

**T.C.  
YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**HİPERSPEKTRAL GÖRÜNTÜLERDE BİLEŞİK ÇEKİRDEK KOVARYANS  
TANIMLAYICI İLE HEDEF TESPİTİ**

**SERKAN SALTÜRK**

**YÜKSEK LİSANS TEZİ  
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI  
HABERLEŞME PROGRAMI**

**DANIŞMAN  
PROF. DR. ABDULLAH BAL**

**İSTANBUL, 2015**

Bu alıřma, 112E207 nolu "Hiperspektral Grntlerde Uzamsal ve Spektral z nitelikler Kullanarak Yksek Hızda Hedef Tespiti ve Sınıflama Yapan Algoritmaların Geliřtirilmesi" isimli TBİTAK projesi kapsamında desteklenmiřtir.

Öncelikle, çalışmalarımız sırasında bize bir hocadan çok ağabey gibi davranan, sadece bu tezde değil, onu tanıdığımızdan beri üzerimizde hayatımızın her alanında emeği olan, bizi her konuda sabırla dinleyen ve bu yolda bizi cesaretlendiren hocamız Prof. Dr. Abdullah BAL'a teşekkürlerimi sunuyorum.

Ayrıca çalışmalarımız sırasında bana destek olan Enformatik Bölümünde ve Elektronik Haberleşme Mühendisliği Bölümünde görevli arkadaşlarıma ve özellikle her türlü bilgisini bizimle paylaşarak değerli zamanını bizim için harcayan Arş. Gör. Hamidullah BİNOL'a teşekkürü bir borç bilirim.

Son olarak, hayatı benim için daha değerli ve anlamlı hale getiren, her daim yanımda olan değerli eşim Arş. Gör. Tuba SALTÜRK'e ve canım kızıma, hangi yolda olursam olayım, arkamda her zaman desteklerini hissettiğim, bugünlere gelmemde maddi ve manevi hiçbir fedakarlıktan kaçınmayan aileme, ailelerine katıldığım günden beri, beni kendi çocuklarından ayırmayan, her türlü maddi manevi desteği bizlerden esirgemeyen kayınvalidem Sabiha SOYDAN ve kayınpederim Hıdır SOYDAN'a ve akademik dünyaya ayak basmama vesile olan ablam Dr. Esengül SALTÜRK'e candan teşekkür ederim.

Bu çalışma, 112E207 nolu "Hiperspektral Görüntülerde Uzamsal ve Spektral Öznitelikler Kullanarak Yüksek Hızda Hedef Tespiti ve Sınıflama Yapan Algoritmaların Geliştirilmesi" isimli TÜBİTAK projesi kapsamında desteklenmiştir.

Kasım, 2015

Serkan SALTÜRK

## İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ .....	xi
ÖZET .....	xii
ABSTRACT.....	xiv
<b>BÖLÜM 1</b>	
<b>GİRİŞ.....</b>	<b>1</b>
1.1    Literatür Özeti .....	1
1.2    Tezin Amacı .....	3
1.3    Hipotez.....	4
<b>BÖLÜM 2</b>	
<b>HİPERSPEKTRAL GÖRÜNTÜLEME.....</b>	<b>5</b>
2.1    Giriş .....	5
2.2    Hiperspektral Görüntülemenin Kullanıldığı Alanlar .....	7
2.3    Spektral İmza.....	8
<b>BÖLÜM 3</b>	
<b>HEDEF TESPİTİ .....</b>	<b>10</b>
3.1    Hedef Tespiti Problemi .....	10
3.2    Hedef Tespiti Problemine Önerilen Yöntemler .....	10
3.2.1    Kovaryans Tanımlayıcı .....	10
3.2.2    Çekirdek Fonksiyonları.....	14
3.2.3    Bileşik Çekirdek Fonksiyonları .....	17
<b>BÖLÜM 4</b>	
<b>HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ .....</b>	<b>20</b>
4.1    Kovaryans Tanımlayıcı ile Hedef Tespiti .....	20

4.2	Çekirdek Kovaryans Tanımlayıcı ile Hedef Tespiti .....	23	
4.3	Bileşik Çekirdek Kovaryans Tanımlayıcı ile Hedef Tespiti .....	25	
BÖLÜM 5			
DENEYSEL ÇALIŞMALAR .....			28
5.1	Metodoloji .....	28	
5.2	Kullanılan Veri Setleri.....	30	
5.2.1	AVIRIS Veri Seti .....	30	
5.2.2	Kennedy Space Center Veri Seti .....	36	
5.2.3	PAVIA Üniversitesi Veri Seti.....	40	
5.2.4	ÇATALCA01 Veri Seti.....	44	
BÖLÜM 6			
SONUÇ VE ÖNERİLER .....			48
KAYNAKLAR .....			50
ÖZGEÇMİŞ .....			52

## SİMGE LİSTESİ

---

$\Phi$	Kovaryans Tanımlayıcı(KT) için yoğunluk, renk ya da filtre cevabı
R	KT hedef bölgesi
$C_R$	KT hedef bölgesi (R) için kovaryans sonucu
$\mu$	Ortalama
$K_S$	Toplam çekirdek dönüşüm matrisi
$K_{STD}$	Standart sapma çekirdek dönüşüm matrisi
$\rho$	Uzaklık metriği fonksiyonu
$\lambda_i$	Her bir i değeri için özdeğer fonksiyonu
$C_i$	Kovaryans matrisi
$\sigma$	Çekirdek fonksiyonu için sigma değişkeni

## KISALTMA LİSTESİ

---

AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
BÇKT	Bileşik Çekirdek Kovaryans Tanımlayıcı
CD	Covariance Descriptor
ÇFKD	Çekirdek Fukunaga Koontz Dönüşümü
CKCD	Composite Kernel Covariance Descriptor
ÇKT	Çekirdek Kovaryans Tanımlayıcı
DAA	Doğrusal Ayrım Analizi
DP	Doğru Pozitif
DPO	Doğru Pozitif Oranı
DVM	Destek Vektör Makinesi
EMÖ	Eğitimsiz Metrik Öğrenme
FKD	Fukunaga-Koontz Dönüşümü
HSG	Hiperspektral Görüntü
KCD	Kernel Covariance Descriptor
KT	Kovaryans Tanımlayıcı
KPCA	Çekirdek Temel Bileşen Analizi
KSC	Kennedy Space Center
LKM	Lineer Karışım Modeli
ROC	Receiver Operating Characteristic
YAZGI	Yazılım Geliştirme ve Görüntü İşleme Laboratuvarı
YP	Yanlış Pozitif
YPO	Yanlış Pozitif Oranı
YSA	Yapay Sinir Ağları

## ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 Yapay sinir ağları yöntemi ile hiperspektral görüntüler(HSG) üzerinde hedef tanıma [2].....	1
Şekil 1.2 Bruce tarafından yayınlanan dalgacık dönüşümü ve DAA kullanarak HSG üzerinde sınıflandırma [2].....	2
Şekil 1.3 Kullanılan HSG ve üzerindeki hedeflerin doğrulama görüntüsü [4].....	2
Şekil 1.4 AVIRIS veri setinden farklı 4 algoritma için hedef tespiti [6].....	3
Şekil 2.1 Mantis Karidesi .....	5
Şekil 2.2 YAZGI Laboratuvarı'ndan alınmış hiperspektral kamera görüntüsü .....	6
Şekil 2.3 Spektral İmza .....	8
Şekil 2.4 Farklı türdeki maddelere ait spektral imza örnekleri .....	9
Şekil 3.1 Yaya tespiti örnekleri [8] .....	13
Şekil 3.2 Log-kovaryans tanımlayıcı kullanarak hareket tanıma algoritmasının genel görüntüsü [9] .....	14
Şekil 3.3 a) Çekirdek fonksiyonu kullanılmadan sınıfların ayrımı b) Çekirdek fonksiyonu ile boyut artırımından sonra sınıfların ayrımı .....	15
Şekil 3.4 Ortalama ve varyansa bağlı değişen Gauss fonksiyonu eğrileri [12].....	16
Şekil 4.1 KSC veri seti 3. sınıf KT ROC eğrisi .....	21
Şekil 4.2 KT için hedef tespiti işlemi süreci .....	22
Şekil 4.3 ÇKT için hedef tespiti işlemi süreci .....	24
Şekil 4.4 Hedef tespiti sırasında uzamsal bilginin kullanılması.....	26
Şekil 4.5 AVIRIS veri seti örnek bir sınıf için KT, ÇKT ve BÇKT ile uzamsal bilgilerin kullanılmasıyla oluşan ROC eğrileri.....	26
Şekil 4.6 BÇKT için hedef tespiti işlemi süreci.....	27
Şekil 5.1 AVIRIS veri seti 1. sınıf verileri için tüm bantların görünümü .....	28
Şekil 5.2 Yöntemlerin başarılarının karşılaştırılması için gerekli terimlerin gösterimi [19] .....	29
Şekil 5.3 a) Doğru Pozitif Oranı – DPO (Recall) b) Yanlış Pozitif Oranı – YPO (Yanlış Alarm Oranı) c) Precision (Kesinlik) d) Accuracy (Doğruluk) .....	30
Şekil 5.4 AVIRIS veri seti (RGB).....	31
Şekil 5.5 AVIRIS veri seti için doğrulama verisi .....	32
Şekil 5.6 AVIRIS sınıf 1 için; a) Hedef Bölge b) KT sonucu bulunan bölge c) ÇKT sonucu bulunan bölge d) BÇKT sonucu bulunan bölge .....	33
Şekil 5.7 AVIRIS sınıf-1 için ROC eğrisi.....	34
Şekil 5.8 AVIRIS sınıf-2 için ROC eğrisi.....	34

Şekil 5.9 AVIRIS sınıf-4 için ROC eğrisi.....	35
Şekil 5.10 KSC veri seti (RGB) .....	36
Şekil 5.11 KSC veri seti doğrulama verisi .....	37
Şekil 5.12 KSC veri seti sınıf 3 için ROC eğrisi.....	38
Şekil 5.13 KSC veri seti sınıf 4 için ROC eğrisi.....	39
Şekil 5.14 KSC veri seti sınıf 6 için ROC eğrisi.....	39
Şekil 5.15 KSC veri seti sınıf 8 için ROC eğrisi.....	40
Şekil 5.16 PAVIA veri setinin rastgele 3 bant ile gösterimi .....	41
Şekil 5.17 PAVIA Üniversitesi veri seti doğrulama verisi .....	42
Şekil 5.18 PAVIA veri seti sınıf 1 için ROC eğrisi.....	43
Şekil 5.19 PAVIA veri seti sınıf 7 için ROC eğrisi.....	43
Şekil 5.20 ÇATALCA01 veri seti (RGB) .....	44
Şekil 5.21 ÇATALCA01 veri seti doğrulama verisi .....	45
Şekil 5.22 ÇATALCA01 veri setinin küçültülmesi ile oluşturulmuş yeni doğrulama verisi .....	45
Şekil 5.23 ÇATALCA01 sınıf 10 için; a)Hedef Bölge b)KT sonucu bulunan bölge c) ÇKT sonucu bulunan bölge d)BÇKT sonucu bulunan bölge .....	46
Şekil 5.24 ÇATALCA01 sınıf 10 (insan hedefi) için ROC eğrisi .....	47
Şekil 5.25 ÇATALCA01 sınıf 6 için ROC eğrisi.....	47

## ÇİZELGE LİSTESİ

---

	Sayfa
Çizelge 2.1 Bilinen hiperspektral görüntüleme sensörleri.....	8
Çizelge 5.1 AVIRIS veri setine ait sınıflar ve bu sınıfların örnek sayıları.....	31
Çizelge 5.2 AVIRIS veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları....	32
Çizelge 5.3 AVIRIS veri seti, KT ve ÇKT için öznelik artırımı ROC eğrisi değerlendirme sonuçları.....	36
Çizelge 5.4 KSC veri setine ait sınıflar ve bu sınıfların örnek sayıları .....	37
Çizelge 5.5 KSC veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları .....	38
Çizelge 5.6 PAVIA Üniversitesi veri setine ait sınıflar ve bu sınıfların örnek sayıları .....	41
Çizelge 5.7 PAVIA veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları.....	42
Çizelge 5.8 ÇATALCA01 veri setine ait sınıflar ve bu sınıfların örnek sayıları .....	44
Çizelge 5.9 ÇATALCA01 veri setinde yapılan testler sonucunda ulaşılan, yöntemlerin performans sonuçları.....	46

## HİPERSPEKTRAL GÖRÜNTÜLERDE BİLEŞİK ÇEKİRDEK KOVARYANS TANIMLAYICI İLE HEDEF TESPİTİ

Serkan SALTÜRK

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Abdullah BAL

Hiperspektral görüntüleme, diğer görüntüleme tekniklerine göre sağladığı avantajlar ve hiperspektral görüntüleme teknolojisindeki hızlı gelişmelere bağlı olarak yaygın bir şekilde kullanılabilir hale gelmiştir. Yüksek bant genişliğine ve veri işleme süresinin uzun olmasına rağmen, hiperspektral görüntüleme, yüksek spektral çözünürlüğü ve görüntü üzerindeki materyale duyarlı olması nedeniyle sıklıkla kullanılmaktadır.

Bu çalışmada hiperspektral görüntüler üzerinde çekirdek kovaryans tanımlayıcı(ÇKT) ve bileşik çekirdek kovaryans tanımlayıcı(BÇKT) yöntemleriyle hedef tespiti uygulaması yapılmıştır. Önerilen yöntemlerin hedef tespiti başarısı, yöntemlerin AVIRIS, KSC (Kennedy Space Center), PAVIA ve ÇATALCA01 veri setleri üzerinde uygulanmasıyla klasik kovaryans tanımlayıcı (KT) ile karşılaştırılmıştır. Uygulama sırasında AVIRIS ve KSC veri setlerinde tüm sınıflar, ÇATALCA01 ve PAVIA veri setlerinde ise sadece belirli hedef sınıflar uygulamaya dahil edilmiştir.

Yapılan uygulamalarda ÇKT ve BÇKT yöntemlerinin KT yöntemine göre daha başarılı sonuçlar verdiği görülmüştür. Ayrıca uygulamalar sırasında KT yöntemi için farklı öznelilikler kullanılmış, bunların sonuca olumlu etkisi değerlendirilmiştir.

Çalışma kapsamında spektral bilgilerin yanı sıra uzamsal bilgiler de kullanılmış, bu bilgiler BÇKT yönteminin uygulanması sırasında uygulamaya dahil edilmiş ve daha iyi sonuçlar elde edildiği görülmüştür.

**Anahtar Kelimeler:** Hiperspektral görüntüleme, kovaryans tanımlayıcı, çekirdek kovaryans tanımlayıcı, bileşik çekirdek, hedef tespiti

**TARGET DETECTION ON HYPERSPECTRAL IMAGES WITH COMPOSITE  
KERNEL COVARIANCE DESCRIPTOR**

Serkan SALTÜRK

Department of Electronics and Communications Engineering

MSc. Thesis

Adviser: Prof. Dr. Abdullah BAL

Hyperspectral imaging has become popular because of its advantages over the other imaging techniques and rapid improvements on hyperspectral technologies. In spite of its high bandwidth and time-consuming process, because of its high spectral resolution and sensitivity to material on the image, hyperspectral imaging is often used in image processing.

In this thesis, target detection is performed with Kernel Covariance Descriptor and Composite Kernel Covariance Descriptor on hyperspectral images. Target detection successes of proposed methods are compared to classical covariance descriptor (CD) by applying these methods on AVIRIS, KSC (Kennedy Space Center), PAVIA and ÇATALCA01 datasets. During the tests, all classes of KSC and AVIRIS and specific target classes of ÇATALCA01 and PAVIA datasets are included.


The test results show that KCD and CKCD methods return better results than classical CD. Also, during the tests, different image features are applied to CD method and the results are evaluated.

Within the scope of this work, spatial data is also included with spectral data for CKCD method and better results are found.

**Keywords:** Hyperspectral, covariance descriptor, kernel covariance descriptor, composite kernel, target detection

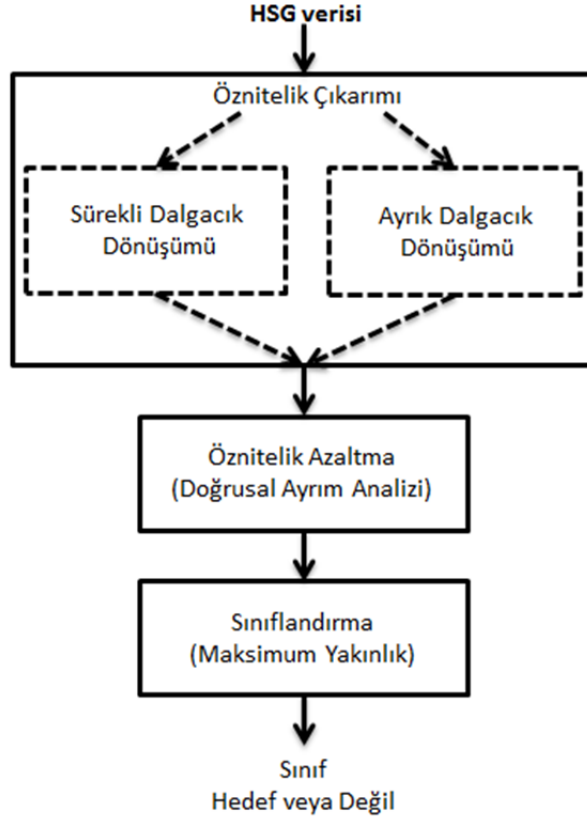
#### 1.1 Literatür Özeti

Hiperspektral görüntülerde hedef tespiti ile ilgili 90'lı yıllardan itibaren yayınlanan çok sayıda çalışma mevcuttur. Howard vd. [2], 1999 yılında yaptığı çalışmada, piksel boyutundan daha küçük hedefleri tanımak için piksel vektörlerini gruplara ayırmış ve bu grupların özniteliklerini bularak boyut indirgeme işlemi yapmıştır. Bu işlemlerden sonra Yapay Sinir Ağları(YSA) yöntemi ile başarılı sonuçlar elde etmiştir.




Şekil 1.1 Yapay sinir ağları yöntemi ile hiperspektral görüntüler(HSG) üzerinde hedef tanıma [2]

Yine benzer bir problem için Bruce vd. [3], Dalgacık Dönüşümü ve Doğrusal Ayrım Analizi(DAA) yöntemlerini kullanarak başarılı bir çalışma ortaya çıkarmıştır.



Şekil 1.2 Bruce tarafından yayınlanan dalgacık dönüşümü ve DAA kullanarak HSG üzerinde sınıflandırma [2]


2008 yılında Alam vd. [4], gauss filtresi ve ileri işleme yöntemleriyle askeri hedef tespiti çalışmasında, sanal ve gerçek görüntüler test edilmiş, hedefler başarıyla tespit edilmiştir.



Şekil 1.3 Kullanılan HSG ve üzerindeki hedeflerin doğrulama görüntüsü [4]

L. Zhang [5] tarafından 2014 yılında yapılan çalışmada Eğitimcili Metrik Öğrenme (EMÖ) metoduyla piksel boyutundan daha küçük hedefleri piksel içinden ayırtırmayı amaçlamıştır. EMÖ yöntemiyle hedef ve arka plan diye ayrılan pikseller arasında maksimum mesafe oluşturularak hedefler tespit edilmiştir.

Yine 2004 yılında Ye Zhang [6] Çekirdek Temel Bileşenler Analizi (ÇTBA) ve Lineer Karışım Modeli (LKM) kullanarak hiperspektral görüntüdeki yanlış hedef tespitini alt seviyelere indirmiştir.



Şekil 1.4 AVIRIS veri setinden farklı 4 algoritma için hedef tespiti [6]

## 1.2 Tezin Amacı

Bu çalışmada, hiperspektral görüntüler üzerinde hedef tespiti uygulaması yapılmış olup bu hedef doğrultusunda dört ayrı veri seti (AVIRIS, KSC, PAVIA, ÇATALCA01) üzerinde Kovaryans Tanımlayıcı (KT) yönteminden daha başarılı olan Çekirdek Kovaryans

Tanımlayıcı (ÇKT) ve Bileşik Çekirdek Kovaryans Tanımlayıcı (BÇKT) yöntemleri ile hedef tespiti yapılması amaçlanmıştır. Ayrıca KT için farklı özniteliklerin kullanımı ve BÇKT yöntemiyle spektral özelliklerle beraber uzamsal özelliklerin kullanımının sonuca etkisi analiz edilmiştir.

### **1.3 Hipotez**

Hiperspektral görüntüler üzerinde hedef tespiti için uygulanan ÇKT ve BÇKT yöntemlerinin uygun değişkenler kullanıldığında klasik KT yöntemine göre daha başarılı sonuçlar vermesi ve KT yöntemine yeni öznitelikler eklendiğinde ya da öznitelikler değiştirildiğinde başarının artması hipotez olarak sunulmuştur. Bunlarla beraber BÇKT yönteminde, spektral özelliklerin yanında uzamsal özellikler kullanıldığında hedef tespiti başarı oranlarının daha yüksek çıkması beklenmektedir.

### HİPERSPEKTRAL GÖRÜNTÜLEME

#### 2.1 Giriş

Hiperspektral sistemlerin tasarlanması fikri, bir deniz canlısı olan mantis karidesinin görme sisteminden esinlenilerek ortaya çıkmıştır. Bu canlı, insan gözünün 3 renkle algıladığı cisimleri 16 farklı fotoreseptör pigmentiyle algılar.



Şekil 2.1 Mantis Karidesi

Hiperspektral görüntüler, bilinen diğer sayısal görüntülere göre çok daha fazla bilgi içeren, insan gözünün göremeyeceği dalgalarda işlem yapılabilmesine olanak sağlayan görüntülerdir. İnsan gözü ışığın 400nm - 700nm aralığında dalga boylarını algılayarak, hiperspektral kameralar 350nm – 2500nm arası dalga boyunu algılayabilmektedirler.



Şekil 2.2 YAZGI Laboratuvarı'ndan alınmış hiperspektral kamera görüntüsü

Tek seviyeli, yani gri seviyeli görüntü algılayıcıları görüntünün her bir pikselini tek bir değer olarak algılar ve her bir pikseli bir sayıyla ifade eder. Bu algılayıcılar her bir görüntü için sadece bir matris oluştururlar.

Renkli görüntü algılayıcıları ise, görüntüyü insan gözünün görebildiği kırmızı, yeşil ve mavi renklerle resmeder ve görüntüler her piksel için 3 ayrı bantla kaydedilir. Dolayısıyla renkli görüntüleme, her bir görüntü için 3 adet matris elde edilir.

Hiperspektral görüntü sistemleri diğer görüntüleme sistemlerine göre dalga boyunu çok daha fazla bantta ayırabilir. Bu da daha fazla matris yani daha fazla sayısal bilgi anlamına gelmektedir. Böylece bir görüntü hakkında sensörün özelliklerine göre daha fazla miktarda bilgi toplanabilir.

## 2.2 Hiperspektral Görüntülemenin Kullanıldığı Alanlar

Hiperspektral görüntülemenin kullanıldığı çok çeşitli alanlar vardır;

- Askeri alanda, savunma, hedef tespiti, hedef tanıma, kimyasal ve radyoaktif saldırılarda erken uyarı sistemi gibi uygulamalarda,
- Tarım alanında, ürün kalitesinin belirlenmesi, ürünlerin zararlı etkenlerden korunması, ekonomik ve doğru ilaçlama gibi uygulamalarda,
- Madencilik alanında yeraltı kaynaklarının tespitinde,
- Gıda sektöründe besin güvenliği ve kalitesi konularında,
- Tıp alanında hastalık tespiti, ilaç üretimi gibi uygulamalarda hiperspektral görüntüleme kullanılmaktadır.

Ayrıca uzay araştırmaları, çevre kirliliğinin ve çevresel felaketlerin izlenmesi, biyoteknoloji, adli tıp, jeoloji gibi daha çok çeşitli alanlarda kullanımına sıklıkla rastlanmaktadır.


Hiperspektral görüntüleme sensörleri belli bir hedefi ya da bir alanı taramak ve takip etmek için, özellikle savunma alanında ve askeri alanda kullanılan, diğer görüntüleme sensörlerine göre çok daha fazla bilgi elde edebilen sensörlerdir. Tablo 2-1’de bilinen başlıca hiperspektral sensörler tanıtılmıştır.

Çizelge 2.1 Bilinen hiperspektral görüntüleme sensörleri

ADI	ÜRETİCİ	TİPİ	BANT SAYISI	DALGA BOYU
AVIRIS	NASA Jet PropulsiyonLab.	Uçak	224	400 – 2500 nm
HYDICE	ABD Donanma Araştırma Lab.	Uçak	210	400 – 2500 nm
PROBE-1	Earth SearchSciences Şirketi	Uçak	128	400 – 2500 nm
CASI	ITRES Araştırma şirketi	Uçak	228	400 –1000 nm
Hyperion on EO- 1	NASA Goddard Uzay Uçuş Merkezi	Uydu	220	400 – 2500 nm
FTHSI on MightySat II	ABD Hava Kuvvetleri Araştırma Lab.	Uydu	256	350 – 1050 nm
KSC	NASA Kennedy Uzay Merkezi	Uydu	224	400 – 2500 nm


### 2.3 Spektral İmza

Hiperspektral görüntüler üzerindeki sınıfları birbirinden ayırt etmek, istenen hedefleri bulmak ve sınıflandırmak için görüntü üzerindeki her bir piksel, bir vektör ile ifade edilir.



Şekil 2.3 Spektral İmza

Güneş ışınlarının yeryüzündeki çeşitli yüzeylerden yansımaları sonucu uydu ya da uçaktaki sensörler yardımıyla alınan veriler kaydedilir. Hedef tespitinde her bir hedef bir spektral imza ile temsil edilir. Örneğin bir insana, ağaca, akarsuya ya da durağan bir suya ait spektral imzalar birbirinden farklıdır.



Şekil 2.4 Farklı türdeki maddelere ait spektral imza örnekleri

Her bir spektral imza bant sayısı uzunluğunda bir vektörle ifade edilir. Bu bant sayısı hiperspektral sensörün özelliğine göre değişir. Hiperspektral görüntüler üzerinde işlem yaparken daha başarılı sonuçlar elde etmek için, gürültülü ve ışığın yansımaları sırasında bozulmaların olduğu bantlar uygulamaya dâhil edilmez. Bu bantların kullanılması uygulamanın başarısını negatif yönde etkilemektedir.

#### 3.1 Hedef Tespiti Problemi

Teknolojinin hızla geliştiđi ve birçok bilginin sayısallaştığı evrende, görüntü üzerinde hedef tespiti çok önemli ve değerli bir hale gelmiştir. Savunma ve güvenlik alanları başta olmak üzere birçok alanda başarılı çalışan yöntemlere ihtiyaç duyulmaktadır. Hedef tespiti konusunda bu anlamda çok sayıda çalışma yapılmış ve bu çalışmalarda birçok yöntem önerilmiştir.

#### 3.2 Hedef Tespiti Problemine Önerilen Yöntemler

Bu çalışmada, Kovaryans Tanımlayıcı (KT) yönteminden daha başarılı sonuçlar veren Çekirdek Kovaryans Tanımlayıcı (ÇKT) ve Bileşik Çekirdek Kovaryans Tanımlayıcı (BÇKT) yöntemleri hedef tespiti için önerilmiştir.

##### 3.2.1 Kovaryans Tanımlayıcı

Görüntü üzerinde hedef tespiti konusunda çok çeşitli yöntemler bulunmaktadır. Bu yöntemlerden KT yöntemi güçlü özniteliklerle resmin ya da istenen hedefin tespit edilmesini sağlamaktadır. KT ilk olarak 2006 yılında F. Porikli vd. [1] tarafından ortaya çıkarılmış olup daha sonra birçok çalışmada kullanılmıştır. Yöntemde, tek öznitelik yerine çoklu öznitelik kullanılmasıyla beraber, yöntem istatistiki ve uzamsal bilgiyi

beraber kullanılmasıyla da ön plana çıkmaktadır. Yöntemle görüntünün tamamının ya da hedef bölgenin, belirlenen öznitelikleriyle elde edilen kovaryans matrisinin, hedef bölgeyi temsil edeceği tezi ortaya atılmıştır.

Matematiksel olarak aşağıdaki şekilde ifade edilir;

$$F(x, y) = \Phi(I, x, y) \quad (3.1)$$

Burada,  $I$  gri seviye ya da 3 boyutlu görüntü,  $F$  ise bu görüntüden elde edilen  $W \times H \times d$  boyutlu öznitelik matrisidir.  $\Phi$  yoğunluk, renk ya da filtre cevabı gibi bir fonksiyon olabilir. İstenen hedef olan  $R \subset F$  dikdörtgensel bölgesi için,  $\{z_k\}_{k=1..n}$   $R$  bölgesi içinde öznitelik noktaları olduğunu varsayarsak  $R$  bölgesi  $d \times d$  lik kovaryans matrisi ile temsil edilebilir [1].

Renkli bir görüntü için öznitelik olarak pikselin hedefteki yeri  $(x, y)$ , bu pikseldeki renk değerleri (RGB),  $x$  ve  $y$  değerlerine göre türevleri gibi değerler kullanılabilir.

$$F(x, y) = \left[ x \ y \ R(x, y) \ G(x, y) \ B(x, y) \ \frac{\partial I(x, y)}{\partial x} \ \frac{\partial I(x, y)}{\partial y} \right] \quad (3.2)$$

Yukarıdaki özniteliklere göre hedef bölgenin alanı ne olursa olsun 7 öznitelikle işlem yapıldığı için hedef bölge  $7 \times 7$  kovaryans matrisiyle ifade edilir.

Bu yöntemle görüntü üzerindeki hedef bölgenin belirlenen öznitelik matrisi bulunarak bu öznitelik matrisinden kovaryans matrisi oluşturulur.

$$C_R = \frac{1}{n-1} \sum_{k=1}^n (z_k - \mu)(z_k - \mu)^T \quad (3.3)$$

Yukarıdaki denklemde  $\mu$  noktaların ortalamasını temsil etmektedir. Burada sadece ortalamaları birbirinden farklı olan iki dağılım kolaylıkla birbirinden ayrılabilir [1].

Kovaryans matrisleri birçok özneliği bir arada kullanılmasına olanak tanır. Bu matrislerin diagonal değerleri özniteliklerin varyansını, diagonal olmayan değerleri ise korelasyonları ifade eder. Kovaryans matrisleri simetrik olmalarından dolayı  $d$  öznitelik sayısı olmak üzere sadece  $(d^2 + d)/2$  farklı değere sahiptir. Bu da işlem yükünü ciddi oranda azaltmaktadır.

Hedef bölgenin ya da görüntünün kovaryans matrisi bulunduğundan sonra, ana görüntü üzerinde, hedef bölge boyutlarında her bölgenin de kovaryans matrisi hesaplanarak karşılaştırma hesabı yapılır. Bu hesaplama göre de hedefin nerede olduğu bulunur.

Kovaryans matrisleri Öklid uzayında tanımlı olmayan, pozitif matrislerdir. Bu yüzden karşılaştırma hesabı yapılırken Öklid uzaklığı kullanılamaz. Bunun yerine Förstner ve Moonen [7] tarafından önerilen, kovaryans matrislerinin benzeşmezliklerini ölçen metrik kullanılmaktadır.


$$\rho(C_1, C_2) = \sqrt{\sum_{i=1}^n \ln^2 \lambda_i(C_1, C_2)} \quad (3.4)$$

Verilen denklemde (4.2)  $C_1$  ve  $C_2$  ile belirtilen pozitif tanımlı ve simetrik matrislerin karşılaştırılması,  $\rho$  uzaklık metriği ile yapılır.  $\lambda_i(C_1, C_2)$  değeri  $C_1$  ve  $C_2$  matrislerinin özdeğerleridir.  $\rho$  uzaklık metriği ne kadar küçükse bu iki matris birbirine o kadar benziyor demektir. Uzaklığın sıfır çıkması durumu ise bu iki matrisin aynı olduğu anlamına gelmektedir.

Kovaryans tanımlayıcı poz, görüş açısı ve aydınlatmadan bağımsız olması, birçok özneliği aynı anda kullanabilmesi, düşük boyutlu olması gibi nedenlerden dolayı kullanımı avantajlıdır. Bir bölgeyi temsil eden kovaryans matrisinin boyutu öznitelik sayısı olan  $d \times d$  iken, kovaryans matris kullanılmadığındaki boyutu  $n \times d$  dir [1]. Yani


hedef bölge çok geniş bir alan olsa dahi temsil edilmesi için kullanılan matris öznitelik sayısı boyutlarındadır.

Kovaryans tanımlayıcı ile ilgili yapılan çok sayıda çalışma mevcuttur. Bunlardan kovaryans tanımlayıcıyı öneren Porikli vd. [8] kovaryans matrislerinden nesne tanımlayıcı olarak yararlanmış ve Riemannian manifoldlarına dayanan yeni bir algoritma geliştirmişlerdir. INRIA ve DaimlerChrysler veri setleri üzerinde yüksek başarıyla yaya tespiti yapabilmüşlerdir.



Şekil 3.1 Yaya tespiti örnekleri [8]

2010 yılında Guo vd. [9] hareketle ilgili özniteliklerin log-kovaryans tanımlayıcıları ve Aralıklı Doğrusal Kombinasyon(ADK)(Sparse Linear Combination) çatısı ile hareket tanıma algoritması geliştirmişlerdir.



Şekil 3.2 Log-kovaryans tanımlayıcı kullanarak hareket tanıma algoritmasının genel görüntüsü [9]

Yine Ma vd. [10] tarafından 2014 yılında kovaryans tanımlayıcı ve biyolojik özelliklerden faydalanarak kişi tanıma ve yüz doğrulama algoritmaları geliştirilmiştir. Yapılan testlerde birçok veri setinde başarılı sonuçlar elde edilmiştir.

### 3.2.2 Çekirdek Fonksiyonları


Çekirdek fonksiyonları, ele alınan bir verinin daha yüksek boyutlardaymış gibi incelenmesine olanak sağlayan fonksiyonlardır. Böylece veri içindeki sınıflar birbirinden daha kolay ayrılır.

Klasik Kovaryans Tanımlayıcı (KT), hiperspektral veriler üzerinde başarılı sonuçlar verse de doğrusal olmayan veriler içeren hedef bulma problemlerinde daha başarılı bir yapıya ihtiyaç duyulmaktadır. Bu tip hedeflerin bulunması için kullanılacak yöntemlerden biri doğrusal olmayan sınıflandırıcı kullanmaktır. Doğrusal olmayan sınıflandırıcılar, kullanımı ve hazırlanması zor olan yapılardır. Bu tip sınıflandırıcıların kullanımı yerine, kullanılan veri üzerinde bir çekirdek dönüşümü uygulayarak, sınıfların dağılımını değiştirmek ve sınıfların birbirinden ayrılmasını sağlamak daha avantajlıdır.



$$f(x, y) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (3.5)$$

Denklemden  $\sigma$  standart sapmayı,  $\mu$  ortalamayı ifade etmektedir. Standart sapma, Gauss fonksiyonu eğrisinin yatay yöndeki genişliğini ve basıklığını etkilerken,  $\mu$  değişkeni yatay yöndeki yerini belirler.



Şekil 3.4 Ortalama ve varyansa bağlı değişen Gauss fonksiyonu eğrileri [12]

Denklemden  $\frac{1}{\sigma\sqrt{2\pi}}$  sabiti normalizasyon sabitidir. Bu sabitle Gauss çekirdeği normalize edilmiş bir çekirdek haline getirilir ve eğri altındaki alanın integral hesabı yapılabilir. Gauss fonksiyonunun, görüntü ve sinyal işleme, istatistik, ısı ve difüzyon denklemlerinin çözülmesi gibi alanlarda kullanımına sıklıkla rastlanmaktadır.

Bir diğer çekirdek fonksiyonu ise polinom çekirdek fonksiyonudur.  $d$  polinomun derecesini ifade etmek üzere aşağıdaki denklemle (3.5) ifade edilir:

$$f(x) = (x^T x + c)^d \quad (3.6)$$

Burada  $c$  sabiti fonksiyondaki yüksek dereceli terimlerle, düşük dereceli terimler arasındaki dengeleme sabitidir. Bu değer sıfır ya da sıfırdan büyük bir değer olmalıdır.  $c$  değerinin sıfır olması durumunda bu çekirdek homojen çekirdek olarak adlandırılmaktadır.

Çekirdek dönüşümü daha önce yapılan birçok çalışmada kullanılmıştır. Bu yayınlardan Mika vd. [13] tarafından 1999 yılında önerilen Çekirdek Temel Bileşen Analizi (ÇTBA) yöntemi ile görüntüler üzerindeki gürültünün temizlenmesi amaçlanmıştır. Aynı yöntemle hiperspektral görüntüler üzerinde sınıflandırma yapan Fauvel vd. [14] ÇTBA ile doğrusal TBA yöntemine göre daha başarılı sonuçlar elde etmiştir.

Liu vd. [15] 2008 yılındaki yayınında çekirdek dönüşümünü Fukunaga-Koontz Dönüşümü(FKD) [16] yöntemine uygulayarak kızılötesi görüntülerde hedef tanıma konusunda başarılı sonuçlar elde etmiştir. Yine 2013 yılında Dinç ve Bal [17] tarafından aynı yöntem kullanılarak hiperspektral görüntülerde sınıflandırma uygulaması yapılmıştır. Çalışmada ÇFKD yapılan sınıflandırmanın klasik FKD ve DVM (Destek Vektör Makinesi) yöntemlerinden daha başarılı sonuçlar verdiği belirtilmiştir.

### 3.2.3 Bileşik Çekirdek Fonksiyonları

Bileşik çekirdek fonksiyonları farklı çekirdek fonksiyonlarının bir arada kullanılmasıyla oluşturulan fonksiyonlardır. Birçok klasik yöntemden ve çekirdek yöntemlerinden daha iyi sonuçlar vermektedir. Bileşik çekirdek yapısının kullanımı ile spektral özelliklerin yanı sıra uzamsal özellikler de kullanılabilir. Bu da sınıflandırma başarısını hatırı sayılır derecede artırır.

Bu fonksiyonları kullanırken öncelikle  $x_i$  piksellerinin spektral ve uzamsal vektör tanımlamaları yapılır.  $x_i^S$  ve  $x_i^W$  pikselin spektral ve uzamsal öznitelik vektörleri oluşturulduktan sonra Mercer şartlarına uyan herhangi bir çekirdek dönüşümü ile farklı kernel matrisleri oluşturulur. Bu matrisler oluşturulurken Hilbert Uzayı'nın direk toplanabilme avantajından faydalanılır.

$\varphi_1(\cdot)$  ve  $\varphi_2(\cdot)$  Hilbert Uzayı'nda doğrusal olmayan iki dönüşüm olarak kabul edilirse,  $\emptyset$  birleşik çekirdek dönüşümü olmak üzere;

$$\emptyset(x_i) = \{\varphi_1(x_i^s) + \varphi_2(x_i^w)\} \quad (3.7)$$

$$K(x_i, x_j) = \langle \emptyset(x_i), \emptyset(x_j) \rangle$$

$$K(x_i, x_j) = \langle \{\varphi_1(x_i^s) + \varphi_2(x_i^w)\}, \{\varphi_1(x_j^s) + \varphi_2(x_j^w)\} \rangle$$

$$K(x_i, x_j) = K_s(x_i^s, x_j^s) + K_w(x_i^w, x_j^w) \quad (3.8)$$

şeklinde denklemler hesaplanır [11].

Direk toplamanın yanı sıra, bileşik çekirdek fonksiyonları ihtiva ettiği çekirdek fonksiyonlarının etkisine göre ağırlıklı olarak da toplanabilir.  $\mu$  sayısı sıfır ile bir sayıları arasında gerçek bir değer olmak üzere;

$$K(x_i, x_j) = \mu K_s(x_i^s, x_j^s) + (1 - \mu) K_w(x_i^w, x_j^w) \quad (3.9)$$

denklemini ağırlıklı toplamı ifade etmektedir.

Bunların ötesinde çekirdek dönüşümlerinin birleştirilmesi sırasında  $\varphi_1(\cdot)$  yine Hilbert Uzayı'nda doğrusal olmayan bir dönüşümü,  $k = 1, 2, 3$  değerlerini alırken  $A_k$  doğrusal dönüşümleri ifade etmek üzere;

$$\emptyset(x_i) = \{A_1\varphi(x_i^s), A_2\varphi(x_i^w), A_3(\varphi(x_i^s) + \varphi(x_i^w))\} \quad (3.10)$$

$$K(x_i, x_j) = \langle \emptyset(x_i), \emptyset(x_j) \rangle$$

$$K(x_i, x_j) = K_s(x_i^s, x_j^s) + K_w(x_i^w, x_j^w) + K_{sw}(x_i^s, x_j^w) + K_{ws}(x_i^w, x_j^s) \quad (3.11)$$

Burada dikkat edilmesi gereken spektral ve uzamsal öznelik vektörlerinin aynı boyutlarda olmasıdır. Genel olarak ifade edilirse aşağıdaki şekilde özetlenebilir;

$$K(x_i, x_j) = K_{s1}(x_i^{s1}, x_j^{s1}) + K_{w1}(x_i^{w1}, x_j^{w1}) + K_{s2}(x_i^{s2}, x_j^{s2}) + K_{w2}(x_i^{w2}, x_j^{w2}) + \dots \quad (3.12)$$

Yukarıdaki denklemde (3.3)  $K$  bileşik çekirdek dönüşümü sonucunu ifade ederken  $K_{w1}$ ,  $K_{w2}$ ,  $K_{s1}$  ve  $K_{s2}$  farklı çekirdek dönüşümü sonuçlarını ifade eder. Burada  $K_{w1}$  ve  $K_{w2}$  ele alınan bölgedeki piksellerin sırasıyla ortalama ve standart sapma değerlerinden oluşturulmuş bir çekirdek dönüşümü,  $K_{s1}$  ise spektral bantlar üzerinde yapılmış klasik çekirdek dönüşümü olabilir. Bu örnekte görüldüğü gibi bileşik çekirdek fonksiyonu dönüşümü ile uzamsal özellikler ve spektral özellikler bir arada kullanılabilir. Bunun yanında farklı çekirdek fonksiyonları da hesaplanarak bileşik çekirdek fonksiyonu oluşturulabilir.

2006 yılında Gustau vd. [11] hiperspektral görüntüler üzerinde bileşik çekirdek dönüşümü kullanarak sınıflandırma yapmışlardır. Bu çalışmada standart sapma ve ortalama değerlerinden oluşturulan çekirdek dönüşümü ile spektral boyuttaki çekirdek dönüşümü kullanılmış ve başarılı sonuçlar elde edilmiştir.

Jun Li vd. [18] tarafından 2013 yılında hiperspektral görüntüler üzerinde daha kapsamlı bir bileşik çekirdek dönüşümü yapısı oluşturulmuştur. SVM ve ÇLG(Çokterimli Lojistik Gerileme) yöntemleriyle birçok veri setinde üstün bir sınıflandırma başarısı yakalanmıştır.

**HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ****4.1 Kovaryans Tanımlayıcı ile Hedef Tespiti**

Kovaryans Tanımlayıcı (KT), iki boyutlu görüntülerde kullanılırken bir bölge ya da görüntünün tamamı bir kovaryans matrisiyle ifade edilir. Hiperspektral görüntülerde ise her bir spectral imza aynı şekilde bir kovaryans matrisiyle ifade edilir. Kovaryans matrisi oluşturulurken öncelikle öznelikler belirlenir. Özneliklerin doğru belirlenmesi ve sayısı başarıyı doğrudan etkileyen faktörler arasındadır. Öznelik sayısının artırılması her zaman başarıyı artırmaz.

$$F(x) = \left[ x \quad I(x) \quad I_x \quad I_{xx} \quad \sqrt{I_x^2 + I_{xx}^2} \quad \dots \right] \quad (4.1)$$


Yukarıdaki denklemde (4.1)  $x$ , imzanın bant sırasını,  $I(x)$  bu banttaki reflektans değerini göstermektedir.  $I_x, I_{xx}$  değerleri ise sırasıyla 1. türev ve 2. türevi ifade etmektedir. Burada öznelik sayısı artırılabilir, azaltılabilir ya da farklı öznelikler kullanılabilir. Bu öznelikler kullanıldıktan sonra  $m$  imzanın bant sayısını,  $n$  öznelik sayısını ifade etmek üzere  $m \times n$  boyutlarında bir matris ortaya çıkmaktadır. Bu

matrisin kovaryansı hesaplanarak  $n \times n$  yani öznelik sayısı boyutlarında bir matris ortaya çıkar. Bundan sonra her bir imza bu matrislerle ifade edilir.


Hedef tespiti sırasında ele alınan hedef imza matrisi, veri seti içindeki diğer matrislerle karşılaştırılır. Bu karşılaştırma görüntü işleme uygulamalarında genellikle kullanılan Öklid ya da Mahalonobis uzaklık bulma yöntemleriyle yapılamaz. Bunun nedeni kovaryans matrislerinin Öklid uzayında olmayan, pozitif tanımlı matrisler olmalarıdır. Bu sebepten dolayı kullanılacak olan uzaklık metriği Förstner ve Moonen [7] tarafından önerilen, kovaryans matrislerinin benzeşmezliklerini ölçen metriktir.

$$\rho(C_1, C_2) = \sqrt{\sum_{i=1}^n \ln^2 \lambda_i(C_1, C_2)} \quad (4.2)$$

Tüm imzaların hedef imzaya uzaklığı bir matriste toplandıktan sonra, matris üzerinde doğru pozitif (DP) ve yanlış pozitif (YP) değerleri bulunarak ROC (Receiver Operating Characteristic) eğrileri çizdirilir. Bu eğrinin altında kalan alanların karşılaştırılmasıyla önerilen yöntemlerin performansları ölçülür.



Şekil 4.1 KSC veri seti 3. sınıf KT ROC eğrisi




Şekil 4.2 KT için hedef tespiti işlemi süreci

## 4.2 Çekirdek Kovaryans Tanımlayıcı ile Hedef Tespiti

Hiperspektral görüntülerde kovaryans tanımlayıcı her ne kadar başarılı bir yöntem olsa da bazı sınıflar için bir çekirdek dönüşüm fonksiyonunun kullanılması daha başarılı sonuçlar vermektedir. Bu yöntem uygulanırken klasik KT öznelikleri bulunduğundan sonra, bu öznelik matrisinin kovaryans matrisinin hesaplanması yerine, bir çekirdek dönüşümü yapılır. Bu çalışmada, Gauss çekirdek fonksiyonu (3.5) kullanılmıştır. Aşağıdaki denklem Gauss çekirdek fonksiyonunun normalizasyon sabiti olmadan kullanımını göstermektedir. Bu fonksiyona bazı kaynaklarda Radyal Baz Fonksiyonu (RBF)(Radial Basis Function) tanımlamasıyla rastlanmaktadır.

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{\sigma^2}\right) \quad (4.3)$$

Öznelik matrisinin oluşturulması sonucunda ortaya çıkan  $m \times n$  boyutlarındaki matris, yukarıda belirtilen Gauss Çekirdek Fonksiyonu dönüşümüyle  $m \times m$  boyutlarında bir matrise dönüştürülür. Burada  $m$  spektral imzanın bant sayısını belirtmektedir. Sonuç olarak ortaya çıkan matrisler KT yönteminde uygulanan uzaklık metriğiyle karşılaştırılır ve hedef tespiti başarısı ortaya çıkar. Çekirdek dönüşümünde en önemli etkenlerden biri  $\sigma$  değişkeninin belirlenmesidir. Bu değişken her veri seti, sınıf ve örnek sayısı değişiminde en uygun şekilde ayarlanmalıdır. Değişkenin belirlenmesi performans sonucuna doğrudan etki eden faktörlerden biridir.



Şekil 4.3 ÇKT için hedef tespiti işlemi süreci

### 4.3 Bileşik Çekirdek Kovaryans Tanımlayıcı ile Hedef Tespiti


KT yönteminin kullanımının birçok hiperspektral veri üzerinde başarılı sonuçlar verdiği bilinmektedir. ÇKT yöntemleriyle ise bu başarı daha da artırılabilir. Veri setine göre tek çekirdek dönüşümü yerine daha fazla çekirdek fonksiyonu kullanmak bu başarıyı daha da yukarı seviyelere çekebilir. Burada kullanılacak çekirdek dönüşümleri uzamsal ya da spektral boyutta olabilir.

$$K(x_i, x_j) = K_{s1}(x_i^{s1}, x_j^{s1}) + K_{w1}(x_i^{w1}, x_j^{w1}) \\ + K_{s2}(x_i^{s2}, x_j^{s2}) + K_{w2}(x_i^{w2}, x_j^{w2}) + \dots \quad (4.4)$$

Bu çekirdek dönüşümleri kullanılırken çekirdek fonksiyonunun etkisine göre farklı ağırlıklarla çarparak çekirdek fonksiyonunun sonuca etkisi maksimum başarılı olacak şekilde ayarlanabilir. Ağırlıkların değerleri her biri sıfır ile bir arasında ve toplamları bir olmak üzere aşağıdaki denklemden yararlanır:

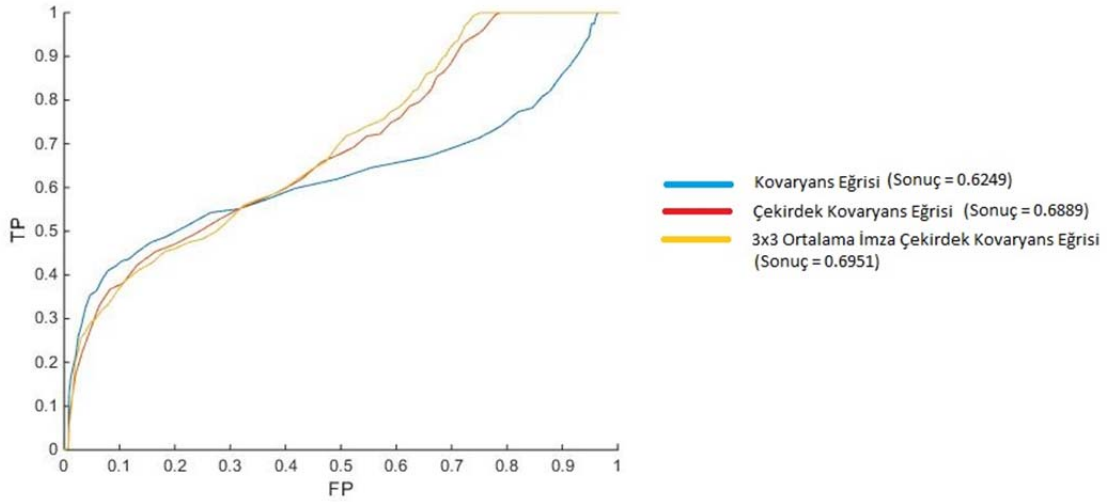
$$K(x_i, x_j) = \alpha K_{s1}(x_i^{s1}, x_j^{s1}) + \beta K_{w1}(x_i^{w1}, x_j^{w1}) \\ + \gamma K_{s2}(x_i^{s2}, x_j^{s2}) + \mu K_{w2}(x_i^{w2}, x_j^{w2}) + \dots \quad (4.5)$$

ÇKT yönteminde spektral imza her ne kadar hedefin karakteristiği hakkında bilgi verse de BÇKT yöntemiyle uzamsal özelliklerin de kullanılması pikseller arasındaki yakın ilişkiden dolayı hedef tespitinde başarıyı ciddi oranda artırmaktadır. Bu çalışmada uzamsal özelliklerin etkisini gözlemlemek adına klasik yaklaşımda  $m \times 1 \times 1$  ile tek imzanın ele alınması yerine, istenen uzamsal alandaki  $m \times k \times k$  matrisi üzerinde işlem yapılmıştır. Burada  $k \times k$  işlem yapılacak uzamsal piksel alanını belirtmektedir. Bu matris alındıktan sonra her bir bant üzerinde  $k \times k$  boyutundaki matrislerden, uzamsal matris bilgileri oluşturularak yeni bir  $m \times 1$  uzunluğunda imza oluşturulur. Örnek olarak, her bir  $k \times k$  matrisinin ortalaması ile yeni bir imza oluşturulabilir.

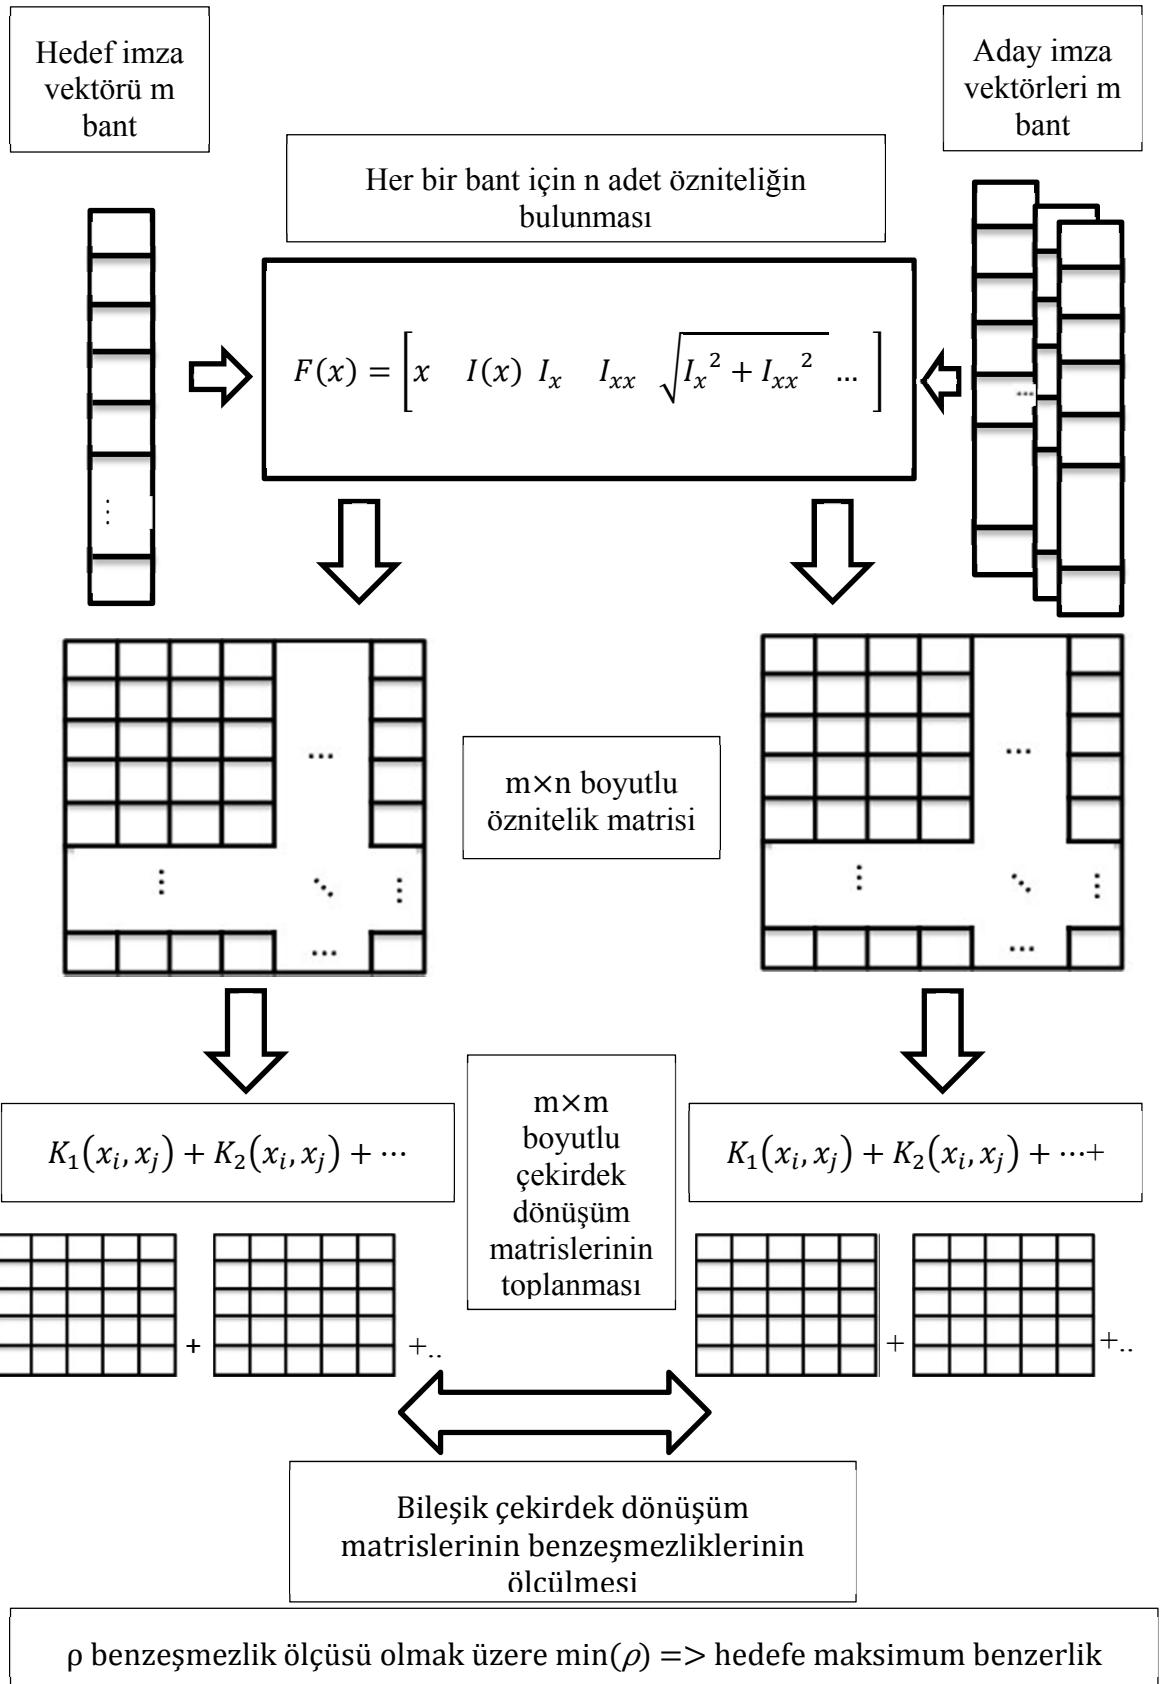


Şekil 4.4 Hedef tespiti sırasında uzamsal bilginin kullanılması

Yeni imza oluşturulduktan sonra spektral imza üzerinde uygulanan tüm yöntemler bu imza üzerinde uygulanır. Bu imzaya uygulanan çekirdek dönüşümü ile klasik çekirdek dönüşümü toplanarak Bileşik Çekirdek Kovaryans Tanımlayıcı (BÇKT) yöntemi de kullanılabilir. Bu yöntemin birçok sınıfta daha başarılı sonuçlar verdiği analiz edilmiştir.



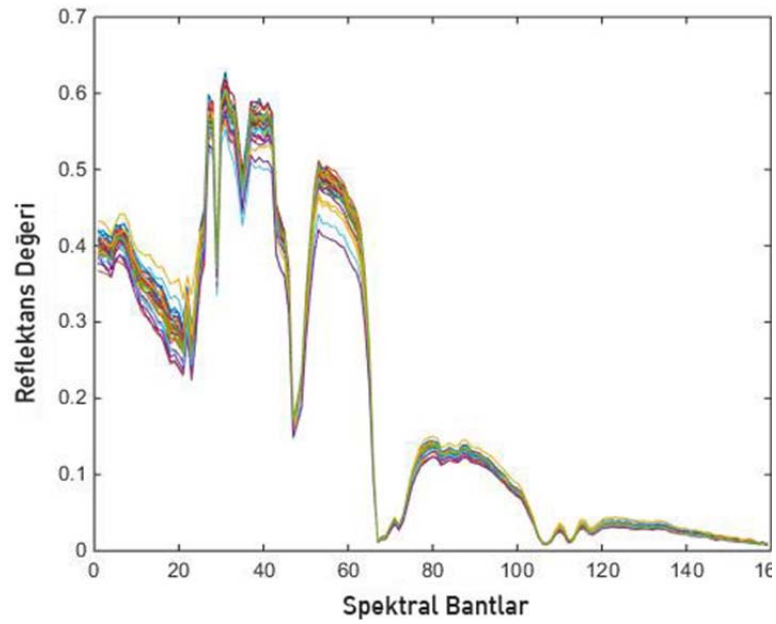
Şekil 4.5 AVIRIS veri seti örnek bir sınıf için KT, ÇKT ve BÇKT ile uzamsal bilgilerin kullanılmasıyla oluşan ROC eğrileri



Şekil 4.6 BÇKT için hedef tespiti işlemi süreci


**DENEYSEL ÇALIŞMALAR****5.1 Metodoloji**

Hiperspektral görüntülerde hedef tespiti konusunda ilk adımda yapılması gereken veri setinin doğrulama verisinin incelenmesidir. Bu aşamada hedef tespiti yapılacak sınıfın spektral imzaları çizdirilerek bant seçimi yapılması hedef tespitindeki başarı üzerinde olumlu yönde etkisi olacaktır.

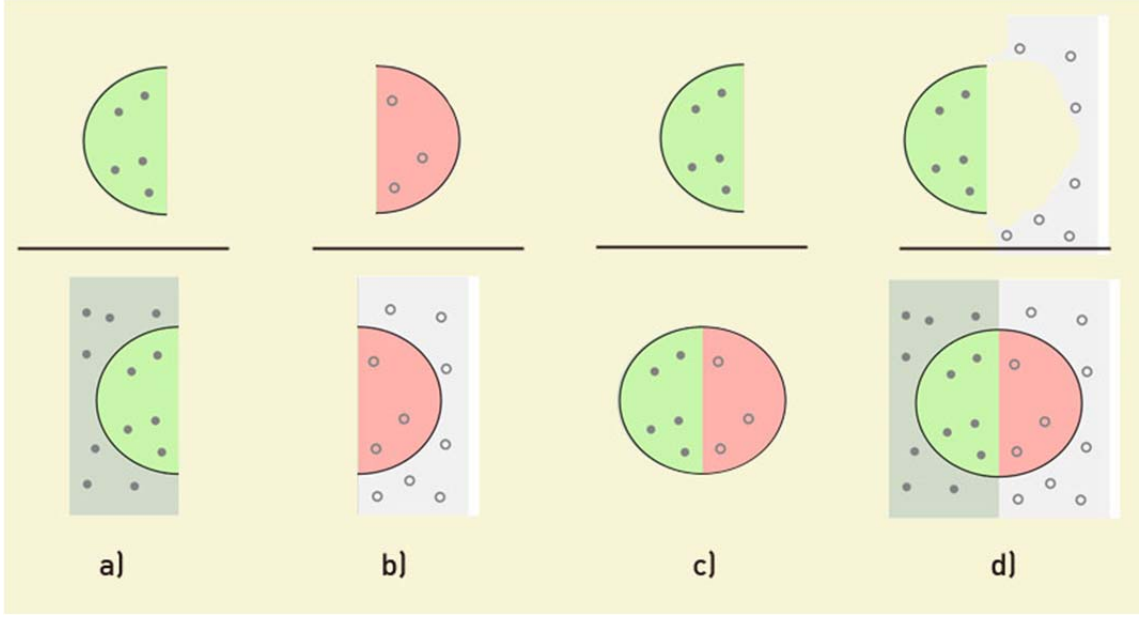


Şekil 5.1 AVIRIS veri seti 1. sınıf verileri için tüm bantların görünümü

Bu aşamadan sonra hedef tespiti için belirlenen sınıf içinden belirli sayıda örnek alınır. Bu örneklerin ortalaması alınarak sınıfın belirleyici imzası olarak kullanılır. Daha sonra bu imza KT, ÇKT ve BÇKT yöntemleriyle veri setindeki diğer piksel imzalarıyla karşılaştırılır. Bu karşılaştırma tüm piksellere ilgili yöntemlerin uygulanarak ortaya çıkan matrislerin eşiklenmesiyle yapılır. Eşikleme sonucunda elde edilen matrisler üzerinde sensitivity (duyarlılık), precision (kesinlik), accuracy (doğruluk) gibi değerlendirme kriterleriyle yöntemlerin başarıları test edilir.



Şekil 5.2 Yöntemlerin başarılarının karşılaştırılması için gerekli terimlerin gösterimi [19]



Şekil 5.3 a) Doğru Pozitif Oranı – DPO (Recall) b) Yanlış Pozitif Oranı – YPO (Yanlış Alarm Oranı) c) Precision (Kesinlik) d) Accuracy (Doğruluk)


Bu çalışmada yöntemlerin başarı karşılaştırılmasında duyarlılık (DPO) - yanlış alarm oranı (YPO) bilgileri kullanılmıştır. Bu bilgilere göre ROC eğrileri çizdirilmiştir.

## 5.2 Kullanılan Veri Setleri

Bu tez kapsamında AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), KSC (Kennedy Space Center), PAVIA ve ÇATALCA01 veri setleri üzerinde çalışılmıştır.

### 5.2.1 AVIRIS Veri Seti

AVIRIS veri seti 400-2500nm dalgaboyları arasında çekim yapabilen bir hiperspektral kamerayla, uçaktan alınmış hiperspektral görüntüleri içerir. Bu hiperspektral veri setinde bant sayısı 224 olmasına rağmen, bu çalışmada bazı problemlili bantlar kullanılmayarak 159 bantla işlem yapılmıştır. AVIRIS veri setinde 16 sınıf bulunmaktadır.




Şekil 5.4 AVIRIS veri seti (RGB)

AVIRIS veri setine ait sınıflar ve örnek sayıları (Tablo 5-1) ile doğrulama matrisi aşağıda gösterilmiştir (Şekil 5.4) ;

Çizelge 5.1 AVIRIS veri setine ait sınıflar ve bu sınıfların örnek sayıları

#	Sınıflar	Örnek Sayısı
1	Yonca	46
2	İşlenmemiş mısır	1428
3	Minimum işlenmiş mısır	830
4	Mısır	237
5	Çimen-Otlak	483
6	Çimen- Ağaçlar	730
7	Biçilmiş çimen-Biçilmiş otlak	28
8	Kümelenmiş Saman	478
9	Yulaf	20
10	İşlenmemiş soya fasülyesi	972
11	Minimum işlenmiş soya fasülyesi	2455
12	Soya Fasülyesi	593
13	Buğday	205
14	Ağaçlık	1265
15	Binalar-Çimen-Ağaçlar-Araçlar	386
16	Taş-Gümüş-Kuleler	93

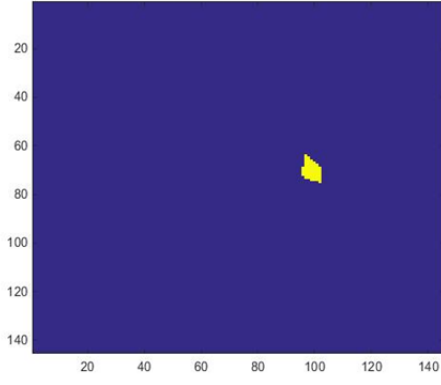


Şekil 5.5 AVIRIS veri seti için doğrulama verisi


AVIRIS veri seti üzerinde yapılan testlerde ÇKT yöntemi Klasik KT yöntemine göre çok daha başarılı sonuçlar vermiştir. Ayrıca BÇKT yöntemi ile başarı artırılmıştır. Aşağıda AVIRIS veri setinden örnek sınıflar için değerlendirme sonuçlarını göstermektedir.

Çizelge 5.2 AVIRIS veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları


	<i>KT</i>	<i>ÇKT</i>	<i>BÇKT</i>
Yonca	0.9556	0.9652	<b>0.9752</b>
İşlenmemiş Mısır	0.5856	0.6264	<b>0.6333</b>
Minimum işlenmiş Mısır	0.6864	0.7082	<b>0.7106</b>
Mısır	0.6249	0.6889	<b>0.6951</b>
Çimen - Otlak	0.8678	0.8688	<b>0.8715</b>




a)



b)




c)




d)

Şekil 5.6 AVIRIS sınıf 1 için; a) Hedef Bölge b) KT sonucu bulunan bölge c) ÇKT sonucu bulunan bölge d) BÇKT sonucu bulunan bölge


Yukarıdaki şekilde AVIRIS veri seti 1. Sınıfa ait hedef bölgenin önerilen yöntemlerle tespit edilmesi gösterilmiştir. Bulunan değerler ile aşağıda ROC eğrisi çizdirilmiştir. ROC eğrisinden BÇKT yönteminin diğer yöntemlerden daha başarılı sonuçlar verdiğini görmekteyiz.



Şekil 5.7 AVIRIS sınıf-1 için ROC eğrisi



Şekil 5.8 AVIRIS sınıf-2 için ROC eğrisi



Şekil 5.9 AVIRIS sınıf-4 için ROC eğrisi

KT yönteminde özniteliklerin belirlenmesi önemlidir. Uygulama sırasında KT yöntemine farklı öznitelikler ekleyerek sonuca etkisi değerlendirilmiştir. Ve birçok sınıfta başarının arttığı analiz edilmiştir. Burada kullanılan özniteliklere çarpıklık(skewness) ve basıklık(kurtosis) öznitelikleri de eklenmiştir. Aşağıdaki tabloda 5 öznitelik ve 7 öznitelik için değerlendirme sonuçları verilmiştir.

Çizelge 5.3 AVIRIS veri seti, KT ve ÇKT için öznitelik artırımı ROC eğrisi değerlendirme sonuçları

	5 öznitelik KT	7 öznitelik KT	5 öznitelik ÇKT	7 öznitelik ÇKT
Yonca	0.9628	0.9687	0.9671	<b>0.9700</b>
Toprak işlemez mısır	0.6848	0.7026	<b>0.7493</b>	0.7181
Min. toprak işlemeli mısır	0.7254	0.7396	0.7266	<b>0.8049</b>
Mısır	0.5655	0.5809	0.6278	<b>0.7996</b>

### 5.2.2 Kennedy Space Center Veri Seti

Kennedy Space Center(KSC) veri seti ise yaklaşık 20 km yükseklikten NASA tarafından alınmış, gürültülü ve ışığın yansımaları sonucu bozulan bantlar çıkarıldığında 176 banttan oluşan bir hiperspektral veri setidir.



Şekil 5.10 KSC veri seti (RGB)

Çizelge 5.4 KSC veri setine ait sınıflar ve bu sınıfların örnek sayıları

#	Sınıflar	Örnek Sayısı
1	Bodur Ağaç	761
2	Söğüt Bataklığı	243
3	Lahana Palmiye	256
4	Lahana Meşe	252
5	Çizgi Çam	161
6	Geniş Yapraklı Hamak	229
7	Parke Bataklık	105
8	Graminoid bataklık	431
9	Spartina bataklık	520
10	Katail bataklık	404
11	Tuz bataklık	419
12	Çamur daireler	503
13	Su	927




Şekil 5.11 KSC veri seti doğrulama verisi

KSC veri seti üzerinde yapılan testlerde genel olarak ÇKT ve BÇKT yöntemleri klasik KT yöntemine göre daha başarılı sonuçlar vermiştir. Ancak ortaya çıkan test sonuçları,


AVIRIS veri setinde başarının daha fazla arttığını göstermektedir. AVIRIS veri seti gibi KSC veri seti üzerinde de bant seçimi daha ayrıntılı yapılırsa başarıya katkı sağlayabilir. Aşağıdaki çizelgede KSC veri setindeki bazı sınıflar için yöntemlerin performans sonuçları gösterilmiştir.

Çizelge 5.5 KSC veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları


	<i>KT</i>	<i>ÇKT</i>	<i>BÇKT</i>
Lahana Palmiye	0.8275	0.8705	<b>0.9244</b>
Lahana Meşe	0.8874	0.8822	<b>0.9087</b>
Geniş Yapraklı Hamak	0.8703	0.8578	<b>0.8776</b>
Graminioid bataklık	0.8919	0.8965	<b>0.9134</b>




Şekil 5.12 KSC veri seti sınıf 3 için ROC eğrisi



Şekil 5.13 KSC veri seti sınıf 4 için ROC eğrisi




Şekil 5.14 KSC veri seti sınıf 6 için ROC eğrisi



Şekil 5.15 KSC veri seti sınıf 8 için ROC eğrisi

### 5.2.3 PAVIA Üniversitesi Veri Seti

PAVIA Üniversitesi tarafından 1.3 metre geometrik çözünürlükle, uçaktan alınmış görüntülerdir. Toplam 9 sınıf ve 610×340 piksel boyutlarında 103 bant içermektedir. Tablo 5-6 PAVIA veri setine ait sınıflar ve örnek sayılarını göstermektedir.




Şekil 5.16 PAVIA veri setinin rastgele 3 bant ile gösterimi

Şekil 5-16 PAVIA Üniversitesi veri setinden rasgele alınmış 3 bandı göstermektedir. Görüntünün bir bölümü anlamsız veri içerdiği için veri setine dahil edilmemiştir.

Çizelge 5.6 PAVIA Üniversitesi veri setine ait sınıflar ve bu sınıfların örnek sayıları

#	Sınıflar	Örnek Sayısı
1	Asfalt	6631
2	Çayır	18649
3	Çakıl	2099
4	Ağaçlar	3064
5	Boyanmış Metal Levhalar	1345
6	Çıplak Toprak	5029
7	Katran	1330
8	Örme Tuğla	3682
9	Gölgeler	947




Şekil 5.17 PAVIA Üniversitesi veri seti doğrulama verisi


Çizelge 5.7 PAVIA veri setinde bazı sınıflar için ROC eğrisi değerlendirme sonuçları

	<i>KT</i>	<i>ÇKT</i>	<i>BÇKT</i>
Asfalt	0.9262	0.9427	<b>0.9568</b>
Çayır	<b>0.8892</b>	0.8379	0.8419
Katran	0.8856	0.8880	<b>0.9237</b>
Gölgeler	0.9853	0.9795	<b>0.9868</b>

PAVIA veri setinde birçok sınıfta hedef tespitinde başarı sağlansa da bazı sınıflarda kovaryans tanımlayıcı daha başarılı sonuçlar vermiştir. Bunun sebebi her sınıf için aynı değişkenlerin kullanılması ve bant seçimi yapılmamasıdır.



Şekil 5.18 PAVIA veri seti sınıf 1 için ROC eğrisi



Şekil 5.19 PAVIA veri seti sınıf 7 için ROC eğrisi

#### 5.2.4 ÇATALCA01 Veri Seti

ÇATALCA01 veri seti ise Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği YAZGI Laboratuvarı tarafından Çatalca, Tekirdağ bölgesinden alınmış görüntüyü içerir. Bu veri seti, 0.4 - 1  $\mu M$  dalgaboyu aralığında 196 spektral bant ve 810×1091 piksel içermektedir. Veri setinde toplam 10 sınıf bulunmaktadır.



Şekil 5.20 ÇATALCA01 veri seti (RGB)

Çizelge 5.8 ÇATALCA01 veri setine ait sınıflar ve bu sınıfların örnek sayıları

#	Sınıflar	Örnek Sayısı
1	Buğday Samanı	67688
2	Araç	494
3	İşlenmiş Buğday Başağı	4139
4	Sürülmüş Buğday Tarlası	3335
5	Kuru Çalılık	4517
6	Yaş Çalılık	145124
7	Merkep	8981
8	Buğday Balyası	38673
9	Yeşil Ayçiçeği	46481
10	İnsan	258



Şekil 5.21 ÇATALCA01 veri seti doğrulama verisi


Bu veri setinin boyutları çok büyük olduğu için veri setinin sadece bir bölümü belirlenerek yeni oluşturulan veri üzerinden çalışılmıştır. Şekil 5.14'te kullanılan bölgenin doğruluk matrisi gösterilmiştir.



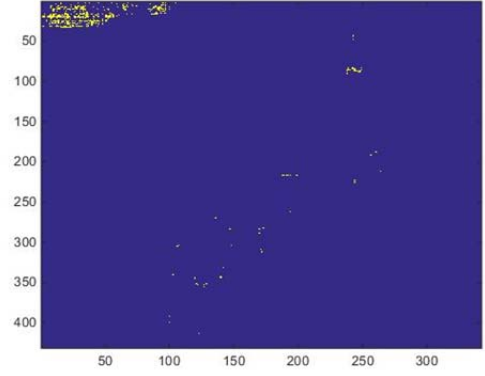
Şekil 5.22 ÇATALCA01 veri setinin küçültülmesi ile oluşturulmuş yeni doğrulama verisi

Çizelge 5.9 ÇATALCA01 veri setinde yapılan testler sonucunda ulaşılan, yöntemlerin performans sonuçları


	<i>KT</i>	<i>ÇKT</i>	<i>BÇKT</i>
Yaş Çalılık	0.9740	0.8730	<b>0.9830</b>
İnsan	0.4987	0.8176	<b>0.9958</b>




a)



b)




c)




d)

Şekil 5.23 ÇATALCA01 sınıf 10 için; a)Hedef Bölge b)KT sonucu bulunan bölge c) ÇKT sonucu bulunan bölge d)BÇKT sonucu bulunan bölge



Şekil 5.24 ÇATALCA01 sınıf 10 (insan hedefi) için ROC eğrisi



Şekil 5.25 ÇATALCA01 sınıf 6 için ROC eğrisi

### SONUÇ VE ÖNERİLER

Bu çalışma kapsamında hiperspektral görüntüler üzerinde çekirdek kovaryans tanımlayıcı (ÇKT) ve bileşik çekirdek kovaryans tanımlayıcı (BÇKT) yöntemleri uygulanmış ve bu yöntemlerle klasik kovaryans tanımlayıcı (KT) yöntemine göre daha başarılı sonuçlar elde edilmiştir. Önerilen yöntemler AVIRIS, KSC, PAVIA ve ÇATALCA01 veri setleri üzerinde test edilmiştir. AVIRIS ve KSC veri setleri üzerindeki testlerde sınıfların birçoğunda başarı artarken ÇATALCA01 ve PAVIA veri setlerinde yalnızca belli hedefler üzerinde başarının arttığı görülmüştür.

BÇKT yöntemi uygulanırken spektral özelliklerin yanı sıra uzamsal özellikler de kullanılmıştır. Bu çalışmada uzamsal özelliklerden sadece hedef pikselin çevresindeki 3×3'lük bölgenin ortalamasından yararlanılmıştır. Burada başka uzamsal özellikler kullanılması ya da hedef bölgenin pencere boyutunun değiştirilmesi sonuca olumlu yönde etki edebilir.

KT ve ÇKT yöntemlerinin uygulanması sırasında farklı görüntü öznitelikleri eklenerek daha başarılı sonuçlar alınmıştır. Çalışma kapsamında eklenen öznitelikler çarpıklık(skewness) ve basıklıktır(kurtosis). Bu özniteliklerin eklenmesinden sonra AVIRIS veri setinde yapılan testlerde, ÇKT yöntemi ile bazı sınıflarda başarı %40 civarında artış göstermiştir.

Bu çalışma, önerilen yöntemlerle başarılı sonuçlar üretmekle beraber ileride çalışılabilecek yeni konular da ortaya çıkarmıştır.

Bu bağlamda çalışma kapsamında kullanılan KT yönteminin öznelikleri ya da öznelik sayısı değiştirilerek daha başarılı sonuçlar elde edilebilir. Ayrıca uygulamada kullanılan Gauss Çekirdek Fonksiyonu yerine farklı çekirdek fonksiyonları kullanılabilir. Bunların dışında çalışmada kullanılan özelliklerden farklı uzamsal özelliklerin kullanılması ve bunların BÇKT yöntemiyle birleştirilmesi başarıyı artırabilir. BÇKT yöntemi uygulanırken çekirdek dönüşümlerinin farklı ağırlıklarla hesaplanması, çekirdek dönüşümlerinin etkisine göre sonuca olumlu yönde katkı sağlayacağı öngörülmektedir.

Çekirdek fonksiyonlarının kullanımı sırasında değişkenlerin belirlenmesi de önemli konulardan biridir. Bu tezde kullanılan Gauss çekirdek fonksiyonu için  $\sigma$  değişkenine deneme yoluyla değer verilmiştir. Ayrıca değişkenler her sınıf için aynı  $\sigma$  değeriyle kullanılmıştır. Bu tip değişkenlerin otomatik olarak belirlenmesi ya da her sınıf için en uygun değişkenin belirlenmesi de ayrıca bir konu olarak değerlendirilebilir.

## KAYNAKLAR

---

- [1] Tuzel, O., Porikli, F. ve Meer, P., (2006), "Region covariance: A fast descriptor for detection and classification", Springer-Verlag Berlin, 589-600.
- [2] Howard, A. ve Padgett, C., (1999). "Intelligent Target Detection in Hyperspectral Imagery", 13. International Conference on Applied Geologic Sensing, Mart 1999, Vancouver, Canada.
- [3] Bruce, L.M. ve Morgan, C., (2001). "Automated detection of subpixel hyperspectral targets with continuous and discrete wavelet transforms" IEEE Geoscience and Remote Sensing, 39:2217-2226.
- [4] Alam, M.S., Islam, M. N., Bal, A. ve Karim, M. A., (2008). "Hyperspectral target detection using Gaussian filter and post-processing", Optics and Lasers in Engineering, 46:817-822.
- [5] Zhang, L., Zhang, L., Tao, D., Huang, X., and Du, B., (2014). "Hyperspectral Remote Sensing Image Subpixel Target Detection Based on Supervised Metric Learning", IEEE Transactions on Geoscience and Remote Sensing, 52(8): 4955-4965.
- [6] Zhang, Y., Gu, Y., (2004). "Kernel-based Invariant Subspace Method for Hyperspectral Target Detection", IEEE, 1520-6149.
- [7] Förstner, W., Moonen, B. (1999). "A metric for covariance matrices". Technical report, Dept. Of Geodesy and Geoinformatics, Stuttgart University.
- [8] Tuzel, O., Porikli, F. ve Meer, P. (2008). "Pedestrian detection via classification on riemannian manifolds", IEEE Transactions on Pattern Analysis and Machine Intelligence, 30(10):1713-1727.
- [9] Guo, K., Ishwar, P., ve Konrad, J. (2010). "Action recognition using sparse representation on covariance manifolds of optical flow", 188-195.
- [10] Ma, B., Su, Y. ve Jurie, F. (2014). "Covariance descriptor based on bio-inspired features for person re-identification and face verification", Image and Vision Computing, 32(6-7):379-390
- [11] Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J. ve Calpe-Maravilla, J. (2006). "Composite kernels for hyperspectral image classification", IEEE Geoscience and Remote Sensing Letters, 3(1):93-97.

- [12] Wikipedia, Gauss fonksiyonu, [https://tr.wikipedia.org/wiki/Gauss\\_fonksiyonu](https://tr.wikipedia.org/wiki/Gauss_fonksiyonu), 9 Kasım 2015.
- [13] Mika, S., Scholkopf, B., Smola, A., Müller, K., Scholz, M., Ratsch, G. (1999). "Kernel PCA and De-Noising in Feature Spaces", IEEE Transactions on Neural Networks, 10-5.
- [14] Fauvel, M., Chanussot, J. ve Benediktsson, J. A. (2007). "Kernel principal component analysis for feature reduction in hyperspectrale images analysis", 238-241.
- [15] Liu, R., Liu, E., Yang, J., Zhang, T. ve Wang, F. (2008). "Detect infrared point targets based on kernel fukunaga-koontz transform", Journal of Infrared and Millimeter Waves, 27(1):47-47.
- [16] Fukunaga, F., Koontz, W. (1970). "Applications of the Karhunen-Lo`eve expansion to feature selection and ordering," IEEE Transactions on Computers, 19:311-318.
- [17] Dinc, S., Bal, A. (2013). "Hyperspectral Image Classification using Kernel Fukunaga-Koontz Transform", Mathematical Problems in Engineering, 2013-7
- [18] Li, J., Reddy Marpu, P., Plaza, A., Bioucas-Dias, J. M. ve Atli Benediktsson, J. (2013). "Generalized composite kernel framework for hyperspectral image classification", IEEE Transactions on Geoscience and Remote Sensing, 51(9):4816-4829.
- [19] Wikipedia, Sensitivity and Specificity, <https://en.wikipedia.org/wiki/Sensitivity-and-specificity>, 9 Kasım 2015.

### KİŞİSEL BİLGİLER

**Adı Soyadı** :Serkan SALTÜRK  
**Doğum Tarihi ve Yeri** :05.04.1985 / Bursa  
**Yabancı Dili** :İngilizce  
**E-posta** :ssalturk@yildiz.edu.tr

### ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Mühendisliği	Esk. Osmangazi Üni.	2009

### İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2009	Yıldız Teknik Üniversitesi	Arş. Gör.

### PROJELERİ

1. Termik Santral Performans İzleme ve Değerlendirme Sistemi Tasarımı Ve Uygulaması (Peridsis) - Araştırmacı

### ÖDÜLLERİ

1. 2011 Proje Pazarı En İyi Tasarım Ödülü (Birincilik)