, J. 2012. Supervised nonlinear spectral unmixing using a postnonlinear mixing model for hyperspectral imagery. *IEEE Transactions on Image Processing*. 21(6), 3017-3025
- Anonim. 2012. Web Sitesi: <https://www.hvkk.tsk.tr>, Erişim Tarihi: 20.05.2018.
- Anonim. 2016. Web Sitesi: [http://www.cartospace.com.tr/?page\\_id=20](http://www.cartospace.com.tr/?page_id=20), Erişim Tarihi: 22.05.2018.
- Anonymous. 2010. Web Sitesi: [https://belspo.be/organisation/Publ/pub\\_ostc/Th\\_en.pdf](https://belspo.be/organisation/Publ/pub_ostc/Th_en.pdf), Erişim Tarihi: 22.05.2018.
- Anonymous. 2013. Web Sitesi: <https://www.spar3d.com/news/lidar/oil-gas-industry-asks-airborne-remote-sensor-makers-for-help/>, Erişim Tarihi: 21.05.2018.
- Anonymous. 2014. Web Sitesi: <http://rs.geo.tuwien.ac.at/>, Erişim Tarihi: 23.05.2018.
- Anonymous. 2015. Web Sitesi: <https://eros.usgs.gov/doi-remote-sensing-activities/2015/innovation-near-surface-remote-sensing-vegetation-growth-dynamics>, Erişim Tarihi: 22.05.2018.
- Anonymous. 2017. Web Sitesi: <https://www.slideshare.net/OpenMapsLimited/landsat-3385760>, Erişim Tarihi: 22.05.2018.
- Atkinson, P., Cutler, M. and Lewis, H., 1997. Mapping sub-pixel proportional land cover with AVHRR imagery. *International Journal of Remote Sensing*. 18(4), 917-935.
- Atkinson, P.M. and Lewis, P. 2000. Geostatistical classification for remote sensing: an introduction. *Computers & Geosciences*. 26, 361-371.
- Blanzieri, E., Melgani, F. 2008. Nearest neighbor classification of remote sensing images with the maximal margin principle. *IEEE Transactions on Geoscience and Remote Sensing*, 46, 1804-1811.
- Borel, C., and Gerstl, S. 1994. Nonlinear spectral mixing models for vegetative and soil surfaces, In *Journal of Remote Sensing of Environment*, 47(3), 403-416.
- Chen, X., Chen, J., Jia, X. and Wu, J. 2010. Impact of collinearity on linear and nonlinear spectral mixture analysis. *IEEE Workshop on Hyperspectral Image*

- Signal Processing: Evolution on Remote Sensing (WHISPERS). 1-4, Reykjavik, Iceland.
- Chen, X., Chen, J., Jia, X., Somers, B., Wu, J. and Coppin, P. 2011. A quantitative analysis of virtual endmembers' increased impact on the collinearity effect in spectral Unmixing. *IEEE Transaction on Geoscience and Remote Sensing*. 49(8), 2945- 2956.
- Çımtay, Y. ve İlk, H. G. 2017. A Novel Derivative-Based Classification Method for Hyperspectral Data Processing. In *Journal of Advances in Electrical and Electronic Engineering*, 15(4), 657-662.
- Deer, P.J. and Eklund, P. 2003. A Study of Parameter Values for a Mahalanobis Distance Fuzzy Classifier. *Fuzzy Sets and Systems*. 137, 191-213.
- Dhodhi, M.K., Saghri, J.A., Ahmad, I. and Mustafa, R. 1999 D-ISODATA: A Distributed Algorithm for Unsupervised Classification of Remotely Sensed Data on Network of Workstations. *Journal of Parallel and Distributed Computing*, 59, 280-301.
- Dobigeon, N., Tournet, J., Richard, C., Bermudez, J.C., McLaughlin, S. and Alfred, O. 2013. Nonlinear Unmixing of Hyperspectral Images: Models and Algorithms, *Laboratoire de Physique des Solides, CNRS, Univ. Paris-Sud, Univ. Paris-Saclay, Orsay Cedex, France*.
- Dwivedi, R.S., Kandrika, S. and Ramana, K.V. 2004. Comparison of Classifiers of Remote-Sensing Data for Land-Use/Land-Cover Mapping. *Current Science*. 86, 328-335.
- Fan, W., Hu, B. and Miller, J. 2009. Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data. *International Journal of Remote Sensing*, 30(11), 2951-2962.
- Foody, G.M. 1999. The Continuum of Classification Fuzziness in Thematic Mapping. *Photogrammetric Engineering and Remote Sensing*, 65, 443-451.
- Fisher, P. 1997. The Pixel: A Snare and a Delusion. *International Journal of Remote Sensing*, 18, 679-685.
- Foody, G.M. and Cox D.P. 1994. Sub-pixel Land Cover Composition Estimation Using a Linear Mixture Model and Fuzzy Membership Functions. *International Journal of Remote Sensing*. 15, 619-631.
- Foody, G. 1996. Relating the land-cover composition of mixed pixels to artificial neural network classification output. *Photogrammetric Engineering and Remote Sensing*. 62(5), 491-499
- Friedl, M.A. and Brodley, C.E. 1997. Decision Tree Classification of Land Cover from Remotely Sensed Data. *Remote Sensing of Environment*. 61, 399-409.
- Gislason, P.O., Benediktsson, J.A. and Sveinsson J.R. 2006. Random Forests for Land Cover Classification. *Pattern Recognition Letters*. 27, 294-300.

- Gonçalves, M.L., Netto, M.L.A., Costa J.A.F. and Zullo Júnior J. 2008. An Unsupervised Method of Classifying Remotely Sensed Images using Kohonen Self organizing Maps and Agglomerative Hierarchical Clustering Methods. *International Journal of Remote Sensing*, 29, 3171-3207.
- Gualtieri, J.A. and Crompton, R.F. 1999. Support Vector Machines for Hyperspectral Remote Sensing Classification, In *The 27th AIPR Workshop: Advances in Computer-Assisted Recognition*. International Society for Optics and Photonics. 35(84), 221-232.
- Halimi, A., Altmann, Y., Dobigeon, N. and Tourneret, J., 2011. Nonlinear Unmixing of Hyperspectral Images Using a Generalized Bilinear Model. *IEEE Transactions on Geoscience and Remote Sensing*. 49(11), 4153-4162.
- Hapke, B. 1993. *Theory of Reflectance and Emittance Spectroscopy*. Cambridge Univ. Press, 513, Cambridge.
- Heylen, R., Parente, M. and Gader, P. 2014. A Review of Nonlinear Hyperspectral Unmixing Methods. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 1844-1868
- Homer, C., Dewitz J., Fry J., Coan, M., Hossain, N., Larson, C., Herold, N., McKerrow, A., VanDriel, J.N. and Wickham, J. 2007. Completion of the 2001 National Land Cover Database for the Conterminous United States. *Journal of Photogrammetric Engineering and Remote Sensing*, 73, 337-341.
- Hsu, P., and Yang, H. 2007. Hyperspectral Image Classification Using Wavelet Networks. *IEEE International Geoscience and Remote Sensing Symposium, IGARSS*. 1767-1770, Barcelona, Spain.
- Huang C., Davis L.S. and Townshend J.R.G. 2002. An Assessment of Support Vector Machines for Land Cover Classification. *International Journal of Remote Sensing*. 23, 725-749.
- Huete, A., Jackson, R. and Post, D. 1985. Spectral response of a plant canopy with different soil backgrounds. *Journal of Remote Sensing of Environment*. 17(1), 37-53
- Ishibuchi, H., Nozaki, K., Yamamoto, N. and Tanaka, H. 1994. Construction of Fuzzy Classification Systems with Rectangular Fuzzy Rules using Genetic Algorithms. *Fuzzy Sets and Systems*. 65, 237-253.
- Jensen, J.R. 2009. *Remote Sensing of the Environment: An Earth Resource Perspective 2/e*. Pearson Education, India.
- Jiang H., Zhao, D., Cai, Y. and An, S. 2012. A Method for Application of Classification Tree Models to Map Aquatic Vegetation using Remotely Sensed Images from Different Sensors and Dates. *Sensors*. 12, 12437-12454.
- Kavzoğlu, T. 2016. Uzaktan algılama teknolojisi notları, Gebze Yüksek Teknoloji Enstitüsü, Gebze, Kocaeli.

- Kavzoglu, T. and Mather, P.M. 2003. The Use of Backpropagating Artificial Neural Networks in Land Cover Classification. *International Journal of Remote Sensing*. 24, 4907-4938.
- Kulkarni, A.D. and Kamlesh, L. 1999. Fuzzy Neural Network Models for Supervised Classification: Multispectral Image Analysis. *Geocarto International*. 4, 42-51.
- Li, J. 2004. Wavelet-Based Feature Extraction for Improved Endmember Abundance Estimation in Linear Unmixing of Hyperspectral Signals. *IEEE International Geoscience and Remote Sensing Symposium*, Vol 42, 644-649, Anchorage, AK, USA.
- Li, J., Li, X., Huang, B. and Zhao, L. 2016. Hopfield Neural Network Approach for Supervised Nonlinear Spectral Unmixing, *IEEE Geoscience and Remote Sensing Letters*, 13(7), 3340-3350.
- Li, Y. 2002. Linear Unmixing of Hyperspectral Signals via Wavelet Feature Extraction. *Doktora Tezi*, Mississippi State University, Electrical and Computer Engineering, 167, Mississippi.
- Licciardi, G. and Frate, F. 2010. A Neural Network Approach For Pixel Unmixing In Hyperspectral Data. *IEEE 2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Reykjavik, Iceland.
- Licciardi, G. and Frate, F. 2011. Pixel Unmixing in Hyperspectral Data by Means of Neural Networks. *IEEE Transactions On Geoscience And Remote Sensing*. 49(11), 4163-4172.
- Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. 2004. *Remote Sensing and Image Interpretation*. Ed. 5. John Wiley & Sons Ltd.
- Lu, D. and Weng, Q. 2007. Survey of Image Classification Methods and Techniques for Improving Classification Performance. *International Journal of Remote Sensing*, 28, 823-870.
- Lvovsky, A.I. 2013. *Fresnel Equations*. Department of Physics and Astronomy. Taylor and Francis: Newyork, Published Online.
- Mannan, B. and Ray, A.K. 2003. Crisp and Fuzzy Competitive Learning Networks for Supervised Classification of Multispectral IRS Scenes. *International Journal of Remote Sensing*. 24, 3491-3502.
- Marcelo, J.S. and Paulo, C. 2013. Laws of reflection and Snell's Law revisited by Video Modeling. *12th Education and Training in Optics and Photonics Conference*. Vol:92(89).
- Marconcini, M., Camps-Valls, G. and Bruzzone, L. 2009. A Composite Semisupervised SVM for Classification of Hyperspectral Images. *IEEE Geoscience and Remote Sensing Letters*. 6, 234-238.
- McIver, D.K. and Friedl, M.A. 2002. Using Prior Probabilities in Decision-tree Classification of Remotely Sensed Data. *Remote Sensing of Environment*. 81, 253-261.

- Mitraka, Z., Frate, F. and Carbobe, F. 2015. Spectral unmixing of urban Landsat imagery by means of neural Networks. Joint Urban Remote Sensing Event, JURSE.
- Mitraka, Z., Frate, F. and Carbobe, F. 2016. Nonlinear Spectral Unmixing of Landsat Imagery for Urban Surface Cover Mapping, *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(9), 3340-3350.
- Meganem, I., Deliot, P., Briottet, X., Deville, Y. and Hosseini, S. 2014. Linear-quadratic mixing model for reflectances in urban environments. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1), 544-558.
- Musaoğlu, N. 2014. Uzaktan Algılama Eğitim notları, İTÜ İnşaat Fakültesi, 77s, İstanbul.
- Nascimento, J. and Bioucas-Dias, J. 2009. Nonlinear mixture model for hyperspectral Unmixing. *Proc. Soc. Photo-Opt. Instrum. Eng. (SPIE), Image Signal Process. Remote Sensing. Vol 15, 7477*
- Nguyen, V. and Hakil, K. 2009. Noisy Band Removal Using Band Correlation in Hyperspectral Images. In *Korean Journal of Remote Sensing*, 25, 263-270.
- Pal, M. and Mather, P.M. 2005. Support Vector Machines for Classification in Remote Sensing. *International Journal of Remote Sensing*. 26, 1007-1011.
- Perakis, K., Kyrimis, K. and Kungolos, A. 2000. Monitoring Land Cover Change Detection with Remote Sensing Methods in Magnesia Prefecture in Greece. *Fresenius Environmental Bulletin*. 9, 659-666.
- Plaza, A., Plaza, R. and Martinez, P. 2008. Joint linear/nonlinear spectral unmixing of hyperspectral image data. *IEEE International Geoscience Remote Sensing Symposium. (IGARSS)*. 4037–4040, Barcelona, Spain.
- Puletti, N., Perria, R. and Storchi, P. 2014. Unsupervised classification of very high remotely sensed images for grapevine rows detection. *European Journal of Remote Sensing*, 47, 45-54.
- Ray, T. and Murray, B. 1996. Nonlinear spectral mixing in desert vegetation. *Journal of Remote Sensing of Environment*. 55(1), 59–64
- Roberts, D., Smith, M. and Adams, J. 1993. Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. In *Journal of Remote Sensing of Environment*, 44(2-3), 255-269.
- Roberts, D.A., Gardner, M., Church, R., Ustin, S., Scheer, G. and Green, R.O. 1998. Mapping Chaparral in the Santa Monica Mountains using Multiple Endmember Spectral Mixture Models. *Remote Sensing of Environment*. 65, 267-279.
- Rollet, R., Benie, G.B., Li, W., Wang, S. and Boucher, J.M. 1998. Image Classification Algorithm based on the RBF Neural Network and K-means. *International Journal of Remote Sensing*, 19, 3003-3009.

- Settle, J.J. and Briggs, S.A. 1987. Fast Maximum-likelihood Classification of Remotely Sensed Imagery. *International Journal of Remote Sensing*. 8, 723-734.
- Shalaby, A. and Tateishi, R. 2007. Remote Sensing and GIS for Mapping and Monitoring Land Cover and Land-use Changes in the Northwestern Coastal Zone of Egypt. *Applied Geography*. 27, 28-41.
- Shanmugam, P., Ahn, Y.H. and Sanjeevi, S. 2006. A Comparison of the Classification of Wetland Characteristics by Linear Spectral Mixture Modelling and Traditional Hard Classifiers on Multispectral Remotely Sensed Imagery in Southern India. *Ecological Modelling*. 194, 379-394.
- Stefan, A. 2010. Band reduction for hyperspectral imagery processing. In Proc. SPIE 7533 Computational Imaging VIII, Vol 7533, San Jose, California.
- Sun, W., Jiang, M., Li, W. and Liu, Y. 2016. A Symmetric Sparse Representation Based Band Selection Method for Hyperspectral Imagery Classification. In *Journal of Remote Sensing*. 8(3), 238-254.
- Tseng, M.H., Chen, S.J., Hwang, G.H. and Shen, M.Y. 2008. A Genetic Algorithm Rule-based Approach for Land-cover Classification. *ISPRS Journal of Photogrammetry and Remote Sensing*. 63, 202-212.
- Woodcock, C.E. and Gopal, S. 2000. Fuzzy Set Theory and Thematic Maps: Accuracy Assessment and Area Estimation. *International Journal of Geographical Information Science*. 14, 153-172.
- Wu, C. and Murray, A.T. 2003. Estimating Impervious Surface Distribution by Spectral Mixture Analysis. *Remote Sensing of Environment*. 84, 493-505.
- Wu, C. 2004. Normalized Spectral Mixture Analysis for Monitoring Urban Composition using ETM+ Imagery. *Remote Sensing of Environment*. 93, 480-492.
- Xian, G. and Crane, M. 2005. Assessments of Urban Growth in the Tampa Bay Watershed using Remote Sensing Data. *Remote Sensing of Environment*. 97, 203-215.
- Xu, M., Watanachaturaporn, P., Varshney, P. and Arora, M. 2005. Decision Tree Regression for Soft Classification of Remote Sensing Data. *Remote Sensing of Environment*, 97, 322-336.
- Yang, X. and Liu, Z. 2005. Use of Satellite-derived Landscape Imperviousness Index to Characterize Urban Spatial Growth. *Computers, Environment, and Urban Systems*. 29, 524-540
- Yuan, F., Sawaya, K.E., Loeffelholz, B.C. and Bauer, M.E. 2005. Land Cover Classification and Change Analysis of the Twin Cities (Minnesota) Metropolitan Area by Multitemporal Landsat Remote Sensing. *Remote Sensing of Environment*. 98, 317-328.
- Zhang, J. and Foody, G.M. 1998. A Fuzzy Classification of Sub-urban Land Cover from Remotely Sensed Imagery. *International Journal of Remote Sensing*. 19, 2721-2738.

Zhang, L., Li, D., Tong, Q. and Zheng, L. 1998. Study of the spectral mixture model of soil and vegetation in PoYang Lake area, China. *International Journal of Remote Sensing*, 19(11), 2077-2084.


Zhu, H.W. and Basir O. 2005. An Adaptive Fuzzy Evidential Nearest Neighbor Formulation for Classifying Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*. 43, 1874-1889.



## EK 1: Kullanıcı Ara Yüzü Uygulaması

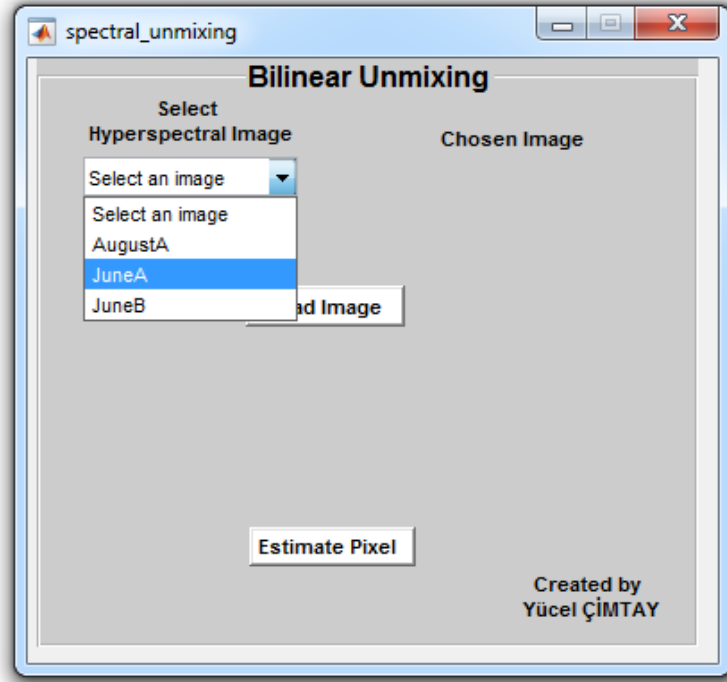
Tezde gerçekleştirilen çalışmalarda MATLAB programı ve kütüphaneleri kullanılmıştır. Görüntü pikselinin tüm spektrumda spektral ayrıştırmaya tabi tutulması ve yeniden oluşturulmasına yönelik, bir kullanıcı ara yüzü geliştirilmiştir. Kullanıcı ara yüzü şu şekilde çalışmaktadır:

- I. Kullanıcı ara yüzü uygulaması çalıştırılmakta ve “Başlangıç ekranı” (Şekil 1) açılmaktadır.



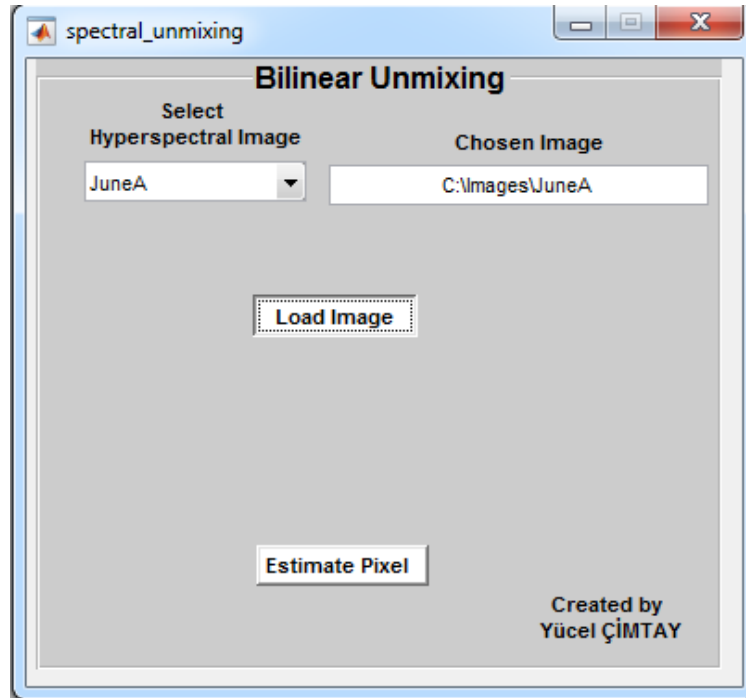
Şekil 1 Başlangıç ekranı

- II. Açılır menüden hiperspektral görüntü ismi seçilir (Şekil 2)



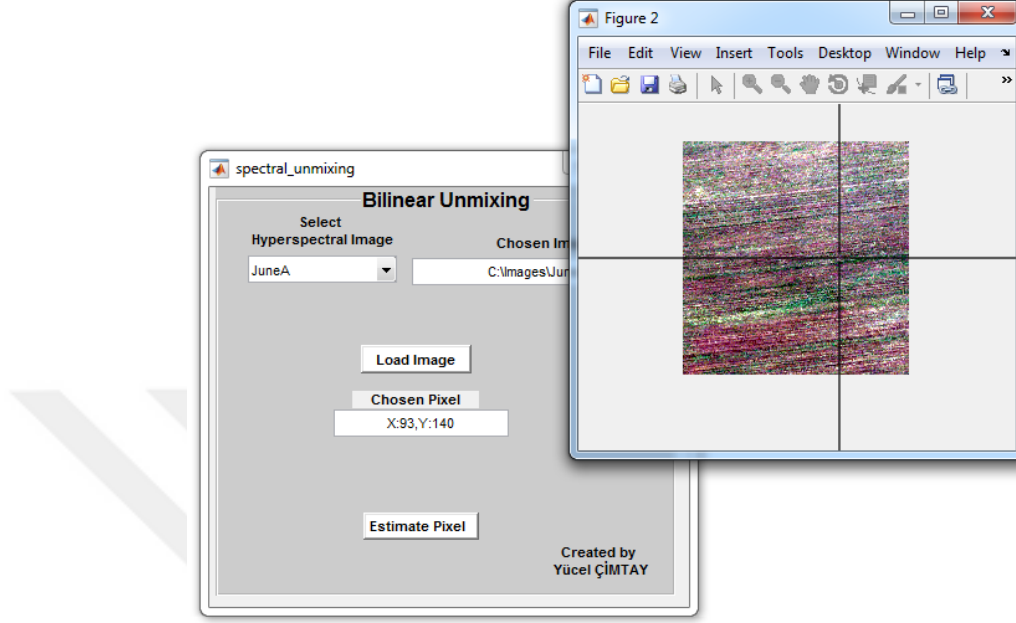
Şekil 2 Görüntü seçim ekranı

III. “Load Image” butonuna basılır (Şekil 3)




Şekil 3 Görüntü açma komut ekranı

- IV. Seçilen görüntünün ekranda açıldığı gözlenir ve ekranda beliren piksel seçim aracıyla analiz edilmek istenen piksel seçilir (Şekil 4)




Şekil 4 Piksel seçim ekranı

- V. Piksel seçildikten sonra "Estimate pixel" butonuna basılır (Şekil 5)

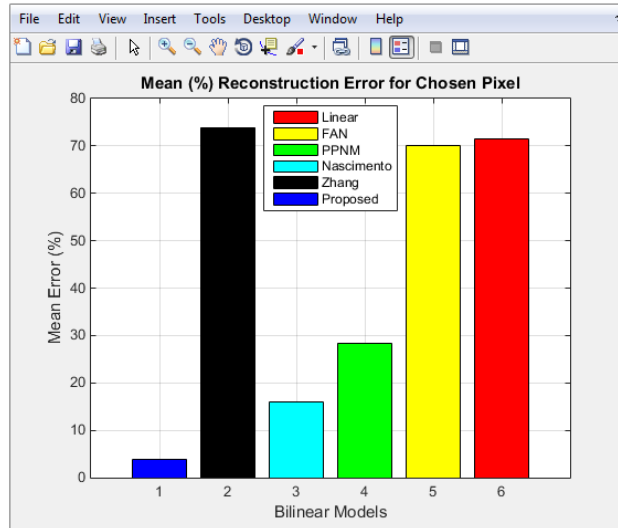


Şekil 5 Piksel kestirim komut ekranı

Piksel kestirim algoritması arka tarafta çalışarak sonuçları hesaplamaktadır. Hesaplanan sonuçlar şekiller (grafikler) halinde gösterilmektedir. Şekil 6 seçilen piksel için, önerilen yöntemin doğrusal yöntem ve önemli bilinear yöntemlerle kestirim spektrumu olarak karşılaştırılmasını göstermektedir. Şekil 7 ise seçilen piksel için yöntemlerin kestirim yüzde hatasını göstermektedir.



Şekil 6 Piksel kestirim sonuç spektrumu



Şekil 7 Ortalama yüzde kestirim hataları

## ÖZGEÇMİŞ

Adı Soyadı :Yücel ÇİMTAY

Doğum Yeri :Elazığ

Doğum Tarihi :07.02.1984

Medeni Hali :Evli

Yabancı Dili :İngilizce

### **Eğitim Durumu (Kurum ve Yıl)**

Lise : Elazığ Kaya Karakaya Fen Lisesi (2002)

Lisans : İ.D. Bilkent Üniversitesi, Mühendislik Fakültesi  
Elektrik-Elektronik Mühendisliği Bölümü (2008)

Yüksek Lisans: Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı(2012)

Doktora : Ankara Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı (Şubat 2013-Temmuz  
2018)

### **Çalıştığı Kurum/Kurumlar ve Yıl**

Adalet Bakanlığı Bilgi İşlem Daire Başkanlığı (2008-2012)

Havelsan (2013-)

### **Hakemli Dergiler**

Cimtay, Y., İlk, H. G. (2018). A Novel Bilinear Unmixing Approach for Reconsideration of Subpixel Classification of Land Cover. Computers and Electronics in Agriculture. (SCI-Expanded)

Çimtay, Yucel ve Gokhan İlk, Hakki. (2017). A Novel Derivative-Based Classification Method for Hyperspectral Data Processing. Advances in Electrical and Electronic Engineering. 15. . 10.15598/aeee.v15i4.2381. (E-SCI)

### **Uluslararası Konferanslar**

Çimtay Y. ve Seke E. (2012). Frame Rate Up-Conversion With Nonlinear Temporal Interpolation”, 5th International Congress on Image and Signal Processing

### **Ulusal Konferanslar**

Çimtay Y., Esin Y.E, İlk H.G. (2017). A new derivative-based approach for hyperspectral classification. 25th Signal Processing and Communications Applications Conference (SIU)

Bozbay B., Çimtay Y., Kandaz F. (2017). Calculation of vegetation index for short wave infrared hyperspectral images. 25th Signal Processing and Communications Applications Conference (SIU)

Karakaya İ. ve Çimtay Y. (2017). The effect of band selection to success of artificial neural network in hyperspectral classification. 25th Signal Processing and Communications Applications Conference (SIU)

Çimtay Y. ve Seke E.(2012). Temporal video interpolation with nonlinear motion estimation. 20th Signal Processing and Communications Applications Conference (SIU)