

KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ

SÜPER-ÇÖZÜNÜRLÜK YÖNTEMLERİNİN HİPERSPEKTRAL  
GÖRÜNTÜLERİN ÇÖZÜNÜRLÜKLERİNİN ARTIRILMASINA ETKİSİ

MURAT ŞİMŞEK

NİSAN 2016

## ÖZET

### SÜPER-ÇÖZÜNÜRLÜK YÖNTEMLERİNİN HİPERSPEKTRAL GÖRÜNTÜLERİN ÇÖZÜNÜRLÜKLERİNİN ARTIRILMASINA ETKİSİ

ŞİMŞEK, Murat

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans tezi

Danışman: Prof. Dr. Ediz POLAT

Nisan 2016, 82 sayfa

Yüksek spektral bilgiye sahip olmasından dolayı, hiperspektral görüntüler birçok alanda kullanılmaktadır. Ancak bu görüntüler, donanımsal kısıtlamalardan dolayı düşük uzamsal çözünürlüğe sahiptir. Hiperspektral görüntülerin uzamsal çözünürlüğünün düşük olması, askeri ve sivil birçok alanda yapılacak çalışmalarda problem oluşturmuştur. Donanımsal olarak yüksek maliyet gerektirmesi sebebiyle, hiperspektral görüntülerin uzamsal çözünürlüğünü arttırmak için yazılımsal yöntemlere yönelim artmıştır. Yazılımsal olarak yapılan çalışmalarda alınan iyi sonuçlar ve düşük maliyetten dolayı, son dönemlerde bu alana rağbet artmaktadır.

Bu tez çalışmasında, hiperspektral görüntülerin uzamsal çözünürlüklerini arttırmak ve uzamsal çözünürlüğü geliştirmek için kullanılan farklı metotların detaylı karşılaştırılması amaçlanmıştır. Yapılan çalışmada, hiperspektral süper-çözünürlük yöntemi olarak, Pan-keskinleştirme yöntemlerinden IHS ve PCA Pan-Keskinleştirme yöntemleri ile K-SVD, ODL ve Bayes sözlük öğrenme tabanlı seyrek temsil yöntemleri uygulanmıştır.

Anılan bu beş metot ile hiperspektral görüntülerin uzamsal çözünürlüğü başarıyla geliştirilmiş olup; RMSE, SAM ve işlem zamanı olmak üzere üç farklı parametre göz önüne alınarak karşılaştırma yapılmıştır. Yapılan bu

karşılaştırmada hiperspektral görüntünün uzamsal çözünürlüğünü arttırmak için uygun metodun tespit edilmesi amaçlanmıştır. Alınan sonuçlar doğrultusunda tüm metotların birbirlerine oranla olumlu veya olumsuz yönleri karşılaştırılmıştır.

**Anahtar kelimeler:** Hiperspektral, Süper-Çözünürlük, Pan-keskinleştirme, Seyrek Temsil, Sözlük Öğrenme, Seyrek Kodlama.



## ABSTRACT

### EFFECTS OF SUPER-RESOLUTION METHODS ON IMPROVING HYPERSPECTRAL IMAGE RESOLUTIONS

ŞİMŞEK, Murat

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Electrical-Electronics Engineering, M.S. Thesis

Supervisor: Prof. Dr. Ediz POLAT

April 2016, 82 pages

Due to having high spectral resolution, hyperspectral images are used in many areas. However, these images have low spatial resolution because of hardware limitations. On account of having low spatial resolution of hyperspectral imagery, it has created a problem on future studies conducted in many military and civilian applications. Because of requirement of high hardware cost, the tendency to software-based methods for improving spatial resolution of hyperspectral imagery has increased. Due to obtaining high success results and having low cost in software-based methods, this area has become more popular recently.

In this thesis, we aim to improve the spatial resolution of hyperspectral images and compare different methods which are used to enhance spatial resolution of hyperspectral images. In this study, Pan-sharpening methods IHS and PCA along with dictionary learning-based sparse representation methods K-SVD, ODL and Bayesian have been employed.

Successful results have been obtained for improving spatial resolution of hyperspectral images by using these five methods mentioned above, in addition a comparison has been performed using RMSE, SAM and

processing time as parameters. It is aimed to identify the most appropriate method for improving spatial resolution of hyperspectral images. Based on the results, the comparison has been performed to identify the positive and negative effects of the methods.

**Key Words:** Hyperspectral, Super-resolution, Pan-sharpening  
Sparse Representation, Dictionary Learning, Sparse Coding.



## TEŐEKKÜR

Tezimin hazırlanması esnasında hiçbir yardımını esirgemeyen ve büyük destekçisi olan, bilimsel konularda daima yardımını gördüğüm tez yöneticisi hocam, Sayın Prof. Dr. Ediz POLAT'a, tez çalışmalarım esnasında, büyük fedakârlıklarla bana destek olan aileme teşekkür ederim.



# İÇİNDEKİLER DİZİNİ

Sayfa

<b>ÖZET</b> .....	i
<b>ABSTRACT</b> .....	iii
<b>TEŞEKKÜR</b> .....	v
<b>İÇİNDEKİLER</b> .....	vi
<b>ŞEKİLLER DİZİNİ</b> .....	viii
<b>ÇİZELGELER DİZİNİ</b> .....	x
<b>KISALTMALAR DİZİNİ</b> .....	xi
<b>1.GİRİŞ</b> .....	1
1.1. Tez Çalışmasının Amaç ve Kapsamı .....	1
1.2. Literatür Araştırması ve Yapılan Benzer Çalışmaların İrdelenmesi .....	2
<b>2.TEMEL KAVRAMLAR VE YÖNTEMLER</b> .....	5
2.1. Hiperspektral Görüntüleme .....	5
2.2. Süper-Çözünürlük (Super-Resolution) .....	8
2.3. Hiperspektral Görüntüler için Süper-Çözünürlük Yöntemi .....	11
2.3.1. Pan-Keskinleştirme Yöntemi .....	12
2.3.1.1. Yansıma Şiddeti, Renk Tonu, Doygunluk (IHS) Yöntemi .....	12
2.3.1.2. Temel Bileşen Analizi (PCA) Yöntemi .....	16
2.3.2. Seyrek Temsil Yöntemi (Sparse Representation) .....	17
2.3.2.1. Seyrek Kodlama (Sparse Coding) .....	18
2.3.2.2. Sözlük Öğrenme (Dictionary Learning) .....	19
2.3.2.2.1. K-SVD (K-Singular Value Decomposition) Sözlük Öğrenme Algoritması .....	21
2.3.2.2.2. ODL (Online Dictionary Learning) Algoritması .....	24
2.3.2.2.3. Bayes Sözlük Öğrenme Algoritması .....	26
<b>3. ANALİZLER</b> .....	29
3.1. Problemin Tanımlanması .....	29

3.2. Hiperspektral Pan-Keskinleştirme Yöntemi ile İlgili Analizler.....	29
3.3. Hiperspektral Seyrek Temsil Yöntemi ile İlgili Analizler.....	31
3.4. Yöntemlerin Karşılaştırılması için Kullanılan Parametreler.....	42
3.4.1. RMSE (Ortalama Karekök Karesel Hata).....	42
3.4.2. SAM (Spektral Açık Eşleyicisi).....	43
3.4.3. İşlem Zamanı .....	44
<b>4. DENEYSEL SONUÇLAR .....</b>	<b>45</b>
4.1. IHS Pan-keskinleştirme Yöntemi ile Süper-Çözünürlüklü Hiperspektral Elde Etme .....	51
4.2. PCA Pan-Keskinleştirme Yöntemi ile Süper-Çözünürlüklü Hiperspektral Elde Etme .....	55
4.3. K-SVD Yöntemi ile Seyrek Temsil Tabanlı Süper-Çözünürlüklü Hiperspektral Elde Etme .....	59
4.4. ODL Yöntemi ile Seyrek Temsil Tabanlı Süper-Çözünürlüklü Hiperspektral Elde Etme .....	63
4.5. Bayesian Seyrek Kodlama ile Seyrek Temsil Tabanlı Süper Çözünürlüklü Hiperspektral Elde Etme.....	67
<b>5. SONUÇ VE DEĞERLENDİRME .....</b>	<b>71</b>
<b>KAYNAKLAR .....</b>	<b>75</b>



## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.1. Hiperspektral imge küpü .....	6
2.2. Süper Çözünürlüklü (SR) görüntü elde etme .....	9
2.3. Süper-Çözünürlük (SR) Modeli .....	10
2.4. IHS küre renk koordinat sistemi .....	13
2.5. IHS Akış Diyagramı.....	15
2.6. PCA Akış Diyagramı .....	17
2.7. Seyrek Temsil.....	18
2.8. K-SVD basamakları .....	21
2.9. Sözlük Güncelleme Formülasyonu .....	23
3.1. Seyrek Temsil Tabanlı Hiperspektral Süper Çözünürlük Algoritması .....	38
3.2. Bayesian Seyrek Temsil Tabanlı Hiperspektral Süper Çözünürlük Algoritması .....	39
3.3. SAM Referans Açık Gösterimi.....	43
4.1. CAVE veri tabanında yer alan hiperspektral görüntüler.....	46
4.2. Pan-keskinleştirme yönteminde kullanılan hiperspektral görüntü ve aynı sahneye sahip pankromatik görüntü .....	47
4.3. Pan-keskinleştirme yönteminin kullanıldığı program ara yüzü.....	47
4.4. IHS pan-keskinleştirme yöntemi uygulanmış görüntünün program çıktısı ve parametreleri.....	48
4.5. Sözlük Öğrenme Tabanlı Seyrek Temsil Yönteminin kullanıldığı program ara yüzü .....	49
4.6. Uygulama Sonucu Elde Edilen Görüntü. ....	49
4.7. 460nm, 540nm ve 620nm Dalga boylarındaki Hata payı.....	50
4.8. CAVE veri tabanında bulunan "Balloons", "Beads" ve "Cd" isimli hiperspektral görüntülerin IHS yöntemi uygulaması. ....	52
4.9. CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin IHS yöntemi uygulaması. ....	53

4.10. CAVE veri tabanında bulunan “Balloons”, ”Beads” ve “Cd” isimli hiperspektral görüntülerin PCA yöntemi uygulaması. ....	56
4.11. CAVE veri tabanında bulunan “Clay”, ”Cloth” ve “Face” isimli hiperspektral görüntülerin PCA yöntemi uygulaması. ....	57
4.12. CAVE veri tabanında bulunan “Balloons”, ”Beads” ve “Cd” isimli hiperspektral görüntülerin K-SVD sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması. ....	60
4.13. CAVE veri tabanında bulunan “Clay”, ”Cloth” ve “Face” isimli hiperspektral görüntülerin K-SVD sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması. ....	61
4.14. CAVE veri tabanında bulunan “Balloons”, ”Beads” ve “Cd” isimli hiperspektral görüntülerin ODL sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması.. ....	64
4.15. CAVE veri tabanında bulunan “Clay”, ”Cloth” ve “Face” isimli hiperspektral görüntülerin ODL sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması.. ....	65
4.16. CAVE veri tabanında bulunan “Balloons”, ”Beads” ve “Cd” isimli hiperspektral görüntülerin Bayes sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması. ....	68
4.17. CAVE veri tabanında bulunan “Clay”, ”Cloth” ve “Face” isimli hiperspektral görüntülerin Bayes sözlük öğrenme tabanlı seyrek temsil yöntemi uygulaması. ....	69
5.1. Ortalama Parametrelerin Karşılaştırılması. ....	73

## ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
4.1. IHS yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.....	54
4.2. PCA yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.....	58
4.3. K-SVD sözlük öğrenme tabanlı Seyrek Temsil yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları .....	62
4.4. ODL sözlük öğrenme tabanlı Seyrek Temsil yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları .....	66
4.5. Bayes sözlük öğrenme tabanlı Seyrek Temsil yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları .....	70
5.1. Yöntemlerin Karşılaştırma Değerleri .....	72

## KISALTMALAR DİZİNİ

G-SOMP+	Generalized Simultaneous Orthogonal Matching Pursuit
HLS	Hue-Luminance-Saturation
HR	High Resolution
HSI	Hyperspectral Imagery
HSV	Hue-Saturation-Value
HYMEX	Hyperspectral Image Exploitation
IHS	Intensity-Hue-Saturation
JPM	Joint Processing Method
K-SVD	K-Singular Value Decomposition
LMM	Linear Mixed Model
LR	Low Resolution
MSI	Multispectral Imagery
ODL	Online Dictionary Learning
PAN	Panchromatic Imagery
PCA	Principle Component Analysis
POCS	Projection onto Convex Sets
RBG	Red Blue Green
RMSE	Root Mean Square Error
SAM	Spectral Angle Mapper
SMA	Spectral Mixture Analysis
SOMP	Simultaneous Orthogonal Matching Pursuit
SPAMS	Sparse Modeling Software
SR	Super-Resolution
SRM	Super-Resolution Mapping
SSJ	Spatial-Spectral Joining
SWIR	Short-wavelength infrared

# 1.GİRİŞ

## 1.1. Tez Çalışmasının Amaç ve Kapsamı

Bu tez çalışmasının genel amaç ve kapsamı, düşük uzamsal çözünürlüğe sahip hiperspektral görüntülerin uzamsal çözünürlüklerini süper-çözünürlük yöntemleriyle geliştirmek, kullanılan süper-çözünürlük yöntemlerini karşılaştırmak ve hiperspektral görüntüler için en efektif Süper Çözünürlük yöntemini tespit etmektir.

Hiperspektral görüntüler, görüntü işlemede çok büyük öneme haiz olan yüksek spektral çözünürlüğe sahip olmasına rağmen, uzamsal çözünürlükleri donanım kısıtlamalarından dolayı düşüktür. Düşük uzamsal çözünürlük, görüntü inceleme, hedef tespiti ve tanıma gibi alanlarda problem doğurduğundan, hiperspektral görüntülerin uzamsal çözünürlüklerini geliştirmede yazılımsal yaklaşımlar geliştirilmiştir.

Hiperspektral görüntünün uzamsal çözünürlüklerini geliştirmek için süper-çözünürlük yöntemleri önerilmiştir. Bu tez çalışmasında, hiperspektral görüntülerin uzamsal çözünürlüklerini arttırmak için literatürde yaygın olarak kullanılan pan-keskinleştirme yöntemleri ile seyrek temsil yöntemleri kullanılmıştır. Farklı pan-keskinleştirme yöntemleri kullanılmış olup birbirleri arasında karşılaştırma yapılmıştır. Ayrıca bu tez çalışmasında, sözlük öğrenme tabanlı seyrek temsil yöntemini kullanarak farklı sözlük öğrenme yöntemi ile süper çözünürlüklü hiperspektral görüntüler elde edilmiş, sözlük öğrenme yöntemlerinin, süper-çözünürlük hiperspektral görüntü elde etmeyi ne kadar etkilediği ortaya konulmuştur.

Pan-keskinleştirme yöntemlerinden IHS (Yansıma Şiddeti, Renk Tonu, Doygunluk) ve PCA (Temel Bileşen Analizi) Pan-Keskinleştirme yöntemleri ile K-SVD, ODL ve Bayes sözlük öğrenme tabanlı Seyrek Temsil yöntemleri kullanılmıştır. Anılan bu yöntemler ile hiperspektral görüntülerin uzamsal

çözünürlüklerini dikkate değer şekilde artırılması ve kullanılan yöntemlerin belirli parametreler aracılığıyla karşılaştırılıp en uygun yöntemin tespit edilmesi amaçlanmaktadır.

Kullanılan yöntemlerin karşılaştırılmasında RMSE, SAM ve işlem zamanı gibi özel parametreler kullanılmış olup, en haz hata payı, en az spektral bozulma değeri ve en az işlem zamanına sahip yöntemin tespitine çalışılmıştır.

Hata paylarından yola çıkarak kullanılan hiperspektral görüntülerin en uygun yöntemle uzamsal çözünürlükleri geliştirilmiş, şu anda kullanılan ve gelecek zamanda kullanılacak hiperspektral uydularından ve kameralardan alınan görüntülerin uzamsal çözünürlüğünün gözle görülür bir şekilde düzelleme ve gelişme gösterdiği değerlendirilmiştir.

## **1.2. Literatür Araştırması ve Yapılan Benzer Çalışmaların İrdelenmesi**

Hiperspektral süper çözünürlük yöntemi alanında yapılan literatür araştırmasında sayı olarak çok az uygulama ve çalışma ile karşılaşmıştır. Günümüzde hiperspektral görüntülemenin popülaritesi her geçen gün arttığı düşünüldüğünde, bu alanda yapılan çalışmaların ve bunların değerinin de aynı oranda arttığı ve yeni bir uygulama alanı olduğu değerlendirilmiştir. Hiperspektral görüntülerin uzamsal çözünürlüğünün geliştirilmesinden ziyade hiperspektral görüntülerin sınıflandırılması üzerine literatürde birçok uygulama ile karşılaşmıştır.

Akgün ve Altunbaşak [1], 2005 yılında hiperspektral görüntülerin süper çözünürlük yöntemiyle yeniden yapılandırılması üzerine çalışmalarda bulunmuştur. Bu çalışmalarda PCA (Temel Bileşen Analizi) yöntemi kullanılmıştır.

Buttingsrud ve Alsberg [2], 2006 yılında maksimum entropi metodu tabanlı hiperspektral görüntüler için süper çözünürlük yöntemi üzerinde çalışmalar yapmıştır.

Mianji ve Zhang [3], 2008 yılında hiperspektral görüntüleme üzerindeki zorlukları üzerine çalışmalar yapmıştır. Bu çalışmada temel süper çözünürlük yaklaşımlarının hiperspektral görüntüleme üzerindeki zorluklarından ve problemlerinden bahsedilmiştir.

Babakhani ve Zhang [4], 2009 yılında hiperspektral görüntüleme sistemlerinin çözünürlüğünü geliştirmek için uygun metod seçimi üzerine çalışmada bulunmuşlardır. Hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmek için kullanılan JPM (Ortak İşlem Metodu), SMA (Spektral Katılım Analizi), SRM (Süper Çözünürlük Eşleme) ve SSJ (Uzamsal-Spektral Birleşim) yöntemlerini karşılaştırmışlardır.

Zhao ve Yang [5], 2011 yılında seyrek temsil ve spektral regülarizasyonu tabanlı hiperspektral süper çözünürlük yöntemi üzerinde çalışmalar yapmışlardır. AVIRIS veri tabanındaki görüntülerden faydalanarak uzamsal çözünürlüğün artırılmasında gelişim göstermişlerdir.

Zhang ve Shen [6], 2012 yılında PCA (Temel Bileşen Analizi) tabanlı hiperspektral süper çözünürlük yöntemi üzerinde çalışmalar yapmışlardır.

Wu ve Zhan [7], 2012 yılında hiperspektral görüntünün süper çözünürlük eşleme yöntemi içindeki uzamsal yapısını birleştirme alanında çalışmalar yapmıştır.

Akhtar ve Shafait [8], 2014 yılında seyrek temsil tabanlı hiperspektral süper çözünürlük yöntemi üzerine çalışmalarda bulunmuştur.

Akhtar ve Shafait [9], 2015 yılında Bayes tabanlı seyrek temsil yöntemi üzerine çalışmalarda bulunmuştur.

2015 yılında bu tez kapsamında yapılan bir çalışmada, ODL ve K-SVD sözlük öğrenme tabanlı seyrek temsil yöntemi kullanarak, hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirme ve sözlük öğrenme yöntemlerinin hiperspektral süper çözünürlük yapısına etkileri üzerine çalışmada bulunmuştur [10].

Literatürde yer alan bu çalışmalar hiperspektral görüntülerin uzamsal çözünürlüklerini geliştirmede katkıda bulunmuştur. Ancak, literatürdeki çalışmalarda belirli yöntem aracılığıyla hiperspektral görüntülerin çözünürlüğü geliştirilmiş olup var olan diğer süper çözünürlük yöntemleriyle detaylı bir karşılaştırma yapılmamıştır. Ayrıca, literatürde yer alan çalışmalarda hiperspektral görüntülerin uzamsal çözünürlüklerini geliştirmede kullanılan yöntemlerin tercih edilebilirliği ile ilgili olarak karşılaştırma parametreleri kullanılarak oluşturulan bir çalışma bulunmamaktadır. Bu tez çalışmasıyla, hiperspektral görüntülerin süper çözünürlük yöntemleri arasında detaylı bir karşılaştırma yapılmış olup, hata payı, spektral bozulma ve işlem süresi gibi önemli parametreler aracılığıyla bir sonuca varılmıştır.






## 2.TEMEL KAVRAMLAR VE YÖNTEMLER

### 2.1. Hiperspektral Görüntüleme

Hiperspektral, çok sayıda spektral banttandır meydana gelen anlamına gelmektedir. Hiperspektral görüntüler, spektral olarak farklı materyalleri ayırt etmek ve tanımlamak için çok sayıda spektral bilgiyi tedarik ettiğinden dolayı spektral olarak üstündür. Uzaktan algılama sistemlerinde yaşanan büyük yeniliklerden biri olan hiperspektral görüntüleme, potansiyel olarak diğer görüntü sistemlerinden daha doğru ve detaylı bilgi elde etmeyi sağlamaktadır [11]. Hiperspektral görüntüleme, yüzey materyallerinden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandındaki ölçümüdür. Çok bantlı görüntüler 1970'li yıllardan beri düzenli olarak kullanılmasına rağmen, Hiperspektral görüntülerin yaygın kullanımı 2000'li yıllara dayanmaktadır. Birçok çokbantlı görüntü çeşitleri (Landsat, SPOT ve AVHRR) yalnızca kısıtlı sayıda dalga boyunda yer yüzeyinin yansımalarını ölçebilirken, hiperspektral sensörler çok sayıda dalga boyuna sahip olduğundan dolayı daha dar ve sık aralıklarla yer yüzeyinden gelen yansımaları çok daha doğru değerlerle ölçebilmektedir. Hiperspektral sensörlerin sahip olduğu çok sayıdaki spektral bilgiyi kaliteli yapan değerler, bu bilgilerin çok dar dalga boylarında ve devamlı bir şekilde veri sunmasıdır. Genel olarak hiperspektral sensörler 10 ve 20 nm. aralıklarda ölçüm yapmaktadır [12].

Hiperspektral kamera ile elde edilen görüntülerin üç boyutu mevcuttur. Bu üç boyutun ilk iki boyutuna görüntünün uzamsal boyutu, üçüncü boyutuna ise görüntünün spektral boyutu denilmek üzere üç boyutlu hiperspektral görüntü küpü olarak ifade edilir [13].



**Şekil 2.1.** Hiperspektral imge küpü [14].

Hiperspektral görüntüleme; hedef tespiti, tarımsal izleme, madde tanıma, madde sınıflandırma, doğal kaynak keşfi gibi konuları içeren askeri ve ticari uygulamalarda kullanılmaktadır [15]. Örnek uygulama olarak, geri dönüşüm alanında elektronik atık tespiti ve ayrıştırılması; gıda alanında tazelik ve nemlilik kontrolü, zararlı gıda tespiti ve yağ/protein/şeker içeriği analizi; ilaç alanında sahte ilaç tespiti, yabancı maddelerin tespiti ve kapsüllerde eskime oranı ölçümü; maden alanında petrol keşfi, rezerve büyüklüğü ve tehlikeli gazların tespiti; orman alanında bitki çeşitliliğinin dağılımı; savunma alanında askeri hedef ve kamuflaj tespiti, gömülü mayın tespiti; tarım alanında böceklenme etkenlerin teşhisi, tarıma elverişli bölgelerin tespiti gibi birçok uygulama mevcuttur. Bu uygulama alanlarında yapılan çalışmalardan; madde tanıma alanında Cochrane [16] hiperspektral görüntülerde bitkilerin çeşitliliğini tespit etmede başarılı sonuçlar elde etmiştir. Doğal kaynak keşfinde ise Ellis [17] petrol sızıntılarının tespitinde hiperspektral görüntülerden faydalanmıştır. Medikal alanında, Freeman [18] ve Overton [19] hiperspektral görüntüleme ile doku yüzeyinde spektroskopik kontrol yaparak kanser gibi hastalıkları tespit etmede, Zuzak [20]'da deri içerisindeki

hemoglobinin oksijene doygunluğunu ölçmede çalışmalar yapmışlardır. Adli alanda, Flynn [21] hiperspektral görüntüleme kullanarak farklı çeşit boyaların tespitinde, Exline [22] ise yüzey üzerindeki gizli parmak izlerinin tespitinde gelişmeler sağlamıştır. Savunma alanında, Kanada Silahlı Kuvvetler için geliştirilen ve 0.4-2.5 mikrometre spektral aralıkta görüntü elde edebilen HYMEX (Hyperspectral Image Exploitation) [23] projesi ile hedef algılama ve tanıma alanında çalışmalar yapılmıştır. Ayrıca Bongiovi [24] kamuflaj durumundaki askeri araçların hiperspektral veriler sayesinde tanınması üzerine çalışmalar yapmıştır.

Günümüzde hiperspektral görüntülerin kullanımı yaygınlaştıkça, yüksek uzamsal çözünürlüğe sahip hiperspektral görüntü gereksinimi de artmaktadır. Hiperspektral görüntüleri işleme ve görüntü sınıflandırmada yüksek doğruluk, güvenilir sonuçlar ve detaylı bilgi elde etmek için yüksek spektral çözünürlüğün yanında yüksek uzamsal çözünürlüğe de ihtiyaç duyulmaktadır [25]. Hiperspektral görüntüler çok sayıda spektral bilgiye sahip olduklarından dolayı spektral çözünürlükleri yüksektir. Ancak; hiperspektral görüntüleme donanım cihazını dizayn ederken spektral alanda yüksek hassasiyet sağlamak için spektral ve uzamsal çözünürlük arasında bir değişim yapılmıştır. Ayrıca hiperspektral görüntüleme için kullanılan uzaktan algılama sistemlerinin tasarımındaki odak yüzeyin dizi teknolojisinin (focal plane array technology) sınırlanması, spektral çözünürlüğü yüksek tutmak için uzamsal çözünürlük arasındaki içsel değiş-tokuşu, veri alanının kapasitesinde genişlik sağlama isteği gibi birçok faktör bu görüntülerin uzamsal çözünürlüğünün kalitesini düşürmektedir [15]. Düşük uzamsal çözünürlük birçok karışık piksele, algılama ve tanıma performansının büyük oranda düşmesine, sivil ve askeri alanlardaki uygulamalarının etkilenmesine sebep olacaktır [6].

Normalde uzamsal çözünürlük yüksek çözünürlüklü sensörler yardımıyla geliştirilebilir. Ancak, bu çözüm hiperspektral görüntüler için çok etkili değildir. Bununla birlikte, sensörlere ulaşan fotonların yoğunluğunu azaltır. Donanım kısıtlamalarını da göz önünde bulundurursak, hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmek için yazılım tabanlı teknikler geliştirmek daha etkili olacaktır. Hiperspektral sistemlerle düşük spektral çözünürlüklü

görüntüleme sistemleri (RGB kameralar vb.) karşılaştırıldığında, düşük spektral çözünürlüklü sistemler büyük örneklemeli görüntü radyansı performansından dolayı birçok spektral bilgisini kaybeder. Ancak bu sistemler, görüntünün büyük uzamsal çözünürlüklü bilgisini içerir. Bu sistemler tarafından elde edilen görüntü, hiperspektral görüntülerin uzamsal çözünürlüğünü iyileştirmede yardımcı olabilir [8]. Hiperspektral görüntülerin uzamsal çözünürlüğünü arttırmak için donanımsal gelişmeler yerine yazılımsal çalışma olarak süper çözünürlük yöntemleri kullanılarak daha ekonomik ve daha efektif sonuçlar alınabilmektedir.

## **2.2. Süper-Çözünürlük (Super-Resolution)**


Teknolojik gelişmelerin son dönemlerde artış göstermesiyle beraber gereksinim olarak yüksek çözünürlüğe sahip görüntü elde etme istediği de artış göstermiştir. Yüksek çözünürlük (HR) anlam olarak, bir görüntüdeki piksel yoğunluğunun yüksek olmasıdır. Bu sebepten yüksek çözünürlüklü (HR) görüntüler daha fazla detay bilgiye sahiptir ve bazı uygulamalarda kullanılmak için kritik öneme sahiptir. Uzaktan algılama sistemlerindeki önemli gelişmelere rağmen, yüksek çözünürlüğe sahip görüntü elde etme işlemi donanımsal olarak yüksek maliyete sebep olduğundan dolayı, son dönemlerde yazılımsal olarak mevcut çözünürlüğü arttırmaya yönelik çalışmalara ağırlık verilmiştir.

Uzamsal çözünürlüğü arttırmak için umut verici bir yaklaşım, düşük çözünürlüklü (LR) görüntülerden yüksek çözünürlüklü (HR) bir görüntü veya görüntü dizisi elde etmek için sinyal işleme tekniklerinin kullanılmasıdır. Son zamanlarda bu tarz çözünürlük geliştirme yaklaşımları en aktif araştırma alanlarından biri olmuştur ve bu yaklaşım literatüre Süper-Çözünürlük (SR) olarak geçmiştir.

Süper-Çözünürlük (SR) terimindeki “Süper” kelimesi, düşük çözünürlüklü görüntüleme sistemlerinin kendisine özgü çözünürlük sınırlamasının en iyi şekilde üstesinden gelme özelliğine sahip olduğunu göstermek için kullanılır. Süper-Çözünürlüklü (SR) görüntü oluşturma tekniği, tıbbi görüntüleme, uydu

görüntüleme ve video uygulamaları da dâhil olmak üzere, aynı sahnenin birden çok görüntüsünün elde edilebileceği birçok alanda kullanılmaktadır. LANDSAT ve uzaktan algılama sistemleri gibi uydu görüntüleme uygulamalarında, genellikle aynı bölgenin birden fazla görüntüsü tedarik edildiğinden görüntüdeki ilgilenilen hedefin çözünürlüğü Süper-Çözünürlük (SR) yöntemi ile artırılabilir.

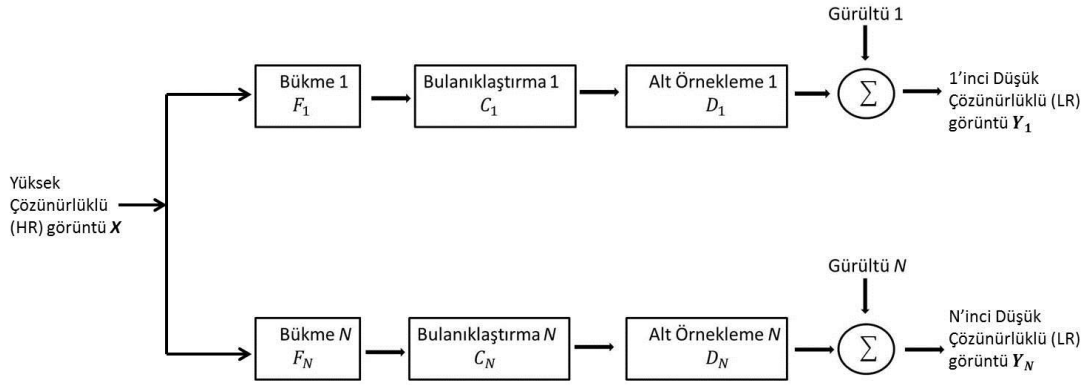
Süper-Çözünürlük (SR) tekniklerinin, uzamsal çözünürlüğü arttırmak için temel dayanak noktası aynı sahnenin çekilen birden fazla düşük çözünürlüklü (LR) görüntülerinin mevcut olmasıdır. Kullanılan aynı sahnenin düşük çözünürlüklü görüntülerinin çok küçük değerlerde farkları olduğundan dolayı aynı sahne hakkında farklı bilgiler elde edilmiş olunur. Süper-Çözünürlük (SR) yönteminde; bir dizi düşük çözünürlüklü (LR) görüntülerin bilgisi bir araya getirilerek bir veya birden çok yüksek çözünürlüklü görüntü oluşturulur. Görüntüler bir araya getirilirken düşük çözünürlüklü (LR) görüntüler, alt örneklendirmenin yanı sıra alt piksel hassasiyeti ile kaydırılır [26].



**Şekil 2.2.** Süper Çözünürlüklü (SR) görüntü elde etme.

Süper-Çözünürlük (SR) tekniğini uygulayıp elde edilen yüksek çözünürlüklü (HR) görüntü, var olan düşük çözünürlüklü görüntülerin alt örneklenmiş ve bunun yanı sıra alt piksel kaydırma işleminin yapılmış halidir.

Mevcut düşük çözünürlüklü (LR)  $N$  adet görüntü  $\{Y_k\}_{k=1}^N$ ,  $[M_k \times M_k]$  boyutlarına sahiptir. Elde etmek istenilen yüksek çözünürlüklü görüntü  $X$ ,  $[L \times L]$  boyutlarına sahip olduğu düşünölsün.  $1 \leq k \leq N$  için  $L > M$  olur. Her düşük çözünürlüklü (LR) görüntü, elde edilen yüksek çözünürlüklü (HR) görüntünün rastgele ortalama bükme işlemi, lineer değışkende bulanıklaştırma, alt örnekleme işlemi ve gürültü eklenmiş hali olmaktadır.



**Şekil 2.3.** Süper-Çözünürlük (SR) Modeli.

Şekil 2.3'de yer alan süper-çözünürlük modeli matematiksel olarak şu şekilde ifade edilir;

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_N \end{bmatrix} = \begin{bmatrix} D_1 & C_1 & F_1 \\ \vdots & \vdots & \vdots \\ D_N & C_N & F_N \end{bmatrix} X + \begin{bmatrix} E_1 \\ \vdots \\ E_N \end{bmatrix} \quad (2.1)$$

Bu formöilde;  $Y$  düşük çözünürlüklü (LR) görüntüyü,  $D$  alt örnekleme işlemini,  $C$  bulanıklaştırmayı,  $F$  bükme işlemini ve  $E$  ise gürültüyü temsil etmektedir.

Denklem (2.1)'deki alt örnekleme, bulanıklaştırma ve bükme işlemlerinin olduğu matris  $H$  olarak, gürültü matrisi ise  $E$  olarak temsil edildiğinde; Denklem (2.2.)'deki gibi bir ifade elde edilir [27].

$$Y=HX+E$$

(2.2)

Genel olarak kabul edilen süper-çözünürlük yöntemi, aynı sahneye ait birçok düşük çözünürlüklü (LR) görüntünün sensör hareketi içerisindeki alt-piksel kaydırmasının yapılmasıdır. Bu metod genellikle zor ve işlemsel olarak külfetli çalışmalardan oluşan hassas bir işlemdir. Bu zor işlemlerin üstesinden gelmek için son zamanlarda görüntü işleme alanında çalışmalar yapan araştırmacılar değişik yöntemler geliştirmeye başlamışlardır.

### 2.3. Hiperspektral Görüntüler için Süper-Çözünürlük Yöntemi

Son zamanlarda görüntülerin uzamsal çözünürlüğünün geliştirilmesinde süper çözünürlük yapılanmasının olumlu etkisinden dolayı, araştırmacılar hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmede de süper çözünürlük yapılanması tekniklerini kullanmaya başlamışlardır. Bu alanda yapılan çalışmalarda, Akgün [1], POCS tabanlı bir süper-çözünürlük yöntemi ile hiperspektral görüntülerin çözünürlüğünü geliştirmek için komplike bir hiperspektral görüntü elde etme yöntemi önermiştir. Buttingsrud ve Alsberg [2], maksimum entropi tabanlı hiperspektral görüntü süper çözünürlüklü yeniden yapılanma yöntemi önermiştir. Mianji [3], hiperspektral görüntülerin süper çözünürlük yapılanmasının önemli problemleri ve zorlukları hakkında çalışma yapmıştır. Ancak, bu yöntemlerin çoğu sadece kendi deneylerinde bilinen hareket parametrelerini varsayarak, sentetik görüntüler kullanmışlardır. Alternatif olarak, birçok araştırmacı, yardımcı bir yüksek çözünürlüklü görüntü kullanarak hiperspektral görüntülerinin uzamsal çözünürlüğünü geliştirmek için görüntü füzyonu probleminin üstesinden gelmeyi başarmıştır. Bunun en tipik örneği hiperspektral görüntülere pan-keskinleştirme [28] yöntemlerinin uygulanmasıdır. Fakat bu metodların birçoğu, hiperspektral görüntüler için son derece önemli olan spektral bilgilere genellikle zarar vermektedir.

Genel olarak hiperspektral görüntüler için üzerinde çalışılan süper-çözünürlük yöntemlerine, En Küçük Kareler Yöntemi, Pan-keskinleştirme Yöntemleri,

İstatistiksel Yöntemler, Temel Bileşen Analizi ve Sözlük Öğrenme Tabanlı Seyrek Temsil Yöntemleri örnek verilebilir.

Bu tezde, Pan-Keskinleştirme ve Sözlük Öğrenme Tabanlı Seyrek Temsil Yöntemi kullanılmıştır. Bu yöntemlerden elde edilen parametreler ile karşılaştırma yapılmış olup, hiperspektral görüntüler için en uygun süper çözünürlük yönteminin tespitine çalışılmıştır.

### **2.3.1. Pan-Keskinleştirme Yöntemi**

Uzaktan algılama sistemlerindeki görüntülerin uzamsal çözünürlüğünü arttırmak için en çok kullanılan yöntemlerden biri Pan-Keskinleştirme (Pan-Sharpning) yöntemidir. Eğer uygun pankromatik görüntüler veya yüksek çözünürlüklü multispektral görüntüler mevcutsa, pan-keskinleştirme yöntemi ile bunların füzyonu yapılarak yüksek çözünürlüklü hiperspektral görüntüler elde edilebilir. Bu yöntemin en belirgin metotları aşağıda yer almaktadır.

1. Yansıma Şiddeti, Renk tonu, Doygunluk (Intensity-Hue-Saturation (IHS)) Yöntemi
2. Temel Bileşen Analizi (Principal Component Analysis (PCA)) Yöntemi
3. Dalgacık (Wavelet) Yöntemi

Fakat bu yöntemler için kullanılan Pankromatik görüntü, işlem yapılacak olan hiperspektral görüntüdeki kadar spektral bilgiye sahip olmadığından dolayı, HSI-PAN keskinleştirme işleminde kullanılan hiperspektral görüntüdeki spektral bilgi, bozulmaya maruz kalmaktadır [29].


#### **2.3.1.1. Yansıma Şiddeti, Renk Tonu, Doygunluk (IHS) Yöntemi**

Pan-keskinleştirme için bilinen en yaygın metotlardan biri IHS (Intensity-Hue-Saturation) yöntemidir. Bu yöntem görüntü analizindeki standart uygulamalar olan renk iyileştirme, özellik geliştirme, uzamsal çözünürlüğü geliştirme ve farklı veri setlerinin füzyonu için ortaya çıkmıştır [30]. IHS uzayında, spektral



bilgi genellikle renk ve doygunluk bileşenin üzerine yansıtılır. Görüntü sisteminde, eklenen yansıma şiddeti değişikliği spektral bilgide küçük bir etki yapmaktadır ve bu etkiyle kolaylıkla başa çıkılabilir. Görüntü füzyonu işleminde, spektral bilgi korunup düşük uzamsal çözünürlük geliştirilmek istendiğinde, bu yöntem yapılan füzyon için spektral bilgide bozulmaya neden olmaktadır [31].

Kırmızı, yeşil ve mavi (RGB) olmak üzere üç temel renge sahip olan sayısal görüntülerin toplam parlaklık ölçüsünü “Yansıma Şiddeti (I)”, görüntüyü oluşturan ışığın dalga boyunu “Renk Tonu (H)” ve görüntüyü oluşturan rengin saflık derecesini “Doygunluk (S)” temsil etmektedir. Bu yöntem, düşük mekânsal çözünürlüğe sahip görüntüden seçilen üç banda ait verileri kullanarak IHS (Intensity-Hue-Saturation) bileşenlerine dönüştürür [32].



**Şekil 2.4.** IHS küre renk koordinat sistemi.

IHS yönteminde, model çeşitlerinin karmaşıklıklarına rağmen, renk tonu ve doygunluk değerleri genellikle birbirine benzemektedir. Ancak, dönüşümdeki yansıma şiddeti bileşeninin hesaplanması, kullanılan metot içerisinde değişiklik göstermektedir. Genel olarak en yaygın yansıma şiddeti formülleri Denklem 2.3-2.5'de gösterilmiştir.

$$V = \max\{R, G, B\} \quad (2.3)$$

$$I = \frac{R+G+B}{3} \quad (2.4)$$

$$L = \frac{\max(R,G,B)+\min(R,G,B)}{2} \quad (2.5)$$

Denklem 2.3'de yer alan formül Smith altıgensel modeli, denklem 2.4'de bulunan formül Smith üçgensel modeli belirtmektedir. Denklem 2.5 ise maksimum ve minimum renk kullanılarak oluşturulmuş formüldür [33]. Denklem 2.3'de yer alan Smith altıgensel modelindeki V, IHS modelinin diğer bir ismi olan HSV (Hue-Saturation-Value) modelinde bulunan "V" harfi olup yansıma şiddetini temsil etmektedir. Denklem 2.5'de bulunan L harfi ise, IHS modelinin diğer bir ismi olan HLS (Hue-Luminance-Saturation) modelinde bulunan "L" harfini temsil etmektedir.

IHS yönteminde kullanılan küre renk modelindeki kartezyen dönüşüm modeli denklem 2.6'da gösterilmiştir.

$$\begin{bmatrix} I \\ v1 \\ v2 \end{bmatrix} = \begin{bmatrix} 0.577 & 0.577 & 0.577 \\ -0.408 & -0.408 & 0.816 \\ -0.707 & 0.707 & 1.703 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.6)$$

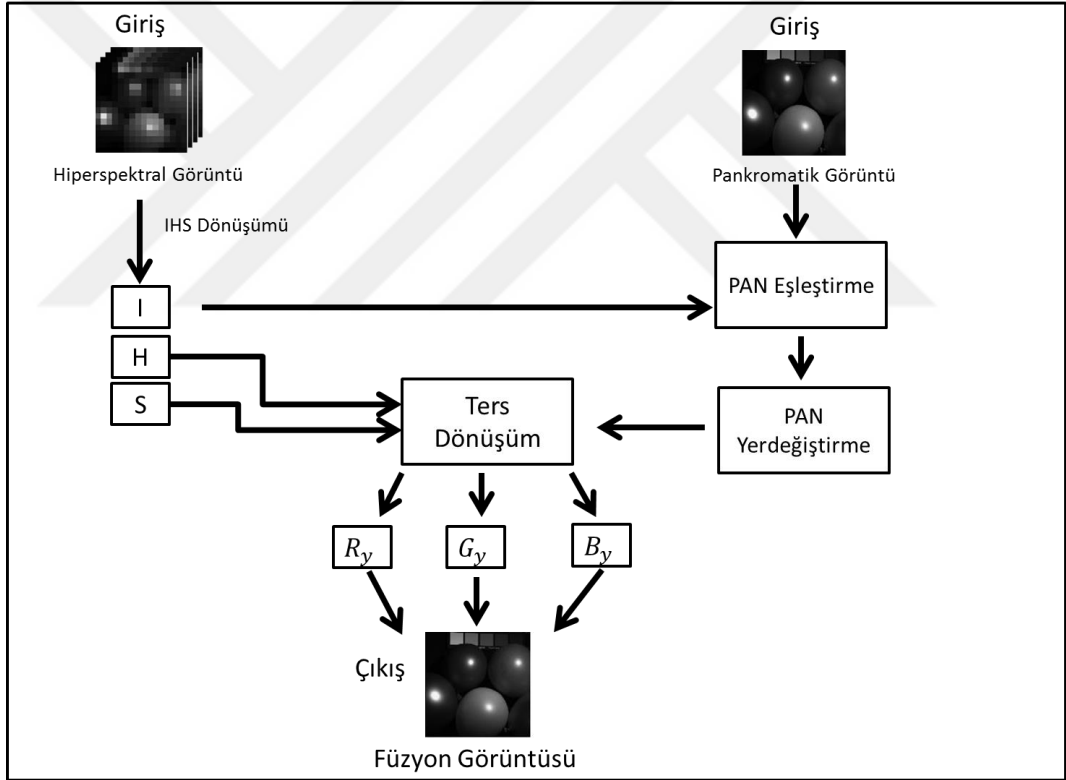
$$H = \tan^{-1}\left(\frac{v2}{v1}\right) \quad (2.7)$$

$$S = \sqrt{(v1^2 + v2^2)} \quad (2.8)$$

Denklem 2.6'da yer alan "I" yansıma şiddetini, v1 ve v2 ise renk tonu ve doygunluğun kartezyen bileşenlerini temsil etmektedir. İşlem esnasında kullanılan pankromatik görüntünün piksel değerini hesaplamak için denklem 2.6'ya ters dönüşüm yaparak denklem 2.9 elde edilmiştir.

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 0.577 & -0.408 & -0.707 \\ 0.577 & -0.408 & 0.816 \\ 0.577 & 0.816 & 0 \end{bmatrix} \begin{bmatrix} I \\ v1 \\ v2 \end{bmatrix} \quad (2.9)$$

Denklem 2.9'da yer alan I değeri füzyon için kullanılan pankromatik görüntünün piksel değerindeki yansıma şiddeti değerini ifade etmektedir [34]. Şekil 2.5'de IHS yönteminin akış diyagramı yer almaktadır.



Şekil 2.5. IHS Akış Diyagramı.

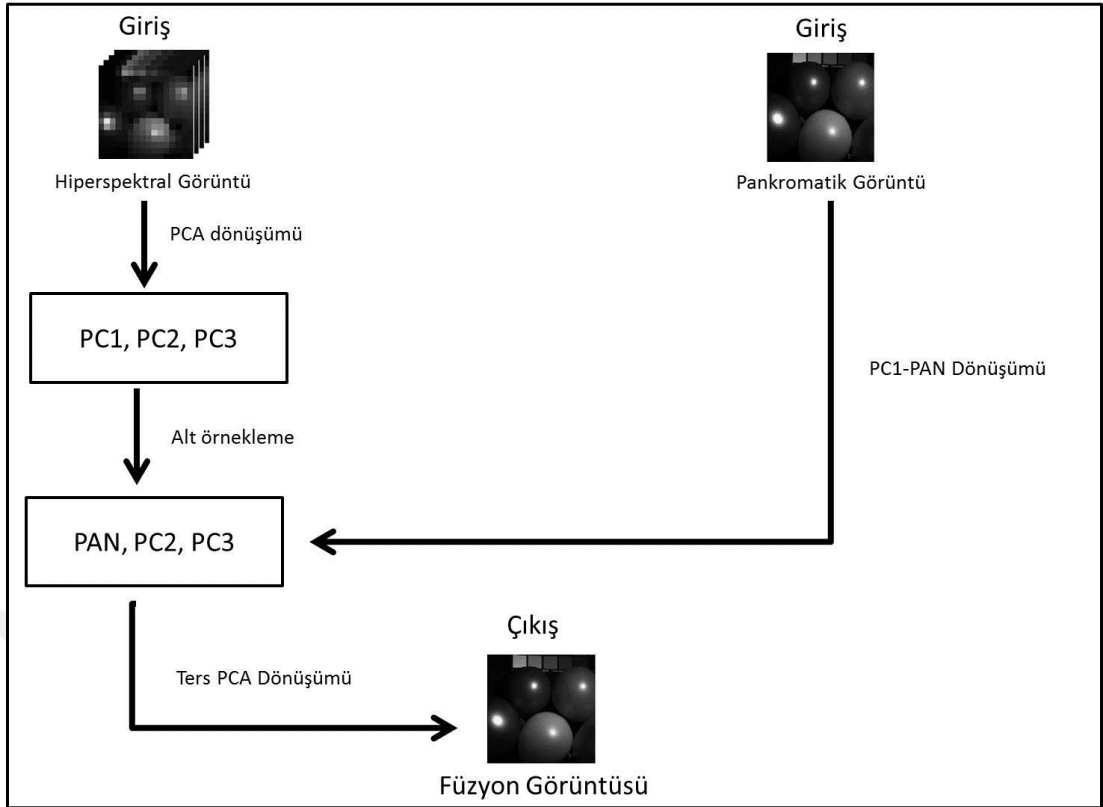
### 2.3.1.2. Temel Bileşen Analizi (PCA) Yöntemi

Temel bileşen analizi (PCA), sinyal işleme, istatistik gibi birçok alanda yaygın şekilde kullanılan bir yöntemdir. Bu metot, Karhunen-Loeve dönüşümü olarak da bilinir [35]. PCA, yüksek korelasyonlu değişkenleri, temel bileşenler olarak adlandırılan korelasyonsuz değişkenler setine dönüştüren bir matematiksel işlemdir.

İlk temel bileşen; verinin içindeki değişkenliği mümkün olduğu kadar açıklar. Sonraki her bir bileşen ise kalan değişkenliği açıklamaktadır. Veri içerisindeki değişken kadar temel bileşen olabilir. Orijinal değişkenler ile tanımlanan alanda yeni pozisyonlar, mevcut bir eksen dönüşümü olarak görülebilir. Bu yeni dönüşümle, dönüşüm tarafından tanımlanan yeni değişkenler arasında herhangi bir korelasyon olmayacaktır.

PCA, yaygın olarak boyut azaltma ve veri analizi için kullanılır. PCA, çok bantlı görüntülerdeki (MSI, HSI) bantların kovaryans matrisindeki özdeğer ve özvektörleri kullanarak hesaplanır. Özdeğerler temel bileşenler boyunca değişkenliği (varyansı), özvektörler ise temel bileşenlerin yönünü belirtmektedir. Çok bantlı görüntülerin bantlarındaki kovaryans matrisinin özdeğerleri büyüklük sırasına göre düzenlenir. Temel bileşenleri hesap edebilmek için kullanılan dönüşüm matrisi, özdeğerlere karşılık gelen ve düzenlenen özvektörler tarafından elde edilir. Bu sebepten dolayı birinci temel bileşen en yüksek özdeğere veya maksimum varyansa karşılık gelmektedir. İkinci temel bileşen ikinci en yüksek varyansa karşılık gelir ve böylelikle sırayla varyans değeri azalır.

PCA, görüntü sıkıştırma, görüntü geliştirme, boyutsal kısaltma ve görüntü füzyonunda çok kullanışlı bir metottur. PCA, çok bantlı görüntü bantlarında ve bu bantlardan hesaplanan temel bileşende uygulanır. İlk temel bileşen, görüntü füzyonunda kullanılacak olan pankromatik görüntü tarafından yer değiştirilir. Ters PCA dönüşümü ile görüntü domenine geri dönme işlemi hesaplanır.



**Şekil 2.6.** PCA Akış Diyagramı.

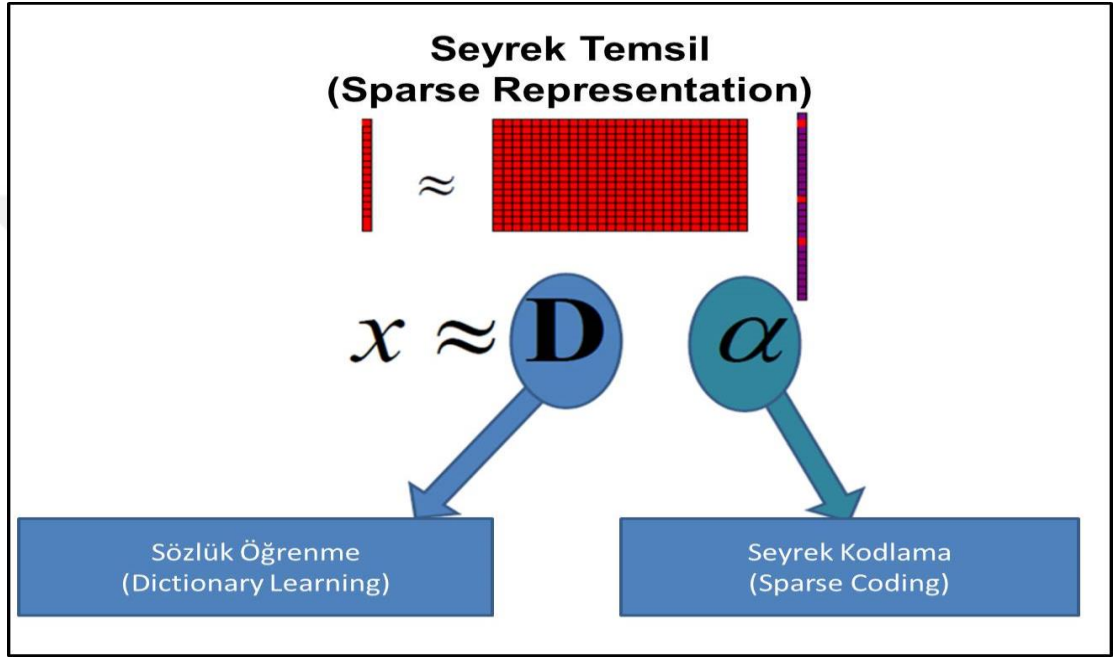
PCA, keskinleştirilecek alana karşı duyarlıdır. Piksel değerlerinin varyansı ve çeşitli bantlardaki korelasyon, görüntüdeki kaplama alanına bağlı olarak değişim gösterir. PCA, kovaryans matrislerinin hesaplamalarını içerdiğinden, performansı görüntüdeki bantlar arasındaki kovaryansa göre değişiklik gösterir.

### 2.3.2. Seyrek Temsil Yöntemi (Sparse Representation)

Seyreklik; bir vektör veya matris içerisindeki çok sayıda sıfırları ima etmektedir. Seyrek Temsil; seyrek sinyallerin az sayıda temel sinyalden veya atomdan tamamen yeniden düzenlenebilir olduğunun gösterimidir. Doğal sinyallerin seyrek temsili, sinyalin kendi seyrekliğini ve sıkıştırılabilirliğini kullanarak elde edilebilir. Doğal bir sinyalin az sayıda temel vektörünün, lineer kombinasyonunun sıkıştırılmış haline seyrek sinyal denilebilir. Seyrek

Temsil Yöntemi, zaman domeni ile dönüşüm domeninin direkt olarak karşılaştırılmasında çok değerli bir yöntem haline gelmiştir.

Seyrek Temsil Yöntemi iki farklı problem içermektedir. Bunlar “Seyrek Kodlama” ve “Sözlük Öğrenme”dir. Burada “Sözlük” (Dictionary) olarak tabir edilen kavram, temel dalga biçimleri ya da atomların prototipi veya ana fonksiyonları topluluğudur.



Şekil 2.7. Seyrek Temsil

### 2.3.2.1. Seyrek Kodlama (Sparse Coding)

Seyrek kodlama bir sözlüğün (dictionary) bir kaç atomunun lineer bir kombinasyonu olarak bir sinyalin temsil edilmesini sağlar. Varsayılan sinyal  $x \in \mathbb{R}^m$  ve ölçümleri  $x_i$  olarak gösterildiğinde;

$$x = Da, \quad D \in \mathbb{R}^{m \times n}, \quad m < n \quad (2.10)$$

$m \ll n$  olduğundan Denklem (2.10) sonsuz sayıda çözümü kabul etmektedir. Denklem (2.10) için seçilen bir çözüm yoluna karşılık gelen denklem,

$$\tilde{a} = D^T(DD^T)^{-1}x \quad (2.11)$$

$D$ 'nin sözde devriğidir.

Denklem (2.11)'in çözümünün hesaplanması için popüler yöntemlerden biri de denklemin içerdiği en seyrek (sparsest) vektörün bulunmasıdır. En seyrek çözüm Denklem (2.12)'in çözümü ile bulunabilir.

$$\min_{\omega} \|\omega\|_1, D\omega = x \quad (2.12)$$

Buradaki en seyrek çözüm belirli koşulların gerçekleşmesine bağlı olduğundan zorlayıcıdır.

Çözüm için bir diğer yöntem ise Denklem (2.12)'de belirtilen yapıya ölçümleri bozan hata gürültüsünün eklenmesidir. Eklenecek gürültü  $\eta$  ve  $\|\eta\|_2 < \epsilon$  olduğunda, Denklem (2.13) elde edilir.

$$x = Da + \eta, \quad \|\eta\|_2 < \epsilon \quad (2.13)$$

Yukarıdaki problemi çözmek için farklı bir yöntem olarak da açgözlü takip (greedy pursuit) veya yinelemeli eşik algoritmaları kullanılabilir [36]. Bu tezde seyrek temsil yönteminin seyrek kodlama (sparse coding) kısmında açgözlü takip (greedy pursuit) algoritması olan G-SOMP+ algoritması [8] kullanılmıştır.

### 2.3.2.2. Sözlük Öğrenme (Dictionary Learning)

Sözlük (Dictionary); temel dalga biçimleri ya da prototip atomlar veya baz fonksiyonların bir koleksiyon biçimidir [37]. Sözlük Öğrenme (Dictionary Learning) tanım olarak; bir sözlüğün belirli bir amaca uyarlamak için

eğitilmesidir. Bu tanıma en güzel örnek seyrek temsil yöntemi için sinyallerin sınıflandırılmasıdır. Bu işlemten dolayı seyrek temsil için sözlük çok önemli bir gerekliliktir.

Önceden belirlenmiş bir sözlüğü kullanmaktan ziyade direkt olarak eğitilmiş bir sözlüğün öğrenilmesi genellikle daha iyi temsile yol açar ve bu nedenle yeniden yapılandırma, geliştirme ve sınıflandırma gibi birçok pratik görüntü işleme uygulamalarında geliştirilmiş sonuçlar tedarik etmemizi sağlar [38].

Seyrek temsil yönteminde verimli sonuçlar alabilmek için günümüzde birçok eğitim tabanlı sözlük tasarlama yaklaşımı geliştirilmiştir. Sözlük öğrenme metotlarındaki amaç, verilen örnek seti  $B = [x_1, \dots, x_i]$ , içerisindeki her örnek için en iyi temsili tedarik edecek sözlüğü bulmaktır. Bu problemi çözmek için Denklem (2.14)'deki eşitlik elde edilmiştir.

$$(\hat{D}, \hat{\Gamma}) = \arg \min_{D, \Gamma} \|B - D\Gamma\|_F^2 \quad \forall_i \|\gamma_i\|_0 \leq T_0 \quad (2.14)$$

Denklem (2.14)'de  $\gamma_i$ ,  $\Gamma$ 'ın her bir sütununu temsil eder [36]. Burada  $\|B - D\Gamma\|_F$  yerine  $\|A\|_F$  yazarsak Denklem (2.15)'yi elde ederiz.

$$\|A\|_F = \sqrt{\sum_{ij} A_{ij}^2} \quad (2.15)$$

Formül olarak gösterdiğimiz bu problemi optimize etmek çok zor olduğundan pratik olarak problem iki bölüme ayrılabilir.

- 1.) D'yi sabit tutup  $\|A\|_F$ 'yi bulma
- 2.)  $\|A\|_F$ 'yi sabit tutup D'yi bulma

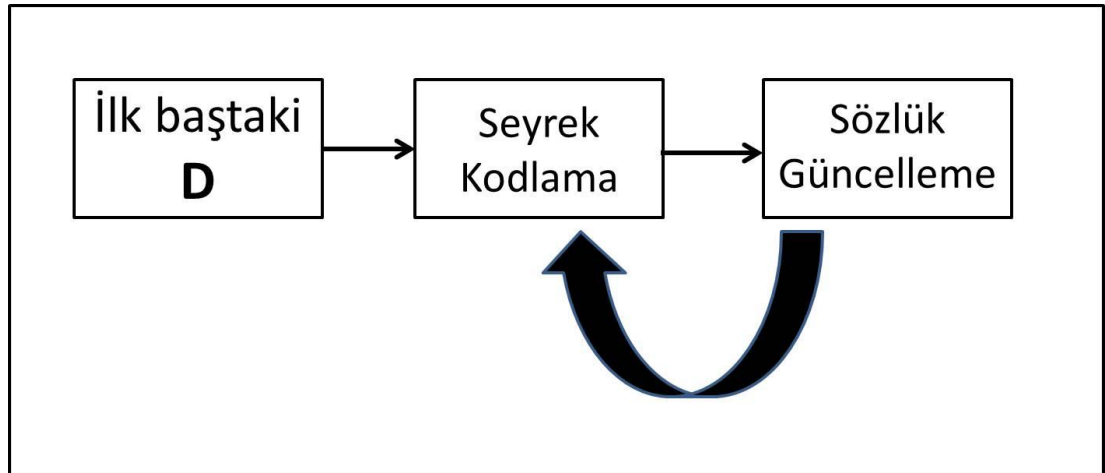
Bu tezde, yukarıda yer alan zorlu problemlerin çözümüne ulaşmak için sözlük öğrenme yöntemlerinden K-SVD (K-Singular Value Decomposition), ODL (Online Dictionary Learning) ve Bayes sözlük öğrenme algoritması kullanılmıştır.



### 2.3.2.2.1. K-SVD (K-Singular Value Decomposition) Sözlük Öğrenme Algoritması

K-SVD (K-Singular Value Decomposition/Tekil Değer Ayrışımı) algoritması, atomların çekirdeğinin güncelleme basamağını ve güncelleme işleminin K-kere tekrar edilmesiyle oluşur [38]. Bu algoritma, esnek olup bir takip algoritması ile bağlantılı olarak çalışır. Basit bir yapıya sahip olmakla birlikte tamamen K-Ortalama (K-means) algoritmasının genelleştirilmesiyle oluşturulmuştur. Kullanılacak sinyal başına bir atom ile çalışmak zorunda olduğundan kazanç şeklindeki vektörel niceleme için bir sözlük eğitilir. Kullanılan atom için bir birim katsayı elde etmeye çalışıldığında, tam olarak K-Ortalama algoritması üretilmiş olur. K-SVD algoritması, efektif bir seyrek kodlama ve Gauss-Seidel yöntemine benzer hızlandırılmış sözlük güncelleme metotları ele alındığında çok hızlı ve verimli çalıştırılabilir. K-SVD algoritmasının adımları birbirleriyle bağlantılı olup, genel amaç fonksiyonlarının minimizasyonu için çalışır [39].

K-SVD algoritması, geçerli bir sözlük öğrenme tabanına dayanan seyrek kodlama örnekleri ve sözlük atomlarının güncellenmesi işlemi arasında dönüşümlü bir iteratif yöntemdir.



Şekil 2.8. K-SVD basamakları.

Şekil 2.8.'de gösterildiği gibi, K-SVD yöntemi üç ana bölümden oluşmaktadır. Birinci bölüm, başlangıçta kullanılacak sözlük bölümü olup K-SVD yöntemi için oluşturulan ilk sözlüktür. İkinci adım, seyrek kodlama bölümüdür. Bu bölümde efektif bir seyrek kodlama tercih edildiğinde, K-SVD yöntemi yüksek verimli bir kapasiteye ulaşır. Son bölüm ise sözlük güncelleme safhasıdır. Başlangıç sözlüğü safhasında; optimize edilmiş seyreklik, diğer arzu edilen özellikler (normalize atomlar vb.) ve verilen örneklerle dayalı olarak bir sözlük öğretilir.

$$\min_{D,X} \|Y - DX\|_F^2 \quad \forall_i, \|x_i\|_0 \leq S \quad (2.16)$$

Denklem (2.16)'de yer alan model için;  $Y = [y_1 \dots y_P] \in \mathbb{R}^{N \times P}$ ; bilinen  $P$  öğretilmiş sinyal setini temsil eder.  $D \in \mathbb{R}^{N \times K}$ ;  $K$  atomları ile tasarlanmış bir sözlük matristir.  $X \in \mathbb{R}^{K \times P}$ ;  $S$  seyreklik seviyesi düzeyine sahip bir seyrek temsil matrisini ifade eder.

Seyrek kodlama safhasında, verilen güncel  $D$  sözlüğü ile  $X$  matrisinin seyrek temsili oluşturur. Bu safhadaki amacımız;  $X$  matrisinin en iyi katsayılarını bulmaktır. Bunun için Denklem (2.17) ve Denklem (2.18)'deki eşitlikler ele alınır.

$$\min_X \|Y - DX\|_F^2 \quad \forall_i, \|x_i\|_0 \leq S \quad (2.17)$$

$$\min_{x_i} \|y_i - Dx_i\|_2^2 \quad \forall_i, \|x_i\|_0 \leq S, i = 1, 2, \dots, P \quad (2.18)$$

Verilen bu seyrek kodlama problemlerini çözmek için OMP (Dikey Eşleştirme Takip Algoritması), BP (Temel Takip Algoritması) gibi bazı temel seyrek kodlama algoritmaları ve bu temel algoritmalarından türetilmiş seyrek kodlama algoritmaları (G-SOMP+ vb.) kullanılır.

Üçüncü safha olan sözlük güncelleme bölümünde amaç; başlangıçta kullanılan sözlük yerine en iyi sonucu almak için daha iyi bir sözlük bulmaktır. Öncelikle bir defada  $D$  sözlüğünün bir sütunu güncelleştirilir. Sonrasında  $d_k$

sütunu hariç D sözlüğünün tüm sütunları düzeltilir. Son olarak da, optimize edilmiş hedef fonksiyonu tarafından sözlük güncellenir.

Sözlük güncelleme adımına geçebilmek için Denklem (2.16)'da yer alan eşitlikten Denklem (2.19) eşitliği elde edilir.

$$\begin{aligned} \|Y - DX\|_F^2 &= \left\| Y - \sum_{j=1}^K D_j g_j^T \right\|_F^2 = \left\| \left( Y - \sum_{j \neq k} d_j g_j^T \right) - d_k g_k^T \right\|_F^2 \\ &= \|E_k - d_k g_k^T\|_F^2 \end{aligned} \quad (2.19)$$

Denklem (2.19)'da yer alan sözlük  $D = [d_1 d_2 \dots d_k] \in \mathbb{R}^{N \times K}$  ve k'inci atoma ulaşıldığındaki hata payı  $E_k = Y - \sum_{j \neq k} d_j g_j^T$ , katsayılar matrisi de  $X = [x_1 \dots x_p] = [g_1 g_2 \dots g_k]^T \in \mathbb{R}^{K \times P}$  olarak gösterilir.

D sözlüğünün k'inci atomunun güncellenmesi için  $\min_{d_k} \|E_k - d_k g_k^T\|_F^2$  ve  $E_k = Y - \sum_{j \neq k} d_j g_j^T$  eşitlikleri elde edilir.

Seyrekliği korumak için;  $d_k$  kullanarak sadece  $E_k$ 'nin sütunlarıyla ilgilenilir.

$$\min_{d_k, g_k} \left\| \dots E_k - d_k g_k^T \right\|_F^2$$

**Şekil 2.9.** Sözlük Güncelleme Formülasyonu.

K-SVD algoritmasında k'inci atomu kullanılarak Y içindeki sinyallerin indeksi olan  $I; I = (i_1, \dots, i_k)$ , I tarafından indekslenen A'nın alt matrisi  $A_t = [a_{i_1} \dots a_{i_k}]$  olarak gösterilir.

Güncelleme düzenlendiğinde Denklem (2.20) elde edilir.

$$\min_{\underline{d}_k, \underline{g}_k} \|Y_I - DX_I\|_F^2 = \|\underline{E}_k - d_k \underline{g}_k^T\|_F^2 \quad (2.20)$$

Denklem (2.20)'de yer alan  $\underline{E}_k = Y_I - \sum_{j \neq k} d_j X_{j,t}$  fonksiyonu k'inci atomsuz hata matrisini,  $\underline{g}_k^T = X_{k,l}$   $X_I$ 'ın içindeki k'inci satırı, yani  $X$  matrisinin k'inci satırının sıfır olmayan elemanlarını temsil eder.

İlk seviyedeki basit problem Denklem (2.21)'de eşitlikten çözülür.

$$\min_{\underline{d}_k, \underline{g}_k} \|\underline{E}_k - d_k \underline{g}_k^T\|_F^2 \text{ için } \|d_k\|_2 = 1 \quad (2.21)$$

Denklem (2.21)'deki hata payı  $\underline{E}_k = U\Delta V$  olarak, sözlükteki k'inci atom ise  $d_k = u_1$ ,  $\underline{g}_k = \sigma_1 v_1$  ile temsil edilir.

Aynı şekilde D sütununun tüm k atomları güncellendiğinde yeni bir sözlük elde edilmiş olur. Daha sonra bu yeni sözlük K-SVD algoritmasının tüm safhalarındaki işlemlerden geçer [39].

### 2.3.2.2.2. ODL (Online Dictionary Learning) Algoritması

Bu tez çalışmasında ODL algoritmasının tercih edilmesindeki sebep, bu algoritmanın iki önemli özelliğe sahip olmasıdır. Bunlardan biri, büyük ve dinamik veri setlerini ele alması, diğeri ise başka sözlük öğrenme yöntemlerinden daha hızlı olmasıdır. Bu özelliklerinden dolayı son dönemde ODL algoritmasının popülerliği artmakta ve SPAMS (SPARse Modeling Software) [40] MATLAB derleme paketi ile kullanıcılara kolaylık sağlamaktadır.

ODL algoritmasının işlem basamakları şu şekilde yer almaktadır. Öncelikle;

1.  $x \in IR^m \sim p(x)$  ve  $p$  rastgele değişken ve  $p$  örneklerini çizmek için algoritma,  $\lambda \in IR$  regülarizasyon parametresi,  $D_0 \in IR^{m \times k}$  başlangıç sözlüğü,  $T$  iterasyon numarası bilgilerine gereksinim duyulmaktadır.
2.  $A_0 \leftarrow 0, B_0 \leftarrow 0$  ilk önce geçmiş bilgiler sıfırlanır.  $t=1$  'den başlamak üzere  $T$  kadar iterasyona girilir.
3.  $x_t$  rastgele değişkeni ile  $p(x)$  örnekleri çizilir.
4. LARS-Lasso Algoritması kullanılarak seyrek kodlama yapılır.

$$a_t \triangleq \arg \min_{a \in IR^k} \frac{1}{2} \|x_t - D_{t-1}a\|_2^2 + \lambda \|a\|_1 \quad (2.22)$$

$$\begin{aligned} 5. \quad A_t &\leftarrow A_{t-1} + a_t a_t^T \\ B_t &\leftarrow B_{t-1} + x_t a_t^T \quad \text{yeterli istatistikler toplanır.} \end{aligned}$$

6. Bu safhada sözlük güncellemesi kısmına geçilir. Sözlük güncellemesi için ihtiyaç olan gereksinimler, giriş sözlüğü  $D = [d_1, \dots, d_k]$  ve denklem (2.23)'de yer alan eşitliklerdir.

7.

$$\begin{aligned} A &= [a_1, \dots, a_k] \in IR^{k \times k} = \sum_{i=1}^t a_i a_i^T \\ B &= [b_1, \dots, b_k] \in IR^{m \times k} = \sum_{i=1}^t x_i a_i^T \end{aligned} \quad (2.23)$$

8.  $j = 1$  den  $k$ 'ya kadar işlemler tekrarlanır.
9.  $j$ 'inci sütunu optimize etmek için güncellenir;

$$\begin{aligned} u_j &\leftarrow \frac{1}{A_{jj}} (b_j - D a_j) + d_j \\ d_j &\leftarrow \frac{1}{\max(\|u_j\|_2, 1)} u_j \end{aligned} \quad (2.24)$$

9. Yakınsamaya kadar bu işlem devam eder ve sonrasında güncellenmiş sözlüğe geri dönülür.

10. Denklem (2.23) ve denklem (2.24) kullanılarak  $D_{t-1}$  'den tekrar başlanarak  $D_t$  hesaplanır.

$$\begin{aligned} D_t &\triangleq \arg \min_{D \in C} \frac{1}{t} \sum_{i=1}^t \frac{1}{2} \|x_i - Da_i\|_2^2 + \lambda \|a_i\|_1 \\ &= \arg \min_{D \in C} \frac{1}{t} \left( \frac{1}{2} \text{Tr}(D^T DA_t) - \text{Tr}(D^T B_t) \right) \end{aligned} \quad (2.25)$$

11. Hesaplama bittikten sonra tekrardan öğrenilmiş sözlüğe dönülür [41].

Eğitim setlerinden meydana gelen dağılım örneklerini  $p(x)$  varsayarsak,  $p(x)$ 'in iç döngüsü tek bir seferde bir  $x(t)$  elemanı çizer, olasılıksal gradyanındaki azalma gibi ve bir önceki iterasyonda yer alan  $D_{t-1}$  sözlüğündeki  $x_t$  elemanının  $a_t$  dekompozisyonunu hesaplamak için klasik seyrek kodlama adımları alternatif olabilir. Bununla birlikte minimize edilmiş C tarafından hesaplanan  $D_t$  yeni sözlüğünün işleminin yapıldığı sözlük güncelleme adımları kullanılabilir. Bu işlem için kullanılan fonksiyon Denklem (2.26)'da yer almaktadır.

$$\hat{f}_t(D) \triangleq \frac{1}{t} \sum_{i=1}^t \frac{1}{2} \|x_i - Da_i\|_2^2 + \lambda \|a_i\|_1 \quad (2.26)$$

ODL algoritmasının bu adımdan önceki adımları boyunca, formüldeki  $a_i$  vektörü hesap edilir [41]. Böylelikle ODL algoritması ile sözlük öğrenimi gerçekleştirilmiş olur.

### 2.3.2.2.3. Bayes Sözlük Öğrenme Algoritması

Bu tez çalışmasında ele alınan üçüncü sözlük öğrenme yöntemi Bayes Sözlük Öğrenme Yöntemidir. Bayes tabanlı sözlük öğrenme yöntemi Zhou tarafından 2009 yılında ortaya atılmıştır [42]. Bu tezde, parametrik olmayan

Bayes Sözlük Öğrenme tabanlı Beta işlemi ele alınmıştır. Beta işlemi ilk olarak Hjort tarafından 1990 yılında öne sürülmüştür [43]. Bayes sözlük öğrenme yöntemi, seyrek temsil metodu için oldukça önemlidir. Geleneksel seyrek temsil metotları genellikle görüntü varyansı, seyreklik seviyesi ve düzenleme parametrelerinin bilgilerine ihtiyaç duymaktadır. Fakat parametrik olmayan Bayes sözlük öğrenme yönteminde, anılan bilgilere sahip olma gereksinimi yoktur [44]. Ayrıca tipik sözlük öğrenme yöntemlerinde; önceden tanımlanmış sözlük boyutu, tüm parçaları ve seyreklik seviyesi bilinmesi gerekmektedir. Ancak Bayes sözlük öğrenme yöntemlerinde bu gereksinim yoktur [45].

$\Omega$  ölçülebilir uzay,  $B$ 'de onun cebirsel ifadesi,  $H_0$ ,  $(\Omega, B)$ 'deki sürekli olasılık ölçüsü,  $\alpha$  pozitif skaler büyüklüğü olmak üzere bütün ayrımları ve sonsuz kısımları için Denklem (2.27) yazılabilir.

$$H(B_k) \sim \text{Beta}(\alpha H_0(B_k), \alpha(1 - H_0(B_k))) \quad (2.27)$$

Burada  $k$  değeri sonsuza giderken  $k=1 \dots K$  için  $H_0(B_k) \rightarrow 0$  dır. Böylelikle;  $H \sim \text{Beta}(\alpha H_0)$  olur.

Vektör sütunu  $z_i$ , sonsuz ve ikili  $k$ 'inci değeri için  $z_{ik}$  olduğunda; Bernoulli işlemi Denklem (2.28)'deki gibi olur.

$$z_{ik} \sim \text{Bernoulli}(\pi_k) \quad (2.28)$$

Buradan yola çıkarsak  $x_i(w) = \sum_k z_{ik} \delta_{wk}(w)$  yazılabilir. Tüm bu fonksiyonlar göz önüne alındığında Bernoulli işlemi için Denklem (2.29) yazılabilir.

$$x_i \sim \text{Bernoulli } P(H) \quad (2.29)$$

Sonsuz boyutsal vektörün düzenlenmiş örnekleri  $z_i$  olsun. Matris formatında  $Z = [z_1 \dots \dots z_N]$  olduğunda, Beta işlemi, her satır içindeki  $Z$  matrisinin  $\delta_w$  değerine karşılık geldiği sonsuz ikili matrislerin üzerinde önceden gerçekleştirdiği görülür [46].

Hiperspektral görüntüler için Bayes Sözlük Öğrenme yönteminde,  $Y^h$  hiperspektral görüntünün  $i$ 'inci pikseli  $y_i^h \in \mathbb{R}^L$  olarak gösterilir ve seyrek temsil gösterimi  $\beta_i^h \in \mathbb{R}^{|K|}$  olan  $\Phi$  sözlüğünün küçük hata payı  $\epsilon_i^h \in \mathbb{R}^L$  dir. Matematik olarak formülize edilmiş hali Denklem (2.30)'de yer almaktadır.

$$y_i^h = \Phi \beta_i^h + \epsilon_i^h$$

$$\pi_k \sim \text{Beta}(\pi_k | a_0/K, b_0(K-1)/K)$$

$$z_{ik} \sim \text{Bernoulli}(z_{ik} | \pi_{k0}) \quad (2.30)$$

$z_i \in \mathbb{R}^{|K|}$  ikili vektördür ve  $z_{ik}$  bu vektörün  $k$ 'ıncı bileşenidir.  $\pi_{k0}$  ise Bernoulli dağılımının  $k$ 'ıncı parametresidir.

Beta işleminin eşleniği olarak  $\pi_k$ 'nın yerine  $a_0$  ve  $b_0$  hiper parametreleri yerleştirilir. Burada "0" kullanılmasının sebebi, önceki dağılım parametrelerinden ayırt etmek içindir.  $z_i$  parametresi destek göstergesi vektörünü ifade eder ve  $z_{ik} = 1$  değeri ise  $k$ 'nıncı sözlük atomunun  $y_i$  uzantısına katılımını göstermektedir. Ayrıca,  $S_i \in \mathbb{R}^{|K|}$  nin her bir  $S_{ik}$  bileşeninin normal dağılımıdır.



## 3. ANALİZLER

### 3.1. Problemin Tanımlanması

Güncel hiperspektral görüntüler uzamsal çözünürlük açısından ciddi şekilde yoksundur. Bu sorun, hiperspektral sistemler tarafından alınan her spektral görüntünün çok dar bir spektrum penceresi olmasından kaynaklanmaktadır. Böylece sistem, spektral görüntülerin iyi bir sinyal-gürültü oranını sağlamak ve yeterince foton toplamak için uzun prosedürlere maruz kalmaktadır. Bu da hiperspektral görüntülerin düşük uzamsal çözünürlükte olmasına sebep olur. Normalde, uzamsal çözünürlük yüksek çözünürlüklü sensörler ile geliştirilebilir. Ancak bu çözüm, hem ekonomik açıdan hem de sensörlere ulaşan fotonların yoğunluğunu azaltmasından dolayı hiperspektral görüntüleme için efektif değildir. Donanım kısıtlamaları da göz önüne alındığında, hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmek için yazılım tabanlı teknikler geliştirmek gerekmektedir. Hiperspektral sistemlerle düşük çözünürlüklü görüntüleme sistemler karşılaştırıldığında, düşük çözünürlüklü sistemler büyük örneklemeli sahne radyansın performansından dolayı çoğu spektral bilgilerini kaybeder. Ancak bu sistemler, sahenin/görüntünün büyük uzamsal bilgilerini içerir. Bu sistemler tarafından elde edilen görüntü hiperspektral görüntülerin uzamsal çözünürlüğü iyileştirmesinde yardımcı olabilir. Bu çalışma hem Pan-keskinleştirme yöntemi ile hem de Seyrek Temsil tabanlı Süper Çözünürlük yöntemi ile hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirilebilir.

### 3.2. Hiperspektral Pan-Keskinleştirme Yöntemi ile İlgili Analizler

Hiperspektral sistemlerin varlığının artmasıyla, hiperspektral ve pankromatik görüntülerin füzyonu için Pan-keskinleştirme yöntemleri yaygın bir şekilde kullanılmaya başlanmıştır. Fakat hiperspektral Pan-keskinleştirme konusu

hala geliştirilmeye açık bir alandır ve sadece birkaç Pan-keskinleştirme yöntemi hiperspektral görüntüler için kullanılmak üzere literatüre geçmiştir. Yazılım tabanlı yaklaşımlardan pan-keskinleştirme yöntemi, genellikle hiperspektral görüntü ile yüksek çözünürlüklü pankromatik görüntünün kaynaştırılması ile uzamsal çözünürlüğü geliştirir. Bu işlem Pan-keskinleştirme olarak bilinir (pan-sharpening). Bu popüler teknik, hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmek için renk koordinatlarının doğrusal dönüşümünü kullanır. Aydınlatmanın hassasiyeti kullanılarak yüksek çözünürlüklü görüntünün aydınlatma bileşeni ile hiperspektral görüntüyü kaynaştırır.

Hiperspektral görüntülerin kompleks yapısından dolayı hiperspektral Pan-keskinleştirme yöntemleri tahmin edilebildiği üzere, multispektral görüntülere nazaran daha karmaşık bir işlemdir. Pankromatik ve multispektral görüntüler hemen hemen aynı spektral aralık içerisinde elde edilmesine rağmen, hiperspektral görüntülerin spektral aralığı, Pankromatik görüntülerin spektral aralığına göre çok daha geniştir. Genellikle Pankromatik görüntülerin spektral aralığı 0,4-0,8 $\mu$ m'dir. Hiperspektral görüntülerin spektral aralığı genellikle görünür kısa dalga kızılötesi (SWIR) yelpazesini kapsar. Örnek olarak Hyperion hiperspektral görüntü verileri 0,4-2,5 $\mu$ m aralığında elde edilir. 0,8-2,5  $\mu$ m aralığı Pankromatik görüntü tarafından kapsanamayacağından, tanımlanacak füzyon modeli efektif sonuçlar elde edilebilmesi konusunda zorluklar doğurmaktadır. Bu zorlukların en bariz örneği, ikili (dyadic) dalgacık dönüşüm yönteminin multispektral görüntülerde kullanılmasına rağmen hiperspektral görüntülerde kullanılamamasıdır [47] .

Hiperspektral görüntülerin multispektral görüntülere nazaran çok fazla spektral bilgiye sahip olması bu görüntülerin kullanılmak üzere seçilmesinde büyük bir avantaj sağlamıştır. Fakat ana avantajları yüksek spektral bilgiye sahip olması olan hiperspektral görüntülerin, pan-keskinleştirme yönteminin spektral bozulmaya yol açması füzyon işlemi için istenmeyen durumlara neden olmuştur.

### 3.3. Hiperspektral Seyrek Temsil Yöntemi ile İlgili Analizler

Seyrek temsil yöntemi ile diğer geliştirilen yöntemler karşılaştırıldığında, diğer yöntemlerin belirgin eksik tarafları ortaya çıkmaktadır. Örnek olarak, Uzamsal-Spektral görüntü füzyonu, hiperspektral görüntünün uzamsal çözünürlüğünü artırmak için, bir dizi Uzamsal katışım (Spatial Unmixing) metotları kullanır. Bu yöntemler, sadece iki görüntünün spektral çözünürlükleri farklı değilken iyi performans gösterir. Buna ek olarak bunların performansı son derece karışık işlemlerden dolayı zayıflar. Daha yakın zamanda matris ayrıştırma yöntemi, uzamsal çözünürlük ve uzaktan algılama hiperspektral görüntüleme sistemlerinin geliştirilmesinde önemli bir rol oynamıştır. Kawakami [50], yüksek uzamsal çözünürlüğe sahip RGB görüntü ile hiperspektral görüntünün, her bir görüntünün iki faktöre ayrıştırılmış ve bu iki ayrışımın tamamlayıcı faktörlerle birleşerek istenilen görüntüyü elde eden bir birleşme/kaynaşma önermiştir. Fakat bu yöntem için girişte kullanılan yüksek uzamsal çözünürlüklü görüntü ile girişte kullanılan hiperspektral görüntü arasındaki uzamsal dönüşümün ilk bilgilerine ihtiyaç vardır. Bu gereksinimler ve şartlar göz önünde bulundurulduğunda Seyrek Temsil tabanlı hiperspektral süper çözünürlük yöntemi hiçbir ön gereksinime ihtiyaç duymamaktadır ve anılan diğer yöntemlere nazaran daha pratiktir.

Bilindiği üzere donanım kısıtlamalarından dolayı hiperspektral görüntülerin uzamsal çözünürlüğünü arttırmak için yazılım tabanlı yaklaşımlara eğilim her geçen gün daha da artmaktadır. Ancak bu tarz yaklaşımlarda genel düşünce ve arzu edilen sonuç, kısa sürede minimum hata ile işlem yapabilmektir. Bunun için hali hazırda bulunan yaklaşımlar ile sonradan geliştirilen yaklaşımların birbirleriyle kıyaslanması son derece önemli bir hal almıştır. Bu sebepten dolayı, bu tez çalışmasında K-SVD, ODL ve Bayes Sözlük öğrenme tabanlı Seyrek Temsil Yöntemleri ele alınmıştır.

Ele alınan bu yöntemlerle problemlerin çözülebilmesi için izlenmesi gerekli bazı yollar vardır. Tanımlanan problemin çözümlenmesi için problemin formülasyonunun ortaya konulması gerekmektedir.

Önerilen yaklaşımlar, sahneye ilişkin yansıma spektrumlarını ayıklamak için hiperspektral görüntüyü kullanırlar. Hiperspektral görüntüye girdi yapılarak kısıtlı seyrek temsil problemi çözülür. Bu spektrumlar ile oluşturulan yüksek uzamsal çözünürlüklü görüntü, spektral büyüklüğüne göre temel forma dönüştürülür. Daha sonra söz konusu görüntü ve dönüştürülmüş temel, eş zamanlı olarak seyrek yaklaşım ve G-SOMP+ algoritması ile beslenir. Bizim kullandığımız algoritma Eşzamanlı Dikey Eşleştirme İzleme algoritmasının bir genellemesidir ve bu da çözüm alanı üzerinde olmayan olumsuzluklara kısıtlama getirmektedir. Sahne/Boyuttaki uzamsal yapıdaki avantajı, G-SOMP+'un seyrek kodlamayı verimli bir şekilde öğrenmesidir. Bu seyrek kodlama, hiperspektral görüntünün süper çözünürlüğünü hesaplamak için sahnenin/boyutun yansıma spektrumlarını kullanır. Bu yaklaşım nesnelerin hiperspektral görüntülerinde test edilmiştir. Bu testlerde farklı sözlük öğrenme metotları kullanılmış, elde edilmiş uzamsal çözünürlüğü iyileştirilmiş görüntülerin hata oranları birbirleriyle karşılaştırılmış olup, bu karşılaştırma sonucunda en az hata payına sahip ve en hızlı sonuç veren yöntem tespit edilmeye çalışılmıştır.

Elde edilmek istenilen süper çözünürlüklü hiperspektral görüntü  $S \in IR^{M \times N \times L}$  olup,  $S$  elde edilmek istenilen süper çözünürlüklü hiperspektral görüntüyü  $M$  ve  $N$  hiperspektral görüntünün uzamsal boyutunu,  $L$  hiperspektral görüntünün spektral boyutunu ifade etmektedir.

Uzamsal çözünürlüğünü geliştirmek için işlem yapılmak istenen hiperspektral görüntü  $Y_h \in R^{m \times n \times l}$ , işlem yapılmak istenilen hiperspektral görüntü ile aynı sahneye sahip olan yüksek uzamsal çözünürlüklü fakat düşük spektral çözünürlüğe sahip görüntü  $Y \in R^{M \times N \times L}$ , uzamsal çözünürlüğü geliştirmek için karşılaşılan problem  $m \ll M, n \ll N$  ve  $l \ll L$  olmasıdır ki, bu da birçok ölü piksele neden olmaktadır.

Mevcut olan her iki görüntü ile elde edilmek istenilen görüntünün lineer eşleşmesi yapılmak istenirse Denklem (3.1) elde edilir.

$$Y = \psi(S) , Y_h = \psi_h(S) \quad (3.1)$$

Burada  $\Psi: R^{MXNXL} \rightarrow R^{MXNXl}$  ve  $\Psi_h: R^{MXNXL} \rightarrow R^{mXnXL}$  temsil etmektedir. Tipik yer görüntülerinin yanı sıra uzaydan veya havadan çekilen görüntüler sadece küçük sayıda farklı materyal içerirler [31]. Eğer görüntüdeki sahne  $q$  materyalleri içeriyorsa, LMM (Lineer Karışım Modeli) [48],  $Y_h$  görüntüsünün bir pikseli olan  $y_h \in R^L$  için yaklaşık olarak kullanılabilir. Bu yaklaşım Denklem (3.2)'de temsil edilmektedir [8].

$$y_h \approx \sum_{\omega=1}^c \varphi_{\omega} \alpha_{\omega}, c \leq q \quad (3.2)$$

Denklem (3.2)'de yer alan,  $\varphi_{\omega} \in R^L$  sahne içindeki  $\omega$ 'ncü farklı materyalin yansımasını,  $\alpha_{\omega}$  piksel ile irtibatlı olan alandaki farklı materyallerin kesirsel-fraksiyonel bolluğunu ifade eder.

Formül matris formatında yeniden yazılmak istenirse Denklem (3.3) şeklinde elde edilir.

$$y_h = \Phi \alpha \quad (3.3)$$

Denklem (3.3)'de yer alan,  $\Phi \in R^{L \times c}$ 'in sütunları esas materyalin yansıyan vektörlerini,  $\alpha \in R^c$  katsayı vektörünü temsil etmektedir.  $y_h$  pikseli tarafından temsil edilen sahne,  $\mathbf{Y}$  görüntüsünün  $y \in R^L$  pikseline karşılık olan alanı içerir. Burada  $y$  pikseli yaklaşık olarak Denklem (3.4) gibi temsil edilir.

$$y \approx (T\Phi)\beta \quad (3.4)$$

Denklem (3.4)'de yer alan,  $T \in R^{L \times L}$  transfer fonksiyonu,  $\beta \in R^c$  katsayı vektörünü temsil etmektedir. Yukarıdaki formülde,  $T$  yüksek dereceli noksan dikdörtgen matrisidir, bu matris yüksek uzamsal çözünürlüğe sahip görüntüleme sisteminin hiperspektral görüntüleme sisteminin spektral nicelemesiyle alakalıdır.

Bu bağıntıyı kullanarak Denklem (3.5) elde edilir.

$$y \approx (T\Phi) \approx Ts \quad (3.5)$$

Denklem (3.5)'de yer alan  $s \in \mathbb{R}^L$ , S hedef görüntüsünün içindeki pikseli göstermektedir. Formülde eğer  $\Phi$  biliniyorsa, uygun katsayı matrisi kullanılarak ve yüksek dereceli matris olan T'nin tersi alınmadan, elde edilmek istenilen süper çözünürlüklü hiperspektral görüntü tahmin edilebilir.

$D$ ,  $\mathbb{R}^L$  içindeki birim-norm vektörlerinin sonlu bir kümesi olsun. Önerilen çözümde  $D$ ; atomları  $\varphi_\omega$  tarafından belirlenen,  $\Omega$  dizin kümesi üzerindeki  $\omega$  aralıklarının bulunduğu bir sözlüktür. Matematiksel olarak göstermek gerekirse şu şekilde yazılabilir.

$$D \equiv \{\varphi_\omega : \omega \in \Omega\} \subset \mathbb{R}^L \quad (3.6)$$

D sözlüğünden  $\Phi$  matris formu Denklem (3.7)'de yer alan eşitlik olarak yazılabilir.

$$\bar{Y}_h \approx \Phi A \quad (3.7)$$

Denklem (3.7)'de  $\bar{Y}_h \in \mathbb{R}^{L \times mn}$ , katsayı matrisi olan A'nın i'inci sütunu olan  $a_i$  ve odaklanılan  $Y_h$  hiperspektral görüntünün piksellerinin matris formunu temsil eder.

Önerilen çözümde  $k > q$  olmak koşuluyla  $\mathbb{R}^{L \times k}$  'dan  $\Phi$  yazılabilir. Çünkü denklem (3.2)'deki LMM, materyalin yansımalarının lineer karışımı varsayılan bir pikselin yaklaşımıdır. Gerçek hayatta, birden fazla ışık saçılması ve hatta çok fazla materyalin karışımı gibi olağanüstü durumlar spektral imzaların lineer olmayan karışımına neden olmaktadır [48]. Bu genellikle bir malzemenin yansıtma spektrumunu değiştiren veya sahne içindeki aynı malzemenin birden çok farklı yansıtma spektrumları ile sonuçlanır.  $\Phi$  matrisi aynı zamanda bu spektrumları açıklamalıdır. Bundan dolayı  $\Phi$  matrisi için "sözlük" terimi kullanılmaktadır. Aslında  $\Phi$  matrisi, sentetik bir sözlük matrisidir. Fakat bu tezde ODL ve K-SVD ve Bayes sözlük öğrenme yöntemleri tercih edildiğinden, bu yöntemler sentetik sözlük matrisinden küçük farklılıklar gösterebilmektedir. Denklem (3.7)'ye göre  $\bar{Y}_h$ 'in her sütunu, çok küçük sayıdaki sözlük atomlarından oluşturulmuştur. Ayrıca, yansıma

spektrumlarına karşılık gelen vektörler, sözlük atomlarının negatif olmayan vektörleridir. Bu sebepten, önerilen öğrenilmiş  $\Phi$  sözlük matrisi, önerilen seyrek temsil yaklaşımının çözümü için Denklem (3.8) kullanılır.

$$\min_{\Phi, A} \|A\|_1 \text{ s. t. } \|\bar{Y}_h - \Phi A\|_F \leq \eta, \varphi_\omega \geq 0, \forall \omega \in \{1, \dots, k\} \quad (3.8)$$

Denklem (3.8) 'de yer alan,  $\|\cdot\|_1$   $l_1$  matrisini,  $\|\cdot\|_F$  Forbenious matrisinin örneğini,  $\eta$  modelleme hatasını göstermektedir.  $\Phi$  matrisi bilindiğinden, denklem (3.5)'de önerildiği gibi  $B \in \mathbb{R}^{k \times MN}$  katsayı matrisinin, hedef görüntü olan  $S$ 'yi değerlendirmek için uygun şekilde hesaplanması gerekmektedir. Bu matris, önceki bilgilerden önemli iki bölüm ile birlikte öğrenmiş sözlük ve  $Y$  görüntüsü kullanılarak hesaplanır.

Bu bilgiler;

(a) Yüksek çözünürlüklü görüntüde, aynı sahne içindeki birbirine yakın pikseller aynı materyal olarak temsil edilir. Bu sebepten, aynı sözlük atomlarından oluşturulan küçük grup tarafından bu pikseller doğru tahmin olarak değerlendirilmelidir.

(b) Aynı sahne içindeki spektral sinyal kaynağının kesirsel fazlalığı  $B$  elementi tarafından temsil edildiği için,  $B$  elementi negatif olmayan miktarlarda olmalıdır.

Denklem (3.8) içinde yer alan  $A$  için (b) bölümündeki bilgi kullanılır. Fakat çözüme gitmek için denklem içerisinde sadece  $\Phi$  matrisi ile ilgilenildiğinden  $A$ 'yı negatif olmayan sınırlandırma içine sokmak gereksizdir. Bundan dolayı, bu sınırlandırma göz ardı edilerek çözüme gitmekte büyük bir avantaj sağlanmış olunur.

Çözüm için (a) bölümündeki bilgi göz önüne alınırsa, katsayıları matrisini hesaplamak için küçük ayırık uzamsal düzeltmeler bakımından  $Y$  görüntüsünde işlemler yapılır. Her bir yapılan düzeltmeler eklenti  $P \in \mathbb{R}^{M_p \times N_p \times l}$  ve kendisine tekabül eden katsayı matrisi  $B_p \in \mathbb{R}^{l \times M_p \times N_p}$

şekilden gösterilir. Çözüm için tespit edilen eş zamanlı seyrek yaklaşım problemi Denklem (3.9)'da yer almaktadır.

$$\min_{B_P} \|B_P\| \quad s. t. \quad \|\bar{P} - \tilde{\Phi} B_P\|_F \leq \varepsilon, \quad \beta_{pi} \geq 0 \quad \forall i \in \{1, \dots, M_P N_P\} \quad (3.9)$$

Denklem (3.9)'da yer alan,  $\bar{P} \in \mathbb{R}^{L \times M_P \times N_P}$  formu P eklentisi içindeki piksellerin konsatresini,  $\tilde{\Phi} \in \mathbb{R}^{L \times k}$  formu dönüştürülmüş sözlüğü (denklem (3.4)'de yer alan şekliyle uyarlanmış hali olan  $\tilde{\Phi} = T\Phi$ ),  $\beta_{pi}$  formu  $B_P$  matrisinin i'inci sütununu temsil etmektedir.

Denklem (3.9) 'da yer alan problem, zorlayıcı ve kompleks bir yapıya sahip olduğundan bu problemin çözümünde açgözlü takip stratejisi [49] uygulamak kompleks yapıdaki problemin çözümünü kolaylaştırmış olur. Problemdeki hesaplama karmaşası, kompleks ve zorlayıcı işlemlerin mevcudiyetinden dolayı, bu tezde problem çözümü için bir açgözlü takip algoritması olan G-SOMP+ algoritması (Genellemeli Eşzamanlı Ortogonal Eşlemeli Takip Algoritması) tercih edilmiştir.

G-SOMP+ algoritmasının işlem basamakları şu şekilde yer almaktadır [8].

1. İterasyon:  $i = 0$
2. İlk çözüm:  $B^0 = 0$
3. İlk kalıntı:  $R^0 = \bar{P} - \tilde{\Phi} B^0 = \bar{P}$
4. İlk indeks seti oluşturma
5. Ana iterasyon :  $i = i + 1$
6. Sözlükteki negatif olmayan elementleri hesaplama:

$$B^i = \min \|\tilde{\Phi} B - \bar{P}\|_F^2$$

7. Kalıntının hesaplanması  $R^i = \bar{P} - \tilde{\Phi} B^i$



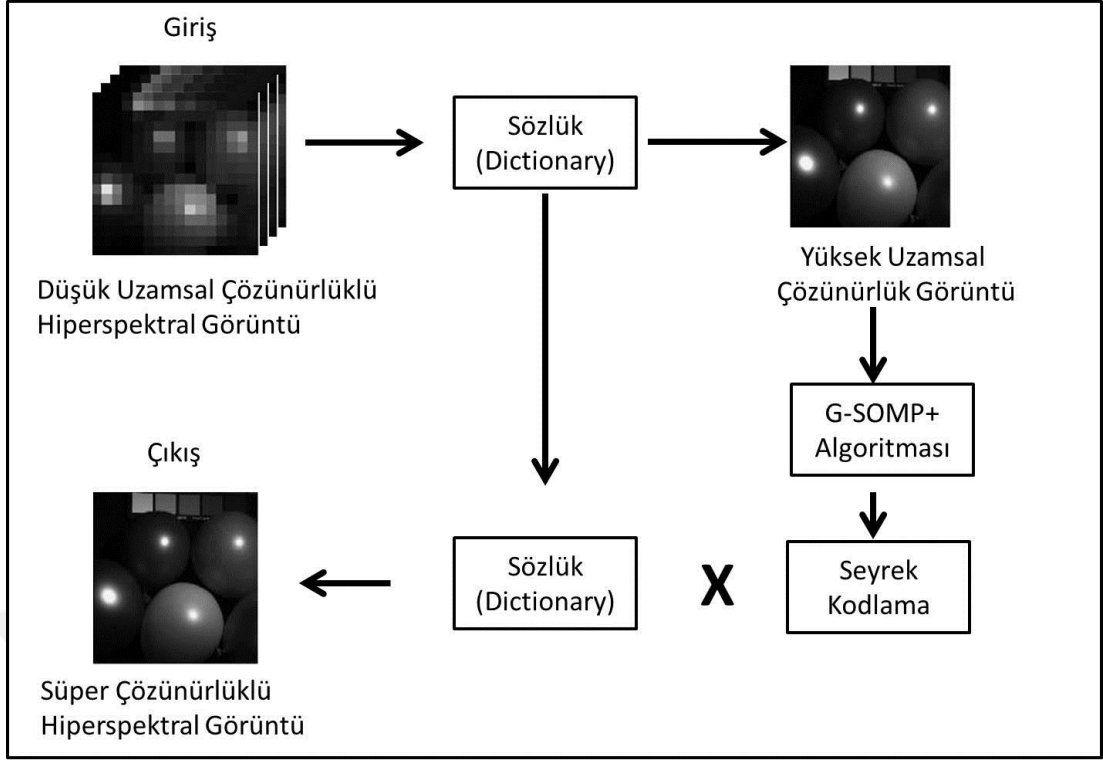
8. Eğer kalıntı  $\|R^i\|_F > \gamma\|R^{i-1}\|_F$  ise bitirilir, aksi takdirde iterasyona devam edilir.

G-SOMP+ algoritmasının SOMP (Eşzamanlı Ortogonal Eşlemeli Takip) algoritmasından önemli üç farkı vardır.

- (1) Tüm korelasyonların birleştirilmesi yerine, G-SOMP+ sözlük atomu ile kalan/artan vektörlerin korelasyonlarını toplar.
- (2) Standart en küçük kareler yaklaşımını kullanmak yerine, negatif olmayan en küçük kareler yöntemi ile her iterasyondaki parçayı (patch) birleştirir.
- (3) Yalnız bir sözlük atomu yerine her bir iterasyondaki sözlük atomlarını seçer.

Bu üç maddede bahsedilen farklılıkta; Denklem (3.1) ve Denklem (3.2)'de istenilen korelasyon matrisinin, negatif olmayan kısıtlamasını empoze eder. Diğer bir yandan, Denklem (3.3)'üncü maddede esas olarak algoritmanın zamanının hesaplanması hedeflenir. G-SOMP+ algoritmasında SOMP algoritmasından farklı durdurma kriterleri kullanılır, bu kalan çürük parametre olan  $\gamma$  tarafından kontrol edilir. G-SOMP+ algoritması denklem (3.9)'daki eşzamanlı seyrek yaklaşımın sınırlandırma çözümünü önerir. Bundan dolayı G-SOMP+ algoritması kapsamlı açgözlü takip algoritması (örneğin SOMP)'dan daha iyi bir şekilde parça (patch) yaklaşımı yapabilir. Her bir görüntü parçası için denklem (3.9)'un çözümü,  $\Phi$  ile birlikte  $\hat{S} \in \mathbb{R}^{L \times MN}$ 'yi hesaplamada kullanılan B arzu edilen korelasyon matrisi, bu matris formundaki  $\bar{S} \in \mathbb{R}^{L \times MN}$  hiperspektral süper çözünürlüklü görüntünün tahminidir. Bu matris kullanılarak elde edilmek istenilen süper-çözünürlüklü hiperspektral görüntünü Denklem (3.10)'deki eşitlik olarak ifade edilir.

$$\hat{S} = \Phi B \quad (3.10)$$

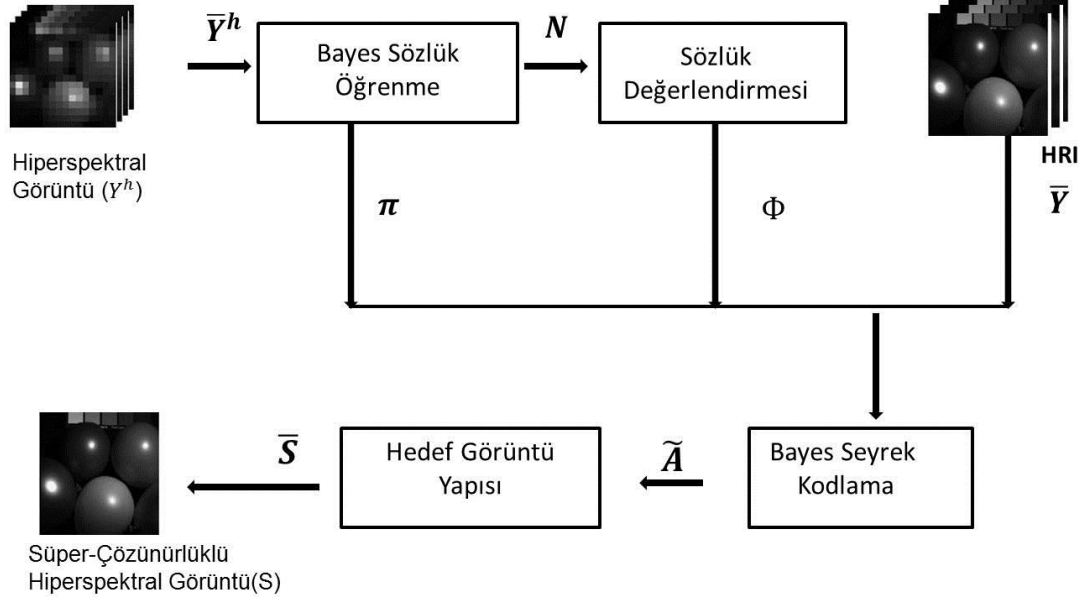


**Şekil 3.1.** Seyrek Temsil Tabanlı Hiperspektral Süper Çözünürlük Algoritması.

Şekil 3.1’de gösterildiği gibi, düşük uzamsal çözünürlüğe sahip hiperspektral görüntü atomların yansıma spektrumunu temsil eden bir sözlüğün öğrenimi için kullanılır. Bu sözlük, dönüştürülmüş ve kısıtlı bir eşzamanlı seyrek yaklaşım sorununu çözerek, seyrek kodu öğrenmek için yüksek uzamsal düşük spektral bilgiye sahip görüntü ile kullanılır. Seyrek kodlama (Sparse Coding) süper çözünürlüklü hiperspektral görüntüyü tahmin etmek için görüntünün orijinal sözlüğü ile birlikte kullanılır.

K-SVD ve ODL sözlük öğrenme tabanlı seyrek temsil yöntemlerine nazaran, Bayes sözlük öğrenme tabanlı seyrek temsil yönteminde bazı farklılıklar bulunmaktadır.

Anılan yöntem, düşük uzamsal çözünürlüğe sahip hiperspektral görüntü ile yüksek uzamsal çözünürlüğe sahip aynı sahnenin görüntüsünün birbiriyle kaynaştırılmasından oluşmaktadır. Bu işlem Şekil 3.2’de gösterildiği gibi dört safhadan oluşmaktadır.



**Şekil 3.2.** Bayesian Seyrek Temsil Tabanlı Hiperspektral Süper Çözünürlük Algoritması.

Birinci safhada, görüntüde gösterilen oranda Bernoulli dağılımı seti ve sahne içerisindeki materyalin spektral yansımaları için muhtemel dağılımın çıkarımı yapılır. İkinci safhada, yüksek çözünürlüklü görüntünün spektral miktar ölçüsünü ayarlamak için bir sözlük değerlendirilir ve dönüşümü yapılır. Üçüncü aşamada ise, dönüştürülmüş sözlük ve Bernoulli dağılımı, yüksek çözünürlüklü görüntünün seyrek kodunu hesaplamak için kullanılır. Bu amaçla, Beta metoduyla öğrenilen Bayes sözlükleri ile kullanılmak üzere genel Bayes seyrek kodlama stratejisi önerilir [46]. Bu tezde teorik olarak analiz edilen stratejinin doğru sonuç verdiği uygulama yapılarak öğrenilmiştir. Önerilen seyrek kodlama stratejisi uygulamada kullanılarak süper çözünürlük hiperspektral görüntü oluşturmak için derlenen sözlük ile birlikte kullanılır. Önerilen yaklaşım sadece CAVE data setinde yer alan görüntüleri iyileştirmede kalmayıp, aynı zamanda tipik optimizasyon temelli yaklaşımlar üzerindeki parametrik olmayan Bayes çerçevesinin avantajlarını da korur [8], [50], [51], [52].

Şekil 3.2.'de gösterilen Bayes Sözlük Öğrenme kısmı, sözlük atomları ve destek gösterge vektörlerinin üzerindeki parametrik olmayan dağılım setlerini

ifade etmektedir. Sözlük değerlendirme kısmında, “ $\Phi$ ” sözlüğü, yüksek çözünürlüklü “ $Y$ ” görüntüsünün spektral nicelemesine göre değerlendirilir ve dönüştürülür. Bayes Seyrek Kodlama kısmında, dönüştürülmüş olan sözlük ve destek göstergesi, vektörlerin üzerinde dağılımları  $Y$  görüntüsünün seyrek kodlaması için kullanılır. Hedef görüntü yapısını oluşturma kısmında ise kodlar, hedef süper çözünürlüklü görüntü oluşturmak için kullanılır.

Girişte kullanılacak olan  $Y^h \in \mathbb{R}^{m \times n \times L}$  düşük uzamsal çözünürlüklü hiperspektral görüntünün  $L$  boyutu, spektral çözünürlüğünü göstermektedir. Düşük uzamsal çözünürlüğe sahip hiperspektral görüntü ile aynı sahneye sahip yüksek uzamsal çözünürlüklü görüntünün boyutları  $Y \in \mathbb{R}^{M \times N \times l}$  olsun. Yüksek uzamsal çözünürlüğe sahip olan görüntünün uzamsal boyutları  $M \gg m$  ve  $N \gg n$  olması gerekmektedir. Bunun tam tersi olarak da yüksek uzamsal çözünürlüğe sahip görüntünün spektral boyutunun  $l \ll L$  olması gerekmektedir. Bu şekilde yüksek uzamsal çözünürlüğe sahip  $Y$  ile düşük uzamsal çözünürlüğe sahip hiperspektral görüntünün füzyonunun sonucunda,  $S \in \mathbb{R}^{M \times N \times L}$  boyutlarına sahip süper çözünürlüklü hiperspektral görüntü elde edebiliriz.

Kullanılan hiperspektral görüntüdeki her bir pikselin  $L$  boyutunda bir spektral imzası bulunmaktadır. Bu spektral imzalar, hesaplamalarımızda matris sütunu olarak kabul edilir. İlk adım olarak, giriş spektrumları görüntülenen sahnede “ $K$ ” spektral olarak materyallerin, karşılıklı “ $K$ ” dağıtımlarının bir dizisi öğrenilir. Ardından  $\Phi$  sözlüğü, spektrumları üzerine öğrenilen dağılımları kullanılarak hesap edilir. Elde edilen Bernoulli dağılımları, dönüştürülmüş sözlüğün üzerinden yüksek çözünürlüklü görüntüyü kodlamak için kullanılır.

Burada;  $\Phi \in \mathbb{R}^{L \times K}$  sözlüğü,  $k \in K = \{1, \dots, K\}$  kardinal sayılar setine sahip  $\varphi_k$  sütununun olduğu bir matristir.

Her bir sütunu işleme sokulan hiperspektral görüntü  $Y^h$ ’in pikselleri ve  $B \in \mathbb{R}^{K \times m \times n}$  katsayı matrisi tarafından düzenlenen bir  $\bar{Y}^h$  matrisi oluşturulur.

$$\bar{Y}^h = \Phi B \quad (3.11)$$

Temel vektör olan  $\varphi_k$  görüntü sahnesi içerisindeki farklı materyallerin spektral yansımalarını ifade etmektedir. Bu sebepten dolayı  $K > L$  ihtimalini de göz önüne almak gerekir. Ancak normalde  $K \ll mn$  olduğu için, genellikle çok az miktarda spektral olarak farklı materyalleri kapsar.

Bir katsayı matrisi olan  $A \in \mathbb{R}^{K \times MN}$  ve yüksek çözünürlüklü görüntü olan  $Y$ 'nin pikselleri tarafından düzenlenmiş  $\bar{Y} \in \mathbb{R}^{L \times MN}$  tarafından oluşturulan  $\bar{Y} = \bar{\Phi}A$  gibi  $\hat{\Phi} \in \mathbb{R}^{L \times K}$  oluşturulur. Oluşturulan bu  $\hat{\Phi} \in \mathbb{R}^{L \times K}$  sözlük, hesaplanan başlangıç sözlüğünün yüksek çözünürlüklü görüntüye göre dönüştürülmüş hali olmaktadır. Ayrıca bu dönüştürülmüş sözlük  $K$  kardinal sayılar setine de endekslenmiş olur. Yukarıdaki formüllerden  $Y$  yüksek çözünürlüklü görüntünün pikselleri ile  $Y^h$  işleme sokulan hiperspektral görüntünün pikselleri, başlangıç sözlüğü  $\Phi$  ve hesaplanan sözlüğün  $\hat{\Phi}$  yaklaşık seyrek temsili olarak kabul edilir. Bunun sebebi ise, bir pikselin genel olarak, tüm görüntüden daha az spektral bilgiye sahip olmasıdır. Bunun yanı sıra, görüntüdeki sahne içerisindeki farklı materyallerin sayısının spektral olarak varlığına bağlı olarak, farklı sahnelerdeki  $K$  değeri büyük fark gösterebilir. Sözlüğün sütunlarına sözlüğün atomları, tamamlayıcı katsayı matrisine ( $A$  vb.) ise seyrek kodlama matrisi denilmektedir.

Bayes Sözlük öğrenme safhasında;  $i^{th}$ ;  $Y^h$  hiperspektral görüntüsündeki her bir pikseli temsil eder ve  $y_i^h \in \mathbb{R}^L$  dir. Kabul edilen seyrek temsil  $\beta_i^h \in \mathbb{R}^K$  ve  $\Phi$  sözlüğünün küçük hatası  $\epsilon_i^h \in \mathbb{R}^L$  dir. Matematiksel olarak ifade ettiğimizde, denklem (3.12)'yi elde ederiz [9].

$$y_i^h = \Phi \beta_i^h + \epsilon_i^h \quad (3.12)$$

### 3.4. Yöntemlerin Karşılaştırılması için Kullanılan Parametreler

#### 3.4.1. RMSE (Ortalama Karekök Karesel Hata)

Elde edilen görüntülerden her ne kadar görsel olarak ayırt edilebilir sonuçlar elde edilse de, nicel değerlendirme ve diğer yöntemlerle karşılaştırma yapabilmek için RMSE (Root Mean Square Error/Ortalama Karekök Karesel Hata) hesabı kullanılmıştır.

$$RMSE = \sqrt{\frac{\sum \|I - \hat{I}\|^2}{LMN}} \quad (3.13)$$

Bu tezde kullanılan yöntemler arasında karşılaştırma yapabilmek için kullanılan RMSE değeri Denklem (3.13)'de yer almaktadır.

Denklem (3.13)'de yer alan;  $I$  gerçek yer görüntüsünü (yüksek uzamsal düşük spektral çözünürlüğe sahip görüntü),  $\hat{I}$  Seyrek Temsil tabanlı süper-çözünürlüklü hiperspektral görüntüyü,  $M \times N$  görüntünün uzamsal boyutlarını,  $L$  görüntünün spektral boyutunu temsil etmektedir.

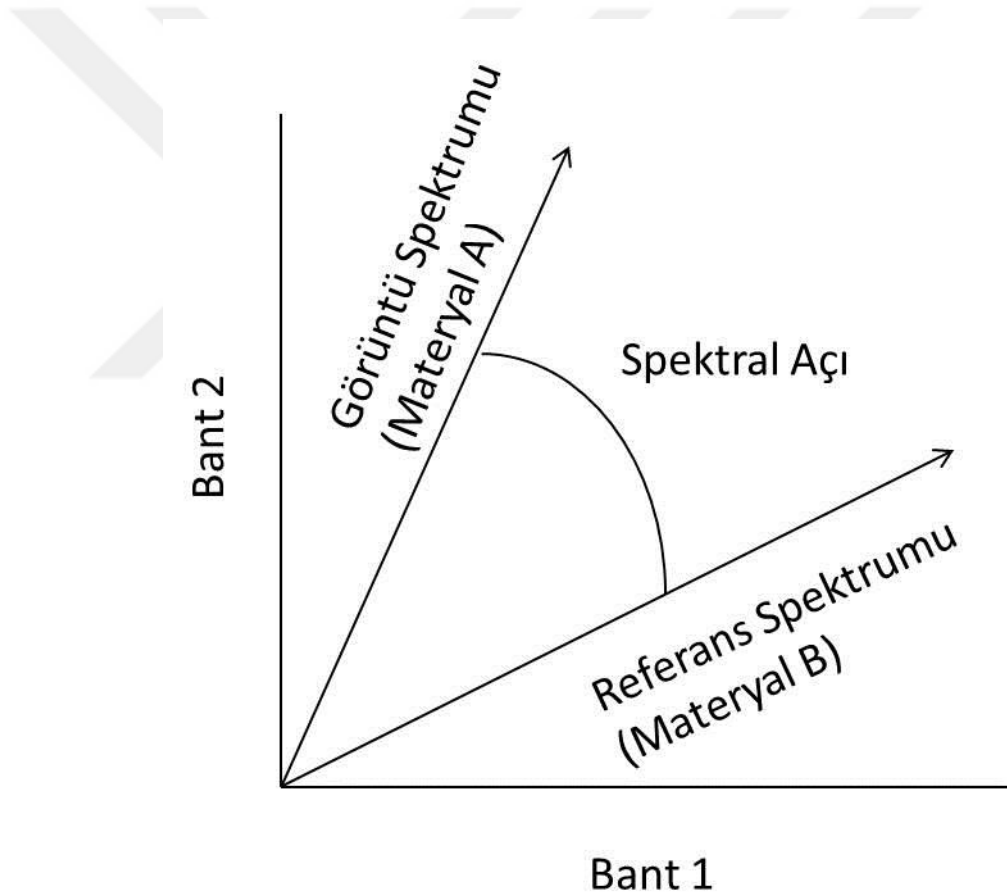
Burada yer alan uzamsal ve spektral boyutlara ek olarak birçok parametre RMSE değerine etki etmektedir. Bu parametreler; kullanılan sözlükteki atomların sayısı, her bir iterasyondaki seçilen atomlar, modelleme hatası ve artık bozuk parametrelerdir. Sözlük içerisindeki atom sayısı, orijinal ve süper çözünürlüklü görüntü arasında RMSE değeri ile doğrudan orantılıdır.

Genel olarak, açgözlü takip algoritmasında kullanılan, gerekli olan iterasyonun tam sayısının önceden bilinmesi zordur. Aynı şekilde, eğer artık hata, durdurucu kriter olarak kullanılırsa tüm görüntüler için bu parametrenin en iyi değerini bulmak, iterasyon sayısını bulmak kadar güç ve zorlayıcı olmaktadır. Bundan dolayı bu tezde yapılan uygulamalarda G-SOMP+ algoritması için durdurma kriteri olarak artık bozuk parametre kullanılmıştır. Çünkü kullanılan algoritmada her bir iterasyonda sabit atom sayısı seçilir ve eğer daha önceki iterasyondaki artığın kesiri son kullanılan

iterasyonunkinden daha fazla ise algoritma durur. G-SOMP+ algoritmasında kullanılmak üzere artık bozuk parametre  $\gamma = 0.99$  seçilmiştir.

### 3.4.2. SAM (Spektral Açı Eşleyicisi)

Spektral Açı Eşleyicisi (SAM) algoritması, iki spektrum arasındaki spektral benzerlik ölçümüne dayanmaktadır. Spektral benzerlik, bant sayısı  $q$  olan  $q$ -boyutlu bir uzayda, vektör gibi dikkate alınan spektrumlar tarafından elde edilir. SAM algoritması, iki spektrum arasındaki açıyı hesaplayarak spektrumlar arasındaki benzerliği tayin eder.



**Şekil 3.3.** SAM Referans Açı Gösterimi.

Şekil 3.3.'de SAM algoritmasının geometrik olarak referans açısı gösterimi yer almaktadır. Bu gösterimde anlaşıldığı gibi SAM değerini bulmak için öncelikle

referans spektrum tayin edilmelidir. Vektör olarak göz önüne alınan referans spektrum, ilgili hiperspektral görüntünün herhangi bir işleme uğramamış halinin spektrumudur. İşlem sonrası spektrum ise, hiperspektral görüntünün süper-çözünürlük işlemi sonrasında elde edilen görüntünün spektral değerinin vektörel gösterimidir [53].

SAM algoritması, gerçek ve işlem yapıldıktan sonra elde edilen görüntü arasındaki spektral distorsiyonu hesaplamak için kullanılır.  $\hat{x}_n$  ve  $x_n$  sırasıyla süper-çözünürlüklü hiperspektral görüntü ve işlem öncesi gerçek hiperspektral görüntünün vektörleri olduğu düşünüldüğünde SAM algoritması;

$$SAM(\hat{x}_n, x_n) = \arccos\left(\frac{\langle \hat{x}_n, x_n \rangle}{\|\hat{x}_n\|_2 \|x_n\|_2}\right) \quad (3.14)$$

Denklem (3.14)'de;  $\langle \dots \rangle$  skaler çarpımı,  $\|\cdot\|$  ise  $l_2$  normunu göstermektedir. Tüm görüntüdeki toplam SAM değeri, görüntüdeki tüm piksellerin SAM değerinin ortalaması alınarak elde edilir. SAM değeri, derece olarak ifade edilir ve  $[-90,90]$  arasında bir değerdir. Optimum SAM değeri 0'dır. SAM değeri büyüdükçe elde edilen görüntüdeki spektral bozulmanın fazla olduğu anlaşılır.

### 3.4.3. İşlem Zamanı

Kullanıcılar genellikle kompleks olmayan ve kısa sürede sonuca ulaşabileceği yöntemleri tercih ettiğinden dolayı bu parametre gündeme gelmiştir. Bu tez çalışmasında işlem zamanı, MATLAB programında yazılımı hazırlanan yöntemin hiperspektral görüntüyü ne kadar sürede işlediğini göstermek için saniye cinsinden bir parametre olarak kullanılmıştır. İşlem zamanı, yöntemler arasında karşılaştırma yapmak için kullanılan temel parametrelerden biridir. CAVE veri tabanında yer alan her bir veri setinin ilgili yöntemin uygulanmasının aldığı süre ölçülmüştür.



#### 4.DENEYSEL SONUÇLAR

Bu tezde; uzaktan algılama ile elde edilen hiperspektral görüntülerin azlığı, erişim kısıtlamaları ve aynı sahnenin düşük spektral ve yüksek uzamsal çözünürlüğe sahip görüntüsünün elde edilme zorluğundan dolayı, uzaktan algılama sistemlerinden elde edilen hiperspektral görüntüler kadar iyi olduğu değerlendirilen yersel hiperspektral görüntü veri tabanı olan CAVE veri tabanı [54] kullanılmıştır.

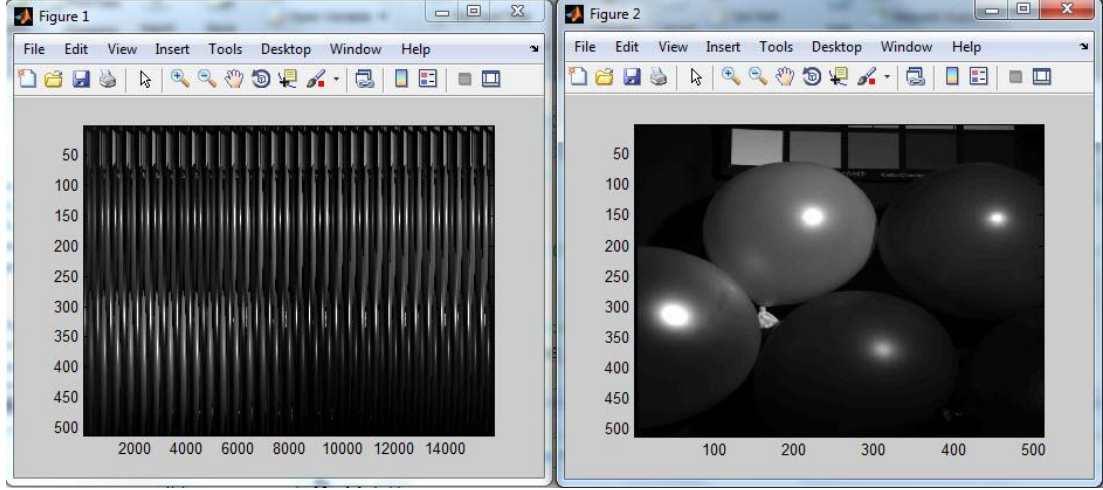
CAVE veri tabanı, 32 adet gündelik nesnelerin hiperspektral görüntüsünden oluşturulmuştur. Bu görüntüler 512x512 boyutunda ve spektral görsel aralığı 400-700 nm olup, 10 nm 'lik dalga boyu aralığında elde edilmiştir. CAVE veri tabanında yer alan  $Y_h$  düşük uzamsal çözünürlüklü hiperspektral görüntü işlem basamaklarında kullanılmak üzere 32x32 boyutlarında ayırık uzamsal bloklar halinde alt örnekleme yapılmıştır. Ardından,  $Y$  yüksek uzamsal ve düşük spektral çözünürlüklü görüntü kullanılarak, Nikon D700 spektral tepkisi tarafından spektral boyut üzerinde gerçek yer görüntüsünün entegresi oluşturulmuştur. Oluşturulan bu entegre görüntüler süper çözünürlük yönteminin işlem basamaklarında kullanılmıştır.

Bu tezde, Şekil 4.1.' de yer alan görüntüler Pan-keskinleştirme ve Sözlük Tabanlı Seyrek Temsil Yöntemi olan hiperspektral süper çözünürlük yöntemleri ve bunların çeşitleri ile hiperspektral görüntülerin uzamsal çözünürlüğü geliştirilmeye çalışılmıştır. Her yöntem için hazırlanan program kodları ve program paketleri, MATLAB R2014a programında ve Intel Core i5 2450M GPU, 2.5 GHz, 4Gb RAM özelliklerine sahip bilgisayarda kullanılmıştır.



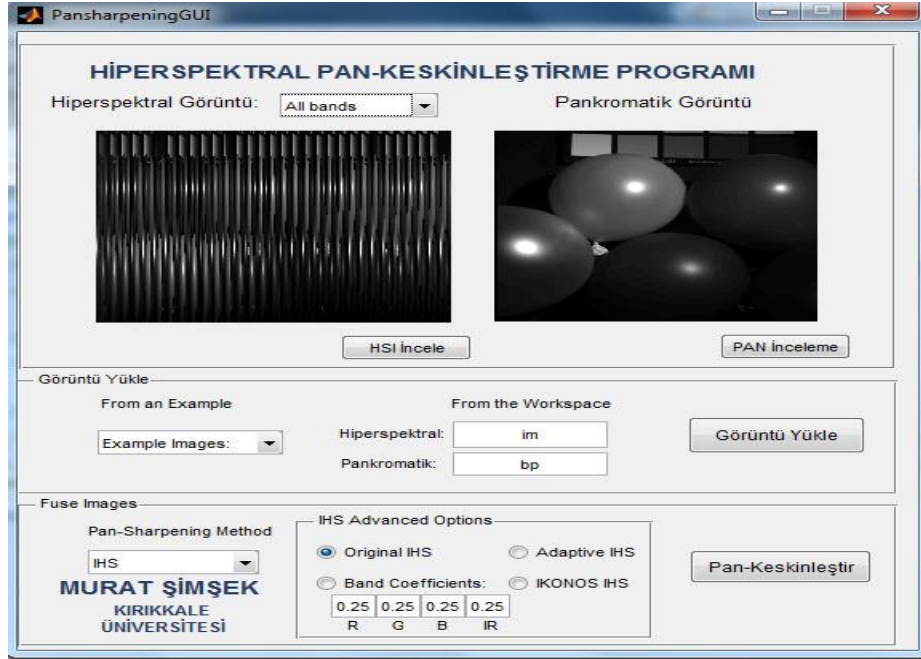
**Şekil 4.1.** CAVE veri tabanında yer alan hiperspektral görüntüler.

Pan-keskinleştirme yöntemi için PansharpeningGUI program paketi [55], Matlab program kodları hiperspektral görüntülere uygun olarak tekrardan hazırlanıp kullanılmıştır. İlk olarak CAVE veri tabanında yer alan hiperspektral görüntüler ve bu görüntülerin yüksek çözünürlüklü Pankromatik görüntüleri programa yüklenmiş olup, anılan veri tabanında yer alan 31 bantlı veri setlerine uygun olarak program paketi kodları tekrardan düzenlenmiştir. Daha önce multispektral görüntüleri için kullanılan bu program paketi; en fazla dört bantlı görüntüleri işlerken, hiperspektral görüntü veri tabanı olan CAVE veri setine uyarlanarak 31 bantlık görüntülere kadar her türlü hiperspektral görüntüyü işleyebilmektedir. Şekil 4.2.'de 31 bantlı hiperspektral görüntü ve süper çözünürlük için kullanılan aynı sahneye ait yüksek uzamsal çözünürlüklü pankromatik görüntü yer almaktadır.

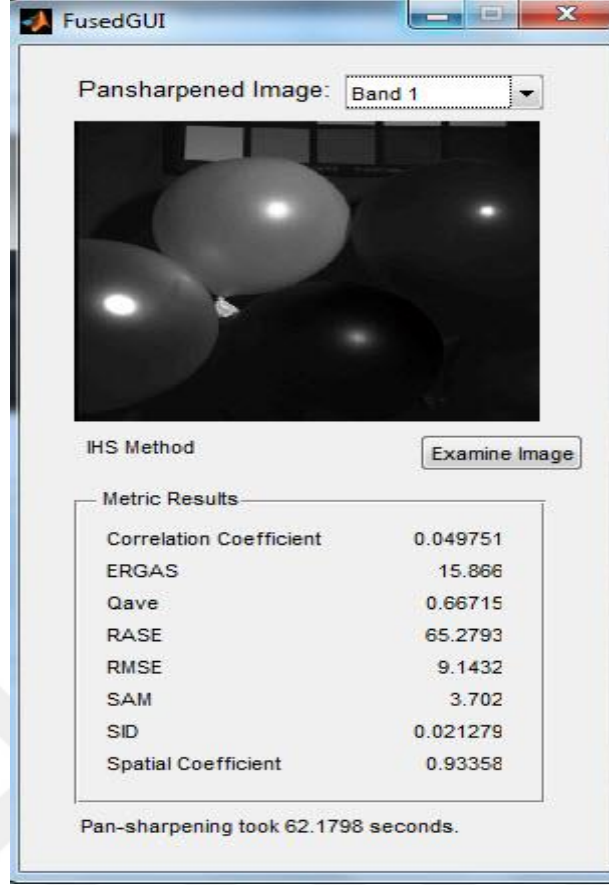


**Şekil 4.2.** Pan-keskinleştirme yönteminde kullanılan 31 bantlı hiperspektral görüntü ve aynı sahneye sahip pankromatik görüntü.

Şekilde 4.2.'de yer alan 31 spektral banda sahip hiperspektral görüntü ile yanında bulunan yüksek uzamsal çözünürlüğe sahip Pankromatik görüntü, Şekil 4.3.'de bulunan program ara yüzü ile pan-keskinleştirme yöntemi kullanılarak füzyona uğratarak, Şekil 4.4.'de yer alan program çıktısındaki süper-çözünürlüklü görüntü elde edilmiştir.



**Şekil 4.3.** Pan-keskinleştirme yönteminin kullanıldığı program ara yüzü.




**Şekil 4.4.** IHS pan-keskinleştirme yöntemi uygulanmış görüntünün program çıktısı ve parametreleri.

Şekil 4.5.'de Sözlük Öğrenme Tabanlı Seyrek Temsil Yöntemi için kullanılan programın ara yüzü yer almaktadır. Anılan Matlab programı, [8], [9] ve [40] yer alan yöntemlere uygun olarak düzenlenip oluşturulmuştur. Şekil 4.5.'de gösterildiği gibi üç bölümden oluşmaktadır. Birinci yöntem K-SVD sözlük öğrenme tabanlı seyrek temsil yöntemidir ve bu yöntemde diğer metotlardan farklı olarak [39]'de yer alan program ile kullanılacak her bir hiperspektral görüntünün sözlükleri hazırlanmıştır. ODL ve Bayes algoritmaları için böyle bir işleme gerek duyulmamaktadır.



**Şekil 4.5.** Sözlük Öğrenme Tabanlı Seyrek Temsil Yönteminin kullanıldığı program ara yüzü.

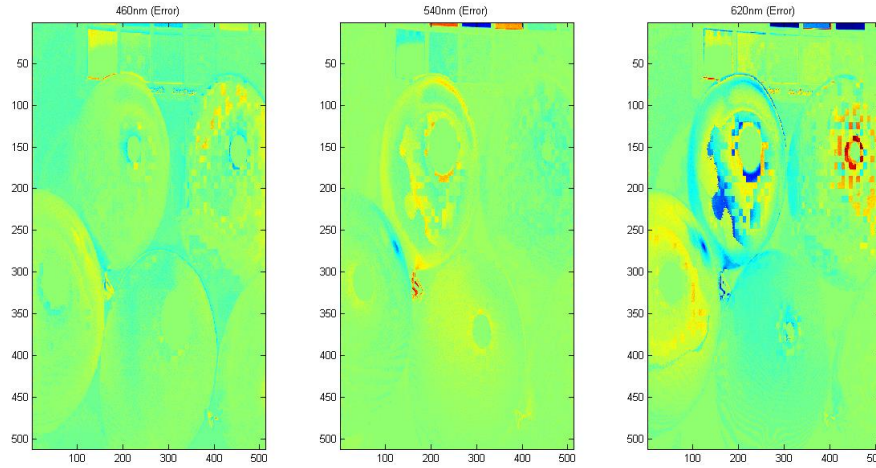
Yapılan uygulamalar sonucunda her bir hiperspektral görüntü K-SVD, ODL ve Bayes Sözlük Öğrenme Tabanlı Seyrek Temsil Yöntemi için Şekil 4.2.'deki gibi sonuç ekranı elde edilmiştir.



**Şekil 4.6.** Uygulama Sonucu Elde Edilen Görüntü.

Şekil 4.6.'de örnek olarak CAVE veri tabanında bulunan “Balloons” isimli hiperspektral görüntüsünün kullanılan yazılım sonucu elde edilen görüntüsü yer almaktadır. Bu görüntüdeki ilk satırda aynı sahneye sahip 460nm, 540nm, 620nm dalga boylarındaki düşük uzamsal çözünürlüğe sahip hiperspektral görüntüler yer almaktadır. İkinci satırda ise süper çözünürlük yönteminde kullanılan yüksek uzamsal, düşük spektral çözünürlüğe sahip yer görüntüsü yer almaktadır. Son satırda ise, seyrek temsil tabanlı süper çözünürlüklü hiperspektral görüntü yer almaktadır. İlk satırda yer alan hiperspektral görüntü ile son satırda yer alan süper çözünürlüklü görüntü arasında uzamsal çözünürlük bakımından gözle görülür fark olduğu anlaşılmıştır.

Ayrıca kullanılan yazılımda seyrek temsil tabanlı süper çözünürlüklü hiperspektral görüntü ile gerçek yer görüntüsü arasındaki fark olan hata payı da Şekil 4.7.'de yer aldığı gibi gösterilmiştir.




**Şekil 4.7.** 460nm, 540nm ve 620nm Dalga boylarındaki Hata payı.

Bu tezde MATLAB R2014a'da yazılan programla yapılan uygulamada, ilk adım olarak kullanılacak hiperspektral görüntünün bilgileri okunur ve görüntünün alt örnekleme yapılır. Burada giriş sinyalinin alt örnekleme yapılırken her N'inci örnek, ilk baştan başlayıp korunarak giriş sinyali olan x alt örneklenir. Ardından uzamsal çözünürlüğü geliştirilecek olan düşük

uzamsal çözünürlükteki hiperspektral görüntü iki boyuta çevrilir. Bu çevrim için Nikon D700 spektral yanıtı kullanılır. Sonrasında 8X8 parça (patch) görüntüler işlenir. İşlenen bu parça görüntüler eşleştirme yapılmak için hiperspektral görüntüde kullanılır.


#### **4.1. IHS Pan-keskinleştirme Yöntemi ile Süper-Çözünürlüklü Hiperspektral Elde Etme**

Hiperspektral görüntülerin IHS pan-keskinleştirme yöntemi ile uzamsal çözünürlüğünü arttırmak için Şekil 4.3.'de arayüzü yer alan program kullanılmıştır. Bu program sayesinde CAVE veri tabanında bulunan tüm görüntülerin uzamsal çözünürlüğü tercih edilen yöntemle göre geliştirilmiştir. CAVE veri tabanında bulunan bazı veri setlerinin IHS yönteminde kullanılan hiperspektral görüntü, yüksek uzamsal çözünürlüğe sahip pankromatik görüntü ve bunların pan-keskinleştirmesinden elde edilen füzyon görüntüleri Şekil 4.8. ve Şekil 4.9.'da yer almaktadır. Şekil 4.8. ve Şekil 4.9.'da CAVE veri tabanında bulunan "Balloons", "Beads", "Cd", "Clay", "Cloth" ve "Face" isimli hiperspektral veri setleri kullanılmış olup, IHS pan-keskinleştirme yöntemi ile süper-çözünürlüklü hiperspektral görüntüler yer almaktadır. Şekil 4.8. ve Şekil 4.9.'da yer alan görüntülerden ilk sütundaki görüntüler (a, d ve g) düşük uzamsal çözünürlükteki hiperspektral görüntülerdir. İkinci sütunda bulunan görüntüler (b, e ve h) yüksek uzamsal çözünürlüğe sahip orijinal görüntülerdir. Son olarak üçüncü sütunda bulunan görüntüler (c, f ve i) ise IHS pan-keskinleştirme yöntemi uygulanarak elde edilen süper-çözünürlüklü hiperspektral görüntülerdir.



**Şekil 4.8.** CAVE veri tabanında bulunan "Balloons", "Beads" ve "Cd" isimli hiperspektral görüntülerin IHS yöntemi uygulaması.





**Şekil 4.9.** CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin IHS yöntemi uygulaması.

CAVE veri tabanında bulunan görüntüleri anılan program aracılığıyla IHS metodu uygulanarak uzamsal çözünürlükleri artırılmış olup, Çizelge 4.1.'de bulunan parametrelere sahip süper çözünürlüklü görüntüler elde edilmiştir.

**Çizelge 4.1.** IHS yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.


<b>IHS PAN-KESKİNLEŞTİRME YÖNTEMİ İŞLEM PARAMETRELERİ SONUÇLARI</b>				
<b>SIRA</b>	<b>GÖRÜNTÜ ADI</b>	<b>RMSE</b>	<b>SAM</b>	<b>İŞLEM ZAMANI (sn)</b>
1	Balloons	9.1432	3.702	62.1798
2	Beads	5.8829	2.1925	54.526
3	CD	5.8301	2.1768	37.253
4	Cloth	5.6526	9.1316	52.349
5	Clay	2.3679	5.4686	29.319
6	Egyptian Statue	3.1948	16.537	57.7
7	Feathers	6.5416	8.9708	49.011
8	Flowers	5.814	29.6845	54.354
9	Glass tiles	11.546	8.8431	53.366
10	Chart and Stuffed toys	4.6167	7.916	22.563
11	Pompoms	10.13	5.6384	81.625
12	Sponges	11.919	4.4132	58.086
13	Thread spools	6.0268	6.4838	54.779
14	Stuffed toys	1.7342	12.1177	65.981
15	Super balls	2.8633	3.8302	47.657
16	Faces	4.1613	4.3022	84.144
17	Photo and face	3.1211	5.9782	13.408
18	Hairs	4.0093	10.3947	38.433
19	Oil Painting	5.6394	20.298	56.967
20	Paints	7.35	3.3321	60.047
21	Beers	12.064	9.5552	43.919
22	Jelly beans	6.1258	14.8502	41.39
23	Lemon slices	3.3131	3.7897	53.393
24	Lemons	5.5298	5.1072	79.347
25	Peppers	5.9515	14.1614	51.359
26	Strawberries	4.7451	9.3996	45.666
27	Sushi	3.6847	3.7899	40.119
28	Tomatoes	2.6322	3.0338	51.029
29	Yellow peppers	5.9406	6.836	37.361

## 4.2. PCA Pan-Keskinleřtirme Yöntemi ile Süper-Çözünürlüklü Hiperspektral Elde Etme


PCA yöntemi için, IHS yönteminde olduđu gibi [55]'de yer alan Matlab program kodları 31 bantlı hiperspektral görüntüleme uygun olarak hazırlanarak kullanılmıştır.

Şekil 4.10. ve Şekil 4.11.'da IHS yönteminde olduđu gibi CAVE veri tabanından bulunan altı görüntünün düşük uzamsal çözünürlüğe sahip hiperspektral görüntüleri (a, d ve g), yüksek uzamsal çözünürlüğe sahip orijinal görüntüleri (b, e ve h) ve PCA pan-keskinleřtirme yöntemi uygulanmış halleri (c, f ve ı) bulunmaktadır.

Görüldüğü üzere PCA pan-keskinleřtirme yöntemi ile elde edilen süper-çözünürlüklü görüntüler Şekil 4.10. ve Şekil 4.11.'da bulunan ilk satırdaki hiperspektral görüntüleme nazaran uzamsal çözünürlükleri gözle görülür düzeyde gelişmesine rağmen, diđer bir pan-keskinleřtirme yöntemi olan IHS yöntemine göre daha düşük uzamsal çözünürlüğe sahiptir. Bu iki yöntem arasında bir karşılaştırma yaptığımızda IHS yöntemi ile elde edilen sonuçlar, PCA yöntemi ile elde edilen sonuçlara göre daha başarılıdır.



**Şekil 4.10.** CAVE veri tabanında bulunan "Balloons", "Beads" ve "Cd" isimli hiperspektral görüntülerin PCA yöntemi uygulaması.



**Şekil 4.11.** CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin PCA yöntemi uygulaması.

CAVE veri tabanında bulunan görüntüler anılan program aracılığıyla PCA metodu uygulanarak uzamsal çözünürlüğü artırılmış olup, Çizelge 4.2.'de bulunan parametrelere sahip süper çözünürlüklü görüntüler elde edilmiştir.

**Çizelge 4.2.** PCA yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.


<b>PCA PAN-KESKİNLEŞTİRME YÖNTEMİ İŞLEM PARAMETRELERİ SONUÇLARI</b>				
<b>SIRA</b>	<b>GÖRÜNTÜ ADI</b>	<b>RMSE</b>	<b>SAM</b>	<b>İŞLEM ZAMANI (sn)</b>
1	Balloons	11.118	13.8656	73
2	Beads	9.8881	19.88	77
3	CD	7.5484	18.0988	67
4	Cloth	6.2117	8.0461	77
5	Clay	9.336	36.3365	60
6	Egyptian Statue	6.9599	25.2066	95
7	Feathers	13.292	20.5186	59
8	Flowers	10.263	28.4625	63
9	Glass tiles	8.9335	20.0657	56
10	Chart and Stuffed toys	19.279	16.9743	60
11	Pompoms	10.209	15.8314	59
12	Sponges	16.819	20.3004	58
13	Thread spools	89.754	25.8079	64
14	Stuffed toys	14.209	22.8484	60
15	Super balls	7.2452	28.0818	61
16	Faces	9.2696	19.3566	59
17	Photo and face	7.5884	18.382	58
18	Hairs	7.1973	18.424	61
19	Oil Painting	8.4192	14.4156	61
20	Paints	17.22	15.1434	58
21	Beers	10.593	10.593	55
22	Jelly beans	12.536	17.3452	61
23	Lemon slices	7.4516	22.377	57
24	Lemons	9.4156	28.0228	58
25	Peppers	9.1184	24.6965	100
26	Strawberries	9.3741	20.3868	58
27	Sushi	5.9254	16.0458	65
28	Tomatoes	6.9755	26.5435	66
29	Yellow peppers	9.4156	26.391	72

### 4.3. K-SVD Yöntemi ile Seyrek Temsil Tabanlı Süper-Çözünürlüklü Hiperspektral Elde Etme

K-SVD (K-Singular Value Decomposition/Tekil Değer Ayrışım) yöntemi, bu tezde K-SVD Matlab Program paketi [39] kullanılmıştır.


İlk olarak, K-SVD Matlab Program paketinde CAVE veri tabanında bulunan her bir hiperspektral görüntünün sözlüğü (dictionary) oluşturulmuştur. Oluşturulan sözlükler, G-SOMP+ algoritması ile kullanılarak süper-çözünürlüklü hiperspektral görüntüler elde edilmiştir.

Şekil 4.12. ve Şekil 4.13.'de, CAVE veri tabanında yer alan görüntülerin düşük çözünürlüğe sahip hiperspektral görüntüleri (a, d ve g), yüksek uzamsal çözünürlüğe sahip orijinal görüntüler (b, h ve e) ve K-SVD sözlük öğrenme tabanlı seyrek temsil yöntemi uygulayarak elde edilen süper-çözünürlüklü görüntüler (c, f ve ı) yer almaktadır. Şekil 4.12. ve Şekil 4.13'de yer alan altı farklı hiperspektral görüntüde de gözle görülür gelişme kaydedilmiştir.



**Şekil 4.12.** CAVE veri tabanında bulunan "Balloons", "Beads" ve "Cd" isimli hiperspektral görüntülerin K-SVD Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması.





**Şekil 4.13.** CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin K-SVD Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması.

CAVE veri tabanında bulunan görüntülere anılan program aracılığıyla K-SVD Sözlük Öğrenme tabanlı Seyrek Temsil Metodu uygulanarak uzamsal çözünürlüğü artırılmış olup, Çizelge 4.3.'de bulunan parametrelere sahip süper çözünürlüklü görüntüler elde edilmiştir.

**Çizelge 4.3.** K-SVD tabanlı Seyrek Temsil yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları

K-SVD TABANLI SEYREK TEMSİL YÖNTEMİ İŞLEM PARAMETRELERİ SONUÇLARI				
SIRA	GÖRÜNTÜ ADI	RMSE	SAM	İŞLEM ZAMANI (sn)
1	Balloons	1.53	0.46	275
2	Beads	3.66	1.28	286
3	CD	4.92	0.82	307
4	Cloth	2.44	0.79	300
5	Clay	1.68	1.21	247
6	Egyptian Statue	0.69	0.48	281
7	Feathers	2.15	0.83	265
8	Flowers	2.43	0.85	285
9	Glass tiles	2.07	0.84	263
10	Chart -Stuffed toys	3.1	0.36	410
11	Pompoms	2.67	0.86	355
12	Sponges	1.54	0.77	237
13	Thread spools	3.78	1.44	333
14	Stuffed toys	2.65	1.57	296
15	Super balls	2.52	1.06	288
16	Faces	1.15	0.25	257
17	Photo and face	1.86	0.56	288
18	Hairs	0.78	0.41	211
19	Oil Painting	1.3	0.54	268
20	Paints	3.12	0.49	415
21	Beers	2.16	0.30	302
22	Jelly beans	3.22	0.67	388
23	Lemon slices	2.85	0.57	354
24	Lemons	1.64	0.63	331
25	Peppers	1.33	0.79	294
26	Strawberries	1.57	0.66	309
27	Sushi	2.01	0.71	267
28	Tomatoes	2.64	0.75	387
29	Yellow peppers	1.72	0.69	241

#### 4.4. ODL Yöntemi ile Seyrek Temsil Tabanlı Süper-Çözünürlüklü Hiperspektral Elde Etme


ODL (Online Dictionary Learning) yöntemi, bu tezde SPAMS Program paketi [40]'ı ile kullanılmıştır. Uygulamadaki seyrek kodlama kısmında kullanılan G-SOMP+ algoritması için kullanılan sözlük, SPAMS derleme paketi kullanılarak istenilen görüntünün sözlüğünü oluşturmada yardımcı olmuştur. Bu derleme paketi başka bir işleme gerek kalmadan kullanıcılara istedikleri görüntünün işlem basamaklarında kullanılmak üzere sözlük oluşturup, uygulamadaki sözlük öğrenme bölümünde büyük kolaylık sağlamaktadır.

SPAMS (Seyrek Modelleme Yazılımı), GPLv3 lisansına sahip seyrek temsil için düzenlenmiş bir açık kaynak kodlu yazılım paketidir. Bu derleme paketi seyrek düzenleme içeren makine öğrenme ve sinyal işleme problemlerini çözmek için algoritmalarından oluşmaktadır. SPAMS derleme paketinde aşağıda yer alan üç araç bulunmaktadır.


1. Sözlük Öğrenme ve Matris Faktörizasyonu aracı
2. Seyrek Ayırışma aracı
3. Yakınsama aracı

Bu tezde SPAMS derleme paketinde bulunan Sözlük Öğrenme ve Matris Faktörizasyonu aracı aktif olarak kullanılmıştır. ODL sözlük öğrenme yöntemi için ve ilgili görüntünün boyut bilgileri için, SPAMS derleme paketinin Sözlük Öğrenme ve Matris Faktörizasyonu aracı efektif sonuçlar vermiştir.

CAVE veri tabanında bulunan ve bu tezdeki uygulamada kullanılan hiperspektral görüntülerin ODL sözlük öğrenme yöntemi ile Seyrek Temsil tabanlı Süper Çözünürlüklü Hiperspektral görüntü işleminin sonuçları ve hata payları Şekil 4.14. ve Şekil 4.15.'da yer almaktadır.



**Şekil 4.14.** CAVE veri tabanında bulunan “Balloons”, ”Beads” ve “Cd” isimli hiperspektral görüntülerin ODL Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması.



**Şekil 4.15.** CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin ODL Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması

CAVE veri tabanında bulunan görüntüler anılan program aracılığıyla ODL tabanlı seyrek temsil metodu uygulanarak uzamsal çözünürlüğü artırılmış olup, Çizelge 4.4.'de bulunan parametrelere sahip süper çözünürlüklü görüntüler elde edilmiştir.

**Çizelge 4.4.** ODL tabanlı Seyrek Temsil Yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.


<b>ODL TABANLI SEYREK TEMSİL YÖNTEMİ İŞLEM PARAMETRELERİ SONUÇLARI</b>				
<b>SIRA</b>	<b>GÖRÜNTÜ ADI</b>	<b>RMSE</b>	<b>SAM</b>	<b>İŞLEM ZAMANI (sn)</b>
1	Balloons	1.44	0.19	225
2	Beads	3.26	0.50	256
3	CD	4.25	0.22	299
4	Cloth	2.11	0.95	219
5	Clay	1.54	0.53	218
6	Egyptian Statue	0.63	0.54	253
7	Feathers	1.86	0.23	236
8	Flowers	2.36	1.43	273
9	Glass tiles	1.92	0.35	209
10	Chart and Stuffed toys	2.12	0.47	282
11	Pompoms	2.23	0.11	296
12	Sponges	1.43	0.89	223
13	Thread spools	3.77	1.36	302
14	Stuffed toys	2.57	1.38	258
15	Super balls	2.45	1.85	241
16	Faces	1.07	0.69	251
17	Photo and face	1.77	0.48	274
18	Hairs	0.73	0.46	203
19	Oil Painting	1.25	0.38	256
20	Paints	3.04	0.31	402
21	Beers	2.09	0.18	298
22	Jelly beans	3.03	0.71	357
23	Lemon slices	2.41	0.47	342
24	Lemons	1.53	0.87	312
25	Peppers	1.23	0.49	288
26	Strawberries	1.44	0.43	299
27	Sushi	1.88	0.63	253
28	Tomatoes	2.50	0.56	365
29	Yellow peppers	1.69	0.31	233

#### 4.5. Bayesian Seyrek Kodlama ile Seyrek Temsil Tabanlı Süper Çözünürlüklü Hiperspektral Elde Etme

Bayesian Seyrek Kodlama yöntemi için, Matlab R2014a programı ve [9]'da yer alan Bayesian program paketi, CAVE veri tabanına göre uyarlanıp kullanılmıştır. Kullanılan yazılım içerisinde sözlük öğrenme iterasyonu 1000 ve her bir seyrek kodlama başına kullanılan iterasyon 25 olarak ayarlanmıştır. Bu değerler CAVE veri setinde yer alan görüntülerin değerlerine göre hesaplanmıştır. Şekil 4.16. ve Şekil 4.17.' da CAVE veri tabanında bulunan altı adet görüntüye Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulanarak uzamsal çözünürlükleri gözle görülür bir şekilde arttırılmıştır.


Şekil 4.16. ve Şekil 4.17.'nin ilk sütununda (a, d ve g) düşük uzamsal çözünürlüğe sahip hiperspektral görüntüler yer almaktadır. İkinci sütununda ise (b, e ve h) hiperspektral görüntü ile aynı sahne ve dalga boyuna sahip yüksek uzamsal çözünürlüğe sahip orijinal görüntüler bulunmaktadır. Üçüncü sütunda (c, f ve ı) Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulanarak elde edilen süper-çözünürlüklü hiperspektral görüntüler yer almaktadır.

Şekil 4.16. ve Şekil 4.17'deki birinci (a, d ve g) ve üçüncü (c, f ve ı) sütun birbiriyle karşılaştırıldığında, kullanılan Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi ile dikkate değer bir şekilde başarılı sonuçlar elde edildiği değerlendirilmiştir.



**Şekil 4.16.** CAVE veri tabanında bulunan "Balloons", "Beads" ve "Cd" isimli hiperspektral görüntülerin Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması.





**Şekil 4.17.** CAVE veri tabanında bulunan "Clay", "Cloth" ve "Face" isimli hiperspektral görüntülerin Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yöntemi uygulaması.

CAVE veri tabanında bulunan görüntüler anılan program aracılığıyla Bayes sözlük öğrenme tabanlı seyrek temsil yöntemi uygulanarak uzamsal çözünürlüğü artırılmış olup, Çizelge 4.5.'de bulunan parametrelere sahip süper çözünürlüklü görüntüler elde edilmiştir.

**Çizelge 4.5.** Bayes tabanlı Seyrek Temsil Yöntemi uygulanan CAVE veri tabanındaki görüntülerin parametre sonuçları.

<b>BAYES TABANLI SEYREK TEMSİL YÖNTEMİ İŞLEM PARAMETRELERİ SONUÇLARI</b>				
<b>SIRA</b>	<b>GÖRÜNTÜ ADI</b>	<b>RMSE</b>	<b>SAM</b>	<b>İŞLEM ZAMANI (sn)</b>
1	Balloons	2.1	2.17	599
2	Beads	5.4	6.44	590
3	CD	5.3	0.89	479
4	Cloth	4.0	0.30	451
5	Clay	2.7	4.16	399
6	Egyptian Statue	1.4	4.62	299
7	Feathers	4.0	6.70	432
8	Flowers	4.6	2.22	658
9	Glass tiles	2.6	1.41	438
10	Chart and Stuffed toys	3.19	2.10	433
11	Pompoms	4.0	2.93	630
12	Sponges	4.0	0.79	444
13	Thread spools	4.6	1.89	363
14	Stuffed toys	4.0	8.14	519
15	Super balls	2.6	4.05	577
16	Faces	1.9	0.24	285
17	Photo and face	1.9	0.55	291
18	Hairs	2.2	1.07	430
19	Oil Painting	1.9	0.50	496
20	Paints	3.2	1.12	482
21	Beers	2.3	0.80	689
22	Jelly beans	4.8	4.46	682
23	Lemon slices	2.9	0.72	361
24	Lemons	2.4	1.19	389
25	Peppers	2.7	6.22	547
26	Strawberries	2.6	3.30	571
27	Sushi	2.9	0.82	516
28	Tomatoes	2.7	1.66	466
29	Yellow peppers	2.1	4.27	548

## 5.SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında hiperspektral süper-çözünürlük yöntemlerinden, Pan-keskinleştirme ve sözlük öğrenme tabanlı seyrek temsil yöntemleri kullanılarak hiperspektral görüntülerin uzamsal çözünürlükleri geliştirilmiş olup, anılan yöntemlerden elde edilen sonuçlar belirli parametrelerle detaylı bir şekilde karşılaştırılmıştır. Pan-keskinleştirme yöntemlerinden IHS (Yansıma Şiddeti, Renk Tonu, Doygunluk) ve PCA (Temel Bileşen Analizi) yöntemleri hiperspektral görüntülere uygun olarak düzenlenip süper-çözünürlük yöntemleri arasında yapılacak karşılaştırmaya dâhil edilmiştir. Seyrek temsil yöntemlerinden ise sözlük öğrenme tabanlı yöntemler kullanılmış olup, K-SVD, ODL ve Bayes sözlük öğrenme tabanlı seyrek temsil yöntemleri uygulanmıştır.

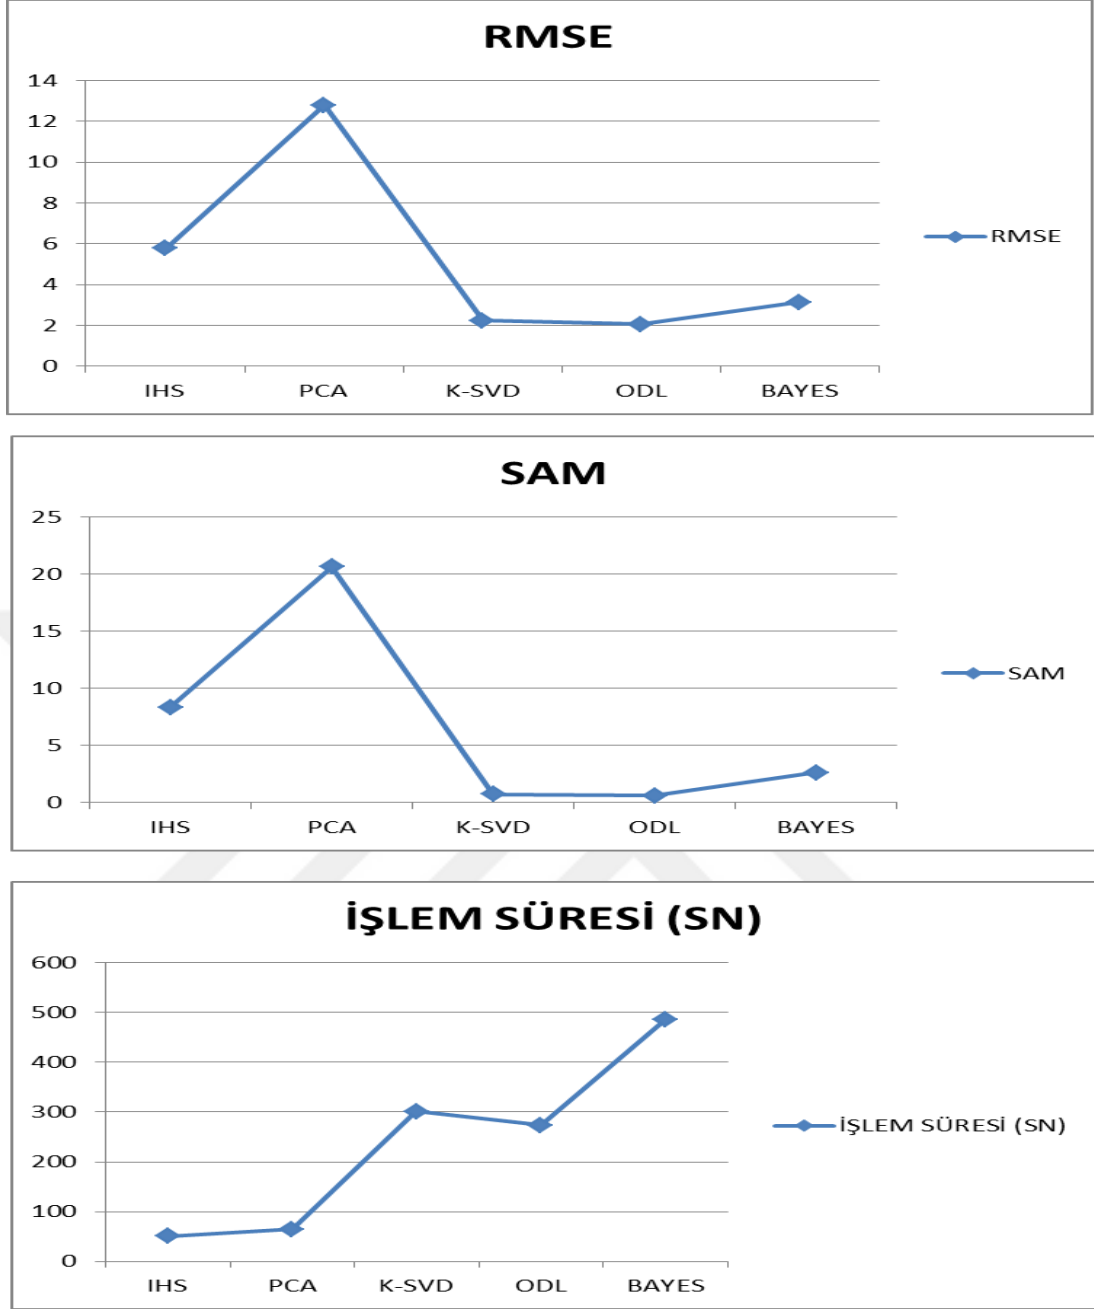
Seyrek temsil yöntemlerinde, K-SVD ve ODL sözlük öğrenme tabanlı yöntemlerde seyrek kodlama olarak G-SOMP+ algoritması kullanılmıştır. Bu algoritma tercih edilen sözlük öğrenme yöntemlerine uyumlu olduğu için K-SVD, ODL yöntemlerinde uygulamaya alınmıştır. Bayes Sözlük Öğrenme tabanlı Seyrek Temsil Yönteminde Bernoulli ve Beta İşlem algoritmaları kullanılarak diğer sözlük öğrenme tabanlı seyrek temsil yöntemleriyle beraber karşılaştırmaya dâhil edilmiştir.

Yapılan bu çalışmada, hiperspektral görüntülerin uzamsal çözünürlüğünü arttırma yöntemi olan hiperspektral süper-çözünürlük yöntemlerinden Pan-keskinleştirme ve Seyrek temsil yöntemleri kullanılarak karşılaştırmalı bir analiz yapılmıştır. Yapılan karşılaştırmada kullanılan yöntemler ve karşılaştırma parametreleri Çizelge 5.1.'de yer almaktadır.

**Çizelge 5.1.** Yöntemlerin Karşılaştırma Değerleri.

<b>Metot</b>	<b>RMSE (Ort.)</b>	<b>SAM (Ort.)</b>	<b>İşlem Zamanı (Ort.)</b>
IHS	5,77	8,34	50,94
PCA	12,81	20,63	64,75
K-SVD	2,24	0,74	301,37
ODL	2,05	0,62	273,20
Bayes	3,13	2,61	484,93

Çizelge 5.1.'de CAVE veri tabanında bulunan görüntüler üzerinde çizelgede yer alan beş süper-çözünürlük yönteminden elde edilen RMSE, SAM ve işlem zamanı değerlerinin ortalamaları karşılaştırılmış olup en uygun yöntemin tespiti amaçlanmıştır. Çizelge 5.1.'de görüldüğü üzere en düşük RMSE ve SAM değerine sahip ODL tabanlı Seyrek Temsil Yönteminin en efektif metot olduğu tespit edilmiştir. Ayrıca, sözlük öğrenme algoritmasının süper-çözünürlük yöntemine büyük etkisinin olduğu Şekil 5.1.'de gözlemlenmiştir.



**Şekil 5.1.** Ortalama Parametrelerin Karşılaştırılması.

Bu çalışma uzaktan algılama sistemlerine önemli bir yer edinen hiperspektral kameraların yakın zamanda daha yaygın kullanılabileceği düşünüldüğünde, bu alanda yapılacak çalışmaların daha çok değerlendirilebileceği, elde edilen hiperspektral görüntülerde yapılması istenilen analizlere büyük fayda sağlayacağı değerlendirilmiştir.

Bu tez çalışması, aşağıda sıralanan özelliklerden dolayı özgün bir değere sahip olduğu değerlendirilmektedir.

- (1) Sözlük öğrenme tabanlı seyrek temsil yöntemi kullanılarak, sözlük öğrenme yöntemlerinin hiperspektral görüntülerin uzamsal çözünürlüğünü geliştirmede etkisini ortaya koyması,
- (2) Günümüzde kullanılan ve gelecekte kullanılacak hiperspektral görüntüler için uzamsal çözünürlüğünün geliştirilmesinde en uygun metodu ortaya koyması,
- (3) Şu anda kullanılmakta olan süper-çözünürlük yöntemleri arasında kullanıcıların kolaylıkla seçim yapabilmesini sağlaması,
- (4) Boyutları ne olursa olsun her türlü hiperspektral görüntüde geçerli olabilecek uygun yöntemin geliştirilmesi,
- (5) hiperspektral görüntülerin detaylı analizini yaparak ülkemizde bu sistemlerin yaygın kullanılabilmesinde ve kullanılacak olan sistemlerden elde edilecek görüntülerin işlenmesinde büyük kolaylık sağlayacağı,
- (6) Askeri ve sivil alanlarda, keşif-gözetleme faaliyetlerinde gelecekte ülkemizde yaygın olarak kullanılması beklenen hiperspektral görüntüler için büyük bir altyapı sağlayacağı değerlendirilmektedir.

## KAYNAKLAR

- [1] Akgün, T., Altunbaşak, Y., Mersereau, R.M., Super-Resolution Reconstruction of Hyperspektral Images, Image Processing, IEEE Transactions, cilt 14, no.11,s.1860-1875, 2005.
- [2] Buttingsurd, B., Alsberg, B.K., Superresolution of Hyperspectral Images, Chemometrics and Intelligent Laboratory Systems,Elsevier, s.62–68, 2006.
- [3] Mianji, F., Babakhani, A., Kardan, M.R., Super-Resolution Challenges in Hyperspectral Imagery, Information Technology Journal,cilt 7 (7), s.1030-1036, 2008.
- [4] Babakhani, A., Zhang, Y., Mianji, F., Optimum Method Selection for Resolution Enhancement of Hyperspectral Imagery, Information Technology Journal, cilt 8, s.263-274, 2009. ,
- [5] Zhao, Y., Yang, J., Zhang, Q., Song, L., Cheng, Y., Pan, Q., Hyperspectral Imgery Super-Resolution by Sparse Representation and Spectral Regularization, EURASIP Journal on Advances in Signal Processing, 87, 2011.
- [6] Zhang, H., Zhang, L., Shen, H., A Super-Resolution Reconstruction Algorithm for Hyperspectral Images, Signal Processing, cilt 92, no.9, s.2082-2096, Elsevier, 2012

- [7] Wu, B., Li, C., Zhan, X., Integrating Spatial Structure in Super-Resolution Mapping of Hyperspectral Image, 2012 International Workshop on Information and Electronics Engineering (IWIEE), Proceia Engineering 29, s.1957-1962, Elsevier, 2012.
- [8] Akhtar, N., Shafait, F., Ajmal, M., Sparse Spatio-spectral Representation for Hyperspectral Image Super-Resolution, Computer Vision-ECCV 2014, Zurich, Switzerland, Springer International Publishing, s. 63-78., 2014.
- [9] Akhtar, N., Shafait, F., Mian, A., Bayesian Sparse Representation for Hyperspectral Image Super Resolution, Computer Vision and Pattern Recognition (CVPR), s.3631-3640, IEEE, Boston, 2015.
- [10] Şimşek, M., Polat, E., The Effect of Dictionary Learning Algorithms on Super-resolution Hyperspectral Reconstruction, XXV International Conference on Information, Communication and Automation Technologies (ICAT), Sarajevo, Bosnia and Herzegovina, 2015.
- [11] Shippert, P., Introduction to Hyperspectral Image Analysis, Online Journal of Space Communication, 2003.
- [12] Shippert, P., Why Use Hyperspectral Imaging?, Photogrammetric Engineering and Remote Sensing, s.377-380, 2004.
- [13] Warner, T. A., Nellis, M. D., Foody, G. M., SAGE Handbook of Remote Sensing, 2009.
- [14] Yellowstone Research, Yellowstone Ecological Research Center, [http://www.yellowstoneresearch.org/research\\_hightech-rs.html](http://www.yellowstoneresearch.org/research_hightech-rs.html). (erişim tarihi 25 Haziran 2015).



- [15] Elbakary, M., Alam, M., Superresolution Construction of Multispectral, IEEE Geoscience and Remote Sensing Letters, Cilt 5, no.2, 2008.
- [16] Cochrane, M., Using vegetation reflectance variability for species level classification of hyperspectral data, International Journal of Remote Sensing, cilt 21, no.10, s.2075-2087, 2000.
- [17] Ellis, J., Hyperspectral imaging technologies key for oil seep/oil-impacted soil detection and environmental baselines, Oil and Gas Journal, 1, cilt 99, no.37, s.49-58, 2001.
- [18] Freeman, J. E., Shi, Y., Panasyuk, S. V., Rogers, A. E., Medical hyperspectral imaging (MHSI) of 1,2-dimethylbenz(a) anthracene (DMBA)-Induced Breast Tumors in Rats., 27th Annual San Antonio Breast Cancer Symposium, San Antonio, Texas, 2004.
- [19] Overton, G., Hyperspectral imaging endoscope shows promise for in vivo cancer detection, Laser Focus World; Cilt 40, no.10, s.33, 2004.
- [20] Zuzak, K. J., Gladwin, M. T., Cannon, R. O., Lewin, I. O., Imaging hemoglobin oxygen saturation in sickle cell disease patients using noninvasive visible reflectance hyperspectral techniques: effects of nitric oxide, American journal of physiology, Heart and circulatory physiology cilt 285, no.3, 2003.
- [21] Flynn, K., O'Leary, R., Lennard, C., Roux, C., Reedy, B. J., Forensic applications of infrared chemical imaging: multi-layered paint chips, Journal of Forensic Sciences, cilt 50, no.:4, s.832-841,2005.

- [22] Exline, D. L., Wallace, C., Roux, C., Lennard, C., Nelson, M. P., Treado, P., Forensic applications of chemical imaging: latent fingerprint detection using visible absorption and luminescence, *Journal of Forensic Sciences*, cilt 48, no.:5, s.1047-1053, 2003.
- [23] Ardouin, J. P., Levesque, J., Rea, T. A., A Demonstration of hyperspectral image exploitation for military, 10th International Conference of Information Fusion, Quebec, 2007.
- [24] Bongiovi R.P., Hackwell J.A, Hayburst T.L., Airborne LWIR hyperspectral measurements of military vehicles, *Proceedings Aerospace Applications Conference*, 1996, Aspen, CO, USA, 1996.
- [25] Fauvel, M., Chanussot, J., Benediktsson, J. A., Sveinsson, J. R., Spectral and Spatial Classification of Hyperspectral, *Geoscience and Remote Sensing Symposium*, s.4834 - 4837, *IGARSS 2007 IEEE International*, Barcelona, 2007.
- [26] Park, S. C., Park, M. Y., Kang, M. G., Super-Resolution Image Reconstruction: A Technical Overview, *Signal Processing Magazine*, IEEE, Cilt 20, No.3, s. 21-36, 2003.
- [27] Elad, M., Feuer, A., Restoration of a Single Superresolution Image from Several Blurred, Noisy, and Undersampled Measured Images, *IEEE Transactions on Image Processing*, cilt 6, no.12, s. 1646-1658, 1997.
- [28] Eismann, M. T., Hardie, R. C., Hyperspectral Resolution Enhancement Using High Resolution Multispectral Imagery with Arbitrary Response Functions, *IEEE Transactions on Geoscience and Remote Sensing*, cilt 43, no. 3, s. 455-465, 2005.

- [29] Khan, M. M., Chanussot, J., Alparone, L., Pansharpening of Hyperspectral Images Using Spatial Distortion Optimization, Image Processing (ICIP), 16th IEEE International Conference, Cairo, 2009.
- [30] Pohl, C., van Genderen, J. L., Multisensor Image Fusion In Remote Sensing : Concepts, Methods And Applications, International Journal Of Remote Sensing, cilt.19, no. 5, s. 823-854, 1998.
- [31] Xiao-Hui, Y., Li-Cheng, J., Fusion Algorithm For Remote Sensing Images Based on Nonsampled Contourlet Transform, ACTA Automatica Sinica, cilt 34, no.3, s. 274-281, 2008.
- [32] Wassai, F. A., Kalyankar, N. V., Zuky, A. A., The IHS Transformations Based Image Fusion, International Journal of Advanced Research in Computer Science, cilt 2, no. 5, 2011.
- [33] Nunez, J, Otazu, X., Fors, O., Prades, A., Multiresolution-Based Image Fusion with Additive Wavelet Decomposition, IEEE Transactions on Geoscience and Remote Sensing, cilt. 37, no. 3, s. 1204-1211, 1999.
- [34] Liao, Y. C., Wang, T. Y., Zheng, W. T., Quality Analysis Of Synthesized High Resolution Multispectral Imagery, Asian Association on Remote Sensing, Asian Conference on Remote Sensing, 1998.
- [35] Castleman, K. R., Digital Image Processing, Upper Saddle River, New Jersey, Prentice Hall, 1995.
- [36] Patel, V. M., Chellappa, R., Sparse Representations, Compressive Sensing and Dictionaries for Pattern Recognition, (ACPR), 2011 First Asian Conference, Beijing, 2011.

- [37] Olshausen, B. A., Field, D.J., Emergence of Simple-Cell Receptive Field Properties by Learning a Sparse Code for Natural Images, *Nature* 381, s. 607-609; doi:10.1038/381607a0, 1996
- [38] Rubinstein, R., Bruckstein, A., Elad, M., Dictionaries for Sparse Representation Modeling, *Proceedings of the IEEE*, cilt 98, no. 6, s. 1045-1057, 2010.
- [39] Aharon, M., Elad, M., Bruckstein, A., K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation, *IEEE Transactions on Signal Processing*, cilt 54, no. 11, s. 4311-4322, 2006.
- [40] Mairal, J., SPAMS: a Sparse Modeling Software, v2.5, <http://spams-devel.gforge.inria.fr>, (Erisim tarihi: 20.06.2014).
- [41] Mairal, J., Bach, F., Ponce, Sapiro, G., Online Dictionary Learning for Sparse Coding, *International Conference on Machine Learning (ICML)*, 2009.
- [42] He, L., Qi, H., Zaretzki, R., Non-parametric Bayesian dictionary learning for image super resolution, *Future of Instrumentation International Workshop (FIW)*, Oak Ridge, TN, s.122-125, 2011.
- [43] Hjort, N. L., Nonparametric Bayes estimators based on beta processes in models for life history data, *An Official Journal of the Institute of Mathematical Statistic*, cilt 18, no.3, s.1259-1294, 1990.
- [44] Zhou, M., Nonparametric Bayesian Dictionary Learning and Count & Mixture Modeling, IBM T. J. Watson Research Center, Yorktown Heights, New York, 2012.

- [45] Huang, Y., Paisley, J., Lin, Q., Ding, X., Bayesian Nonparametric Dictionary Learning for Compressed Sensing MRI, Image Processing, IEEE Transactions, cilt 23, no. 12, s. 5007-5019, 2014.
- [46] Paisley, J., Carin, L., Nonparametric factor analysis with beta process priors, International Conference on Machine Learning (ICML), Montreal, Canada, 2009.
- [47] Loncan, L., Fabre, S., Almeida, L., Bioucas-Dias, J., Hyperspectral Pansharpening: A Review, Geoscience and Remote Sensing Magazine, IEEE , cilt 3, no.3, s.27-46, 2015
- [48] Iordache, M.-D., Bioucas-Dias, J. M., Plaza, A., Sparse Unmixing of Hyperspectral Data, Geoscience and Remote Sensing, IEEE Transactions, cilt 49, no.6, s.2014-2039, 2011.
- [49] Tropp, J. A., Gilbert, A. C., Strauss, M. J., Algorithms for Simultaneous Sparse Approximation. Part I: Greedy pursuit, Signal Processing, cilt 86, no. 3, s. 589-602, 2006.
- [50] Kawakami, R., Wright, J., Tai, Y-W, Matsushita, Y., High-Resolution Hyperspectral Imaging via Matrix Factorization., Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference, s. 2329-2336, Providence, RI, 2011.
- [51] Wycoff, E., Chan, T-H., Jia, K., Ma, W-K., A Non-Negative Sparse Promoting Algorithm for High-Resolution Hyperspectral Imaging, Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference, s. 1409-1413, Vancouver, BC, 2013..

- [52] Yokoya, N., Yairi, T., Iwasaki, A., Coupled Non-Negative Matrix Factorization Unmixing for Hyperspectral and Multispectral Data Fusion, *Geoscience and Remote Sensing, IEEE Transactions*, cilt 52, no. 2, s.528-537, 2012.
- [53] Rashmi, S., Addamani, S., Ravikiran, S, Spectral Angle Mapper Algorithm for Remote Sensing Image Classification, *IJSET- International Journal of Innovative Science, Engineering & Technology*, Cilt 1, No. 4., s.201-205, 2014.
- [54] Yasuma, F., Mitsunaga, T, Iso, D., Nayar, S.K., Generalized Assorted Pixel Camera: Post-Capture Control of Resolution, Dynamic Range and Spectrum, *Image Processing, IEEE Transaction*, cilt 19, no.9, s. 2241 - 2253, 2008.
- [55] Zhao, Y., Yang, J., Chan, J.C-W., Hyperspectral Imagery Super-Resolution by Compressive Sensing Inspired Dictionary Learning and Spatial-spectral Regularization, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Sensors 2015*, cilt 7, no. 6, 2015.