

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

**TERMAL VE HİPERSPEKTRAL GÖRÜNTÜLERDE HAREKETLİ
HEDEF TESPİTİ VE İZLENMESİ**

HAMİDULLAH BİNOL

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

**DANIŞMAN
DOÇ. DR. ABDULLAH BAL**

İSTANBUL, 2012

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**TERMAL VE HİPERSPEKTRAL GÖRÜNTÜLERDE HAREKETLİ
HEDEF TESPİTİ VE İZLENMESİ**

Hamidullah BİNOL tarafından hazırlanan tez çalışması 24.07.2012 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Abdullah BAL
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç. Dr. Abdullah BAL
Yıldız Teknik Üniversitesi

Doç. Dr. Kayhan GÜLEZ
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Atilla ÖZMEN
Kadir Has Üniversitesi

ÖNSÖZ

Öncelikle, örüntü tanıma ve bilgisayarla görü alanlarıyla tanışmamı sağlayan ve çalışmalarımın her aşamasında ilgi ve tecrübesini yanımda hissettiğim tez danışmanım Doç. Dr. Abdullah Bal'a değerli katkılarından ve desteklerinden dolayı şükranlarımı sunuyorum.

Aralarına katıldığım andan itibaren gösterdikleri sıcak ilgi ve sağladıkları uygun çalışma ortamı nedeniyle Yıldız Teknik Üniversitesi ve özellikle Elektronik ve Haberleşme Mühendisliği Bölümü ailesine de teşekkürlerimi sunuyorum.

Çalışmalarım esnasında bilgi, tecrübe ve arkadaşlıklarıyla yanımda olan Yıldız Teknik Üniversitesi Enformatik Bölümü'nde ve Tübitak'ta görevli çalışma arkadaşlarıma da ayrıca teşekkürü bir borç bilirim.

Son olarak, üzerimdeki emeklerini hayatımın her anında hissettiğim değerli aileme teşekkür ederim. Onların ilgi ve destekleri olmasaydı, bu uzun yol şüphesiz daha zor ve meşakkatli geçecekti.

Mayıs, 2012

Hamidullah BİNOL

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET.....	xi
ABSTRACT.....	xiii
BÖLÜM 1.....	1
GİRİŞ.....	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	5
1.3 Hipotez.....	6
BÖLÜM 2.....	7
TERMAL VE HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ	7
2.1 Termal Görüntüler	7
2.1.1 Termal Görüntüleme Sistemleri ve Kullanım Alanları.....	9
2.2 Hiperspektral Görüntüler	12
2.2.1 HSG ve Spektral İmza	14
2.2.2 Hiperspektral Sensörler ve Kullanım Alanları.....	17
BÖLÜM 3.....	21
HEDEF TESPİTİ VE İZLEME	21
3.1 Hedef Tespiti ve İzleme Problemi	21
3.2 Kullanılan Yöntemler	25
3.2.1 Kovaryans Tanımlayıcı.....	25
3.2.1.1 Uzaklık Metriği.....	27
3.2.2 Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış Yöntemi.....	28
3.2.2.1 Ölçekten Bağımsız Öznitelik Dönüşümü	29
3.2.2.2 Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış.....	35

BÖLÜM 4.....	37
TERMAL GÖRÜNTÜLERDE HAREKETLİ HEDEF TESPİTİ VE İZLENMESİ	37
4.1 ÖBÖDA ile Hareket Sezme	37
4.2 Kovaryans Tanımlayıcı kullanarak Hedef İzleme	39
4.3 Otomatik Hedef Tespiti ve İzlenmesi	40
4.3.1 Kısmi Engel Durumunda Hedef Takibi	43
4.3.2 Engelin Hedefi Tümüyle Gizlemesi Durumu	44
4.3.3 Hedefe Benzer Hareketli Nesne Durumu	46
4.3.4 Hedef ve Arka Plan Benzerliği Durumu	47
BÖLÜM 5.....	50
HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ VE İZLENMESİ	50
5.1 ÖBÖDA ile HSG’de Hareket Sezme	50
5.2 Kovaryans Tanımlayıcı ile Hedef Tespiti	55
5.3 Parçalı Kovaryans Tanımlayıcı ile HSG’de Hedef Tanıma.....	57
BÖLÜM 6.....	64
SONUÇ VE ÖNERİLER.....	64
KAYNAKLAR	66
ÖZGEÇMİŞ	70

SİMGE LİSTESİ

C_R	R bölgesinin kovaryans matrisi
F	Öznitelik matrisi
L	Ölçeksel uzay fonksiyonu
N	Özellik sayısı
Φ	Map fonksiyonu
ρ	Uzaklık metriği
$s_i(p)$	i . görüntünün p noktasından çıkarılmış ÖBÖD tanımlayıcıları
λ_i	Genelleştirilmiş özdeğerler
μ	Ortalama
σ	Standart sapma
z_k	Öznitelik noktaları

KISALTMA LİSTESİ

AVIRIS	Airborne Visible InfraRed Imaging Spectrometer
CIE	Uluslararası Aydınlatma Komisyonu
DoG	Difference of Gaussians
DVM	Destek Vektör Makinaları
EM	Elektromanyetik
HSG	Hiperspektral Görüntüler
HSI	Hyperspectral Imagery
HYDICE	Hyperspectral Digital Imagery Collection Experiment
IEEE	Institute of Electrical and Electronics Engineers
IR	InfraRed
KT	Kovaryans Tanımlayıcı
K-KT	Klasik Kovaryans Tanımlayıcı
ÖBÖD	Ölçekten Bağımsız Öznitelik Dönüşümü
ÖBÖDA	Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış
P-KT	Parçalı Kovaryans Tanımlayıcı
RGB	Red Green Blue
ROC	Region of Convergence
ROI	Region of Interest
SNR	Signal to Noise Ratio
SVM	Support Vector Machines
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1 Termal görüntüler	1
Şekil 1.2 Bölütleme yöntemi ile hedef tespiti	3
Şekil 1.3 Yapay sinir ağları yöntemi ile hedef sınıflandırma	5
Şekil 1.4 Kullanılan HSG ve üzerindeki hedeflerin doğrulama görüntüsü	5
Şekil 2.1 EM spektrum ve kızılötesi bandı	7
Şekil 2.2 Termal görüntü	8
Şekil 2.3 Termal kamera	9
Şekil 2.4 Alaska bölgesinin meteoroloji uydusundan çekilmiş görüntüsü	11
Şekil 2.5 Aynı kişinin farklı zamanlara ait göğüs termografisi	11
Şekil 2.6 Işığın görülebilen dalga boyu aralığı	12
Şekil 2.7 Mantis karidesinin göz yapısı	13
Şekil 2.8 Işığın dalga boylarına göre görüntü türleri	13
Şekil 2.9 Işığın yansıması ile HSG'in elde edilişi	14
Şekil 2.10 Hiperspektral küp verisi ve spektral imza	15
Şekil 2.11 Farklı türdeki maddeler için spektral imzalar	16
Şekil 2.12 Spektral imzalardaki bozulmalar	16
Şekil 2.13 Hiperspektal kamera	18
Şekil 2.14 Elma görüntülerindeki spektral imza farkları	19
Şekil 2.15 İnsan yüzüne ait spektral imzalar	20
Şekil 3.1 Renkli görüntüdeki hedef	22
Şekil 3.2 Nesne temsilleri	24
Şekil 3.3 Kızılötesi görüntüdeki hedefler	24
Şekil 3.4 Doğrusal sınıflandırıcı kullanarak hedef sınıfın ayrılması	26
Şekil 3.5 Hedef bulma	28
Şekil 3.6 Ölçeksel uzay ve DoG elde edilmesi	30
Şekil 3.7 Uç nokta taraması	30
Şekil 3.8 Görüntüde uç nokta taraması	31
Şekil 3.9 Gerçek ve hatalı uç noktalar	31
Şekil 3.10 Zıtlık kurtulumu ve kenar elemesi	33
Şekil 3.11 Kilit nokta tanımlayıcıları	34
Şekil 3.12 ÖBÖD yöntemi ile nesne tespiti	35
Şekil 3.13 Aynı nesne ya da sahne çiftleri için ÖBÖDA sonuçları	36
Şekil 4.1 Ardışık termal video kareleri	37
Şekil 4.2 ÖBÖDA çıkışı	38
Şekil 4.3 ÖBÖDA ile elde edilen akış	38
Şekil 4.4 Morfoloji ile değiştirilen ÖBÖDA çıkışı	39
Şekil 4.5 Kovaryans Tanımlayıcı ile hedef izleme için genel gösterim	40

Şekil 4.6	Hedef şablonları.....	41
Şekil 4.7	Otomatik hedef tespiti ve izlenmesi genel akış diyagramı.....	41
Şekil 4.8	Videonun ilk karesi.....	43
Şekil 4.9	Engel durumunda hedefin izlenmemesi.....	44
Şekil 4.10	Tam engel durumunda hedef izleme sonuçları.....	45
Şekil 4.11	Hedefe benzer hareketli nesne durumu için ilk kare.....	46
Şekil 4.12	Hedefe benzer hareketli nesne durumunda takip sonuçları.....	47
Şekil 4.13	Uçak takibi için ilk video karesi.....	47
Şekil 4.14	Uçak takibi sonuçları.....	48
Şekil 4.15	Yaya takibi için ilk video karesi.....	48
Şekil 4.16	Arka plan benzerliği durumunda yaya takibi sonuçları.....	49
Şekil 5.1	HYDICE verisi doğal görünümü.....	51
Şekil 5.2	HYDICE verisindeki havuza ait imza vektörleri.....	52
Şekil 5.3	Bir piksel boyutlu hedefin hareketi.....	52
Şekil 5.4	Üç piksel boyutlu hedefin hareketi.....	53
Şekil 5.5	Üç piksel boyutlu hedef için ÖBÖDA çıkışı.....	53
Şekil 5.6	Üç piksel boyutlu hedefin hareketi.....	54
Şekil 5.7	Üç piksel boyutlu gürültü eklenmiş hedef için ÖBÖDA çıkışı.....	54
Şekil 5.8	Üç piksel boyutlu hedef için hareketli bölgeler.....	54
Şekil 5.9	Kovaryans tanımlayıcı ile üç piksel boyutlu hedef tespit sonucu	56
Şekil 5.10	AVIRIS verisi ve doğrulama görüntüsü.....	57
Şekil 5.11	Her bir piksele ait imza vektörlerinin korelasyon matrisi.....	60
Şekil 5.12	İmzaların farklı karakterdeki kısımları.....	60
Şekil 5.13	AVIRIS 2 numaralı sınıf için P-KT ve K-KT sonuçları.....	61
Şekil 5.14	AVIRIS 6 numaralı sınıf için P-KT ve K-KT sonuçları.....	62

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Başlıca HSG sensörleri.....	17
Çizelge 4.1 Tek sınıf için karışıklık matrisi.....	41
Çizelge 4.2 Engel durumunda hedefin tespit edildiği son duruma ait piksel sayıları...	44
Çizelge 4.3 Tam engel durumu için karışıklık matrisi.....	46
Çizelge 5.1 HYDICE verisinde ÖBÖDA yöntemi ile ölçülen hareketli alanlar	55
Çizelge 5.2 Üç piksel boyutlu hedef için performans sonuçları	56
Çizelge 5.3 Dört piksel boyutlu hedef için performans sonuçları	56
Çizelge 5.4 Öznitelik vektörleri.....	59
Çizelge 5.5 Öznitelik vektörlerinin tanıma başarıları.....	62
Çizelge 5.6 8 sınıf için yöntemlerin karşılaştırmalı sonuçları	63

TERMAL VE HİPERSPEKTRAL GÖRÜNTÜLERDE HAREKETLİ HEDEF TESPİTİ VE İZLENMESİ

Hamidullah BİNOL

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. Abdullah BAL

Teknolojinin gelişmesiyle, sayısal görüntüleme sistemleri günümüzde birçok alanda uygulanmasının yanında, bir ihtiyaç haline gelmiştir. Özellikle hedef tespiti ve izleme problemi, başta askeri alanlar olmak üzere güvenlik ile ilgili sektörlerin ilgisini çekmektedir.

Farklı tür görüntülerde otomatik hedef tespiti ve izleme yapılabilmeyle birlikte, ısıya duyarlı olma özelliğinden dolayı gece şartlarında da takibe imkan vermesi nedeniyle termal görüntüleme sistemleri özellikle askeri uygulamalarda sıklıkla kullanılmaktadır.

Bununla beraber, görüntü yüzeyindeki materyalin cinsine duyarlı olması ve yüksek spektral çözünürlük sağlaması nedeniyle hiperspektral görüntüler (HSG), diğer görüntülere göre farklı bir konumda durmaktadır.

Bu tezde, termal görüntüler üzerinde, Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış (ÖBÖDA) yöntemi ve Kovaryans Tanımlayıcı (KT) metotlarıyla otomatik hedef tespiti ve izlenmesi gerçekleştirilmiştir. Önerilen yöntem farklı hedef türleri ve izleme senaryoları üzerinde uygulanmıştır.

HSG üzerinde hedef tespiti ve izleme için farklı boyutlarda yapay hedefler hiperspektral veri setine yerleştirilmiş ve yine yapay olarak hareket senaryoları üretilmiştir. Hareketli bölgelerin tespitinde ÖBÖDA yöntemi, tespit edilen alanda hedef tanıma ise KT ile gerçekleştirilmiştir. Ayrıca, hiperspektral veride spektral bantlar arası ilişki göz önünde bulundurularak, parçalı hale getirilmiş KT ile tanıma yapılmıştır.

Yapılan deneylerde, önerilen yöntem performansı, termal görüntüler üzerinde karışıklık matrisleri üzerinden değerlendirilmiştir. HSG üzerinde ise önerilen Parçalı-Kovaryans Tanımlayıcı (P-KT) yaklaşımının hedef tanıma başarısı hem klasik KT (K-KT) yaklaşımı hem de Destek Vektör Makinaları (DVM) ile karşılaştırılmıştır. Karşılaştırmalarda tanıma için önerilen yaklaşımın bazı sınıflarda radyal DVM'den daha iyi sonuçlar verdiği görülmüştür.

Tez kapsamında, termal görüntülerde, farklı senaryolar altında güvenlik uygulamaları için kullanılabilecek bir algoritma geliştirmek amaçlanmıştır. HSG üzerinde ise hem uzamsal hem spektral bilgi kullanılarak piksel seviyesinde hedefler için hareket sezme, tespit ve takip yapılması amaçlanmıştır. Önerilen yöntemlerin bu amaçlara uygun olduğu sonucuna varılmıştır.

Anahtar Kelimeler: Hedef Tespiti ve İzleme, Termal Görüntüler, Hiperspektral Görüntüler, Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış, Kovaryans Tanımlayıcı

ABSTRACT

MOVING TARGET DETECTION AND TRACKING ON THERMAL AND HYPERSPECTRAL IMAGES

Hamidullah BINOL

Department of Electronics and Communications Engineering

M.Sc. Thesis

Advisor: Assoc. Prof. Dr. Abdullah BAL

Digital imaging systems have become a necessity of daily life with the advances in the technology and being used in most areas. It has been catching attention on itself in some areas related to security, in particular military forces, due to problems stemming from target detection and tracking.

Thermal imaging systems are commonly used in military applications because of their feature sensitive to heat which enables to view in nights; automatic target detection and tracking in different images.

In addition to that, hyperspectral images (HSI) have a special place in the field from other image types due to being sensitive to the type of material on the surface of the image and providing high spectral resolution.

In this thesis, automatic target detection and tracking has been realized on thermal images with the methods of SIFT Flow and Covariance Descriptor (CD). The suggested method is applied in different types of targets and tracking scenarios.

For target detection and tracking on HSI, different types of superficial targets are placed over hyperspectral data set, and moving scenarios are superficially produced again. For motion detection, SIFT Flow; for detection in the mentioned area, CD methods are used. Furthermore, on HSI, target recognition is realized by putting different approach to CD method called partial-Covariance Descriptor (p-CD).

In the experiments, the performance of the suggested way is evaluated in thermal images by confusion matrices. On HSG, the performance of recognition is compared

with both classic CD approach and SVM. As a result, it has been found that the suggested way for target recognition gave better results than radial SVM in some classes.


In this thesis, our aim is to develop an algorithm which can be used for security applications of thermal images under various scenarios. As for HSI, we aim to detect, and track motion of pixel level targets while using both spatial and spectral information. We conclude that proposed methods are convenient for this purposes.

Keywords: Target Detection and Tracking, Thermal Images, Hyperspectral Images, Scale Invariant Feature Transform Flow, Covariance Descriptor

1.1 Literatür Özeti

Hedef tespiti ve izlenmesi alanında termal görüntüler kullanılarak yapılmış birçok akademik çalışma mevcuttur. Hiperspektral görüntüler üzerinde sınıflandırma ve hedef tanıma ile ilgili yine birçok çalışma gerçekleştirilmiştir. Bu çalışmalar gözetimli ya da gözetimsiz biçimde farklı yöntemler ile sınıflandırma ve hedef tanıma problemine çözüm önermişlerdir.

Termal görüntüler üzerinde işlemler gerçekleştirilirken, görünür dalga boyu ile elde edilmiş görüntülere göre farklı yaklaşımlar geliştirmek gerekmektedir. İki görüntü türü arasındaki temel fark; görünür dalga boyu ile alınmış resimlerde cisimler ışık yansıtıcılıklarındaki değişimlere göre yer almışken, termal görüntülerde ısı değişimlerine göre resmedilirler. Bu durumun en önemli avantajı termal görüntülerde gece şartlarında hedef tespiti ve izlenmesinin mümkün olmasıdır. Şekil 1.1’de termal görüntü örnekleri gösterilmiştir.



Şekil 1.1 Termal görüntüler (a) İnsan ve araca ait bir termal görüntü (b) Gece alınmış insan görüntüsü (c) Sıcak bir günde alınmış görüntü

Termal kamera teknolojilerindeki kısıtlardan dolayı, termal görüntülerin daha düşük çözünürlükte ve daha düşük hassasiyette olmaları dezavantaj oluşturmaktadır. Bu durum, hedefin yalnız şekil bilgisini kullanarak sınıflandırma yapmayı oldukça güçleştirmektedir. Ayrıca, bu kısıtlardan dolayı, termal görüntüler görünür görüntüler kadar hedef hakkında bilgi içermeyebilirler. Termal görüntülerde tek banttan elde edilen görüntülerin, üç bantlı görünür görüntülere karşı açık olan bu dezavantajları hedef izleme algoritmalarında bazı problemler oluşturmaktadır [1, 2].

Bir çok hedef tespit yöntemi, hedefin arka plandan farklı ısı karakteristiğine sahip olduğundan hareketle çalışmaktadır. Örneğin, bu çalışmada da ağırlıklı olarak tespiti ve izlenmesi üzerinde durulan yayaların arka plandan daha sıcak olduğu düşünülmektedir. Bu varsayım gece ve kış şartlarında genellikle doğrudur. Cielniak ve Duckett tarafından bu varsayım çerçevesinde en basit yaklaşımlardan biri olarak sıcak bölgeleri bölütlemek için eşikleme yöntemi uygulanması önerilmiştir [3]. Bu yöntem nesnelerin gerçek sıcaklıklarını tespit eden kameralar için daha uygun bir yöntemdir.


Diğer bir yaklaşım, görüntü üzerinde hem daha sıcak olan bölgelerin hem de belirgin zıtlığa sahip yerlerin seçilmesine dayanır. Örneğin, Fang vd. [4] tarafından her sütundaki piksel değerlerinin dikey olarak toplanması ve belirgin farka sahip bölgelerin çıkartılması önerilmiştir. Bu yöntem ayrıca bölgelerin yayaya benzerliklerini de tespit etmeye çalışmaktadır. Yöntemde toplama işleminden sonra ilgilenilen bölge tespiti (ROI) için en yüksek ve en düşük parlaklığa sahip pikseller araştırılmaktadır. Conaire vd. [5] farklı bir yaklaşım kullanmışlardır. Görüntünün histogramının kullanıldığı bu yöntemde, hedef bölge, arka planın dağılımının bir Gauss dağılımına benzediği varsayımı altında bölütlenmeye çalışılmıştır. Bu teknikler genel olarak hızlı ve verimlidir ancak hedefin arka plandan soğuk olduğu durumlarda ve sıcak gün şartlarında başarısız olmaktadır. Bununla beraber, termal görüntülemeye gerçekten ihtiyaç duyulduğu gece şartlarında verimli şekilde çalışabilmektedirler.

Arka plan çıkartımı gibi görünür görüntülerde de kullanılan algoritmalar yaz mevsimi durumunda iyi sonuçlar vermektedirler. Torresan vd. [6] tarafından geliştirilen kızılötesi sistemi görünür görüntülerdekiyle aynı arka plan çıkartımı yöntemi ile tespit işlemi yapmaktadır.

Bir yerleşim yerinin kullanıldığı senaryoda, genlik değeri eşiklemesine dayalı bölütleme yöntemini seçen sistemler, arka plandaki sıcak noktaları da tespit eden yöntemlere göre

daha ileri bir sınıflandırma basamağı kullanmak zorundadırlar. Örneğin, Fang vd. çalışmasında çeşitli sınıflandırıcı tekniklerinin bir birleşimi kullanılmıştır. İlk olarak ilgilenilen bölgenin histogramları yaya histogramları ile karşılaştırılır. Ayrıca, parlak piksellerin bölgenin ortasında olması durumu (yaya durumu) ve kenarlarda olması durumu (yaya değil) araştırılır. Son olarak bir tür oran hesabı ile karar verilmeye çalışılır [4].

Sonuç olarak, bölütlemeye dayalı tespit yöntemlerinde çoğunlukla hedefin (yayanın) daha sıcak olduğu varsayımı kullanılmaktadır. İlgilenilen bölge bölütlemesi yaya tespiti durumlarında hızlı ve basit bölütleme algoritmaları ile yapılabilir. Burada dezavantaj olarak diğer sıcak noktaların tespiti de gelmektedir. Bu gibi durumlarda iyi bir sınıflandırıcının gerekliliği ortadadır. Bununla beraber, yayanın arka plana göre sıcak olmadığı durumlarda eşiklemeye dayalı yöntemler başarısız olmakta ve arka plan çıkartımı ya da hareket sezme gibi yöntemlere ihtiyaç duyulmaktadır. Bölütleme yöntemi ile hedef tespiti (Şekil 1.2) termal görüntülerde sıklıkla kullanılmaktadır.



Şekil 1.2 Bölütleme yöntemi ile hedef tespiti (a) Termal görüntü (b) Bölütleme sonucu

Hedef takibi özellikle askeri uygulamalar için hayati öneme sahiptir. Basit bir tanımla takip; hedefin konumu ardışık resimler boyunca değişirken, hedefin güzergâhını izlemektir. Başka bir deyişle; gözlemci, farklı video karelerinde izlenecek olan hedefe, değişmeyen etiketler atmalıdır. Termal görüntülerde hedef izleme ile ilgili literatürde birçok çalışma mevcuttur.

Darrel vd. [7] birden fazla insanı tespit eden ve izleyen interaktif bir yöntem sunmuşlardır. Sunulan sistem, bir doku sezici, bir yüz sezici ve eşitsizlik haritası

(disparity map)'nın birleştirilmesiyle sağlanan bilgiyi kullanarak, hedefi tespit etmekte ve izlemektedir. Bununla beraber, sistemlerinin zayıf yönü önceden tanımlanmış bir renk modeline ihtiyaç duymasındır. Görüntüdeki aydınlanma koşullarının değişmesi [8] durumunda izleme performansında düşüş gerçekleşmektedir. Bu problemi çözmek için dinamik bir doku sezici modeli önerilmiştir [9]. Harville [10] videolardaki insanların yerlerini belirlemek için ilginç bir öneri sunmuştur. Yöntem, tespit işleminden önce çevrenin modelini oluşturmak için karmaşık bir görüntü analizi metodu [11] kullanmaktadır. İnsan izleme işlemi ise biçimi değişmiş şablonlarla birleştirilmiş Kalman filtresi kullanılarak gerçekleştirilmiştir. Sistemin zayıf yönü, yaya benzeri nesnelerde yanlış alarmlara düşmesidir.


Yasunovd. [12] tarafından, sabit bir kameraya ve yayanın baş bölgesinin bakış açısının merkezine yerleştirilmesine ihtiyaç duyulan bir yöntem önerilmiştir. Sistem, yayanın önceki tespit edilen baş bölgesini şablon olarak almaktadır. Ardından, bir şablon eşleme yöntemi ile takip yapmaktadır. F. L. Xu vd. [13] tarafından da Kalman filtresi ve ortalama öteleme algoritmasının birleşimi ile yayanın baş bölgesinin takip edildiği bir yöntem önerilmiştir.

Termal görüntülerde hedef izleme ile ilgilenirken görüntü alınan platformun hareketini (ego motion) de göz önünde bulundurmak gerekmektedir. Bu probleme çözüm olarak çeşitli yöntemler geliştirilmiştir. Örneğin, Fusiello ve Roberto [14] izleme özniteliklerini kullanmışlardır.

Strehl ve Aggarwal [15] tarafından izleme için hareket modeline dayalı bir çoklu çözünürlük seması önerilmiştir. Chellapa ve Irani [16, 17] ise yaptıkları çalışmada optik akış yöntemini kullanmışlardır. Bu yaklaşımlar, ardışık iki resim arasındaki koordinatların basit bir dönüşümünü kullanmaktadır. Braga-Neto ve Goutsias [18] 1999 yılında yaptıkları çalışmada morfolojik operatörlere dayalı bir yaklaşım önermişlerdir. Söz konusu yaklaşım, hedefin boyutlarının değişmediği veya soğuk ya da sıcak karakterde olduğu varsayımına dayanmaktadır. Ayrıca yöntemde algılayıcı hareketi ihmal edilmiştir. Bu varsayımlar, termal görüntü karakteristikleriyle çelişebilmektedir.


Literatürde hiperspektral görüntüler üzerinde sınıflandırma ve hedef tanıma ile ilgili birçok yayın mevcuttur. Howard vd. [19] tarafından 1999 yılında hiperspektral görüntülerde, piksel boyutunda veya daha küçük boyuttaki hedefleri tanımak için hazırlanan çalışma, sınıflandırmadan önce ön işleme basamağından oluşur (Şekil 1.3).

Öncelikle alınan piksel vektörleri gruplara ayrılır ve özvektörleri elde edilerek boyutları indirgenir. Son olarak da yapay sinir ağları (YSA) kullanılarak sınıflandırma yapılır.



Şekil 1.3 Yapay sinir ağları yöntemi ile hedef sınıflandırma [19]

Plaza vd. [20] 2003 yılında sundukları çalışmalarında, hiperspektral görüntüler üzerindeki hedefleri, gözetimsiz bir yöntem olan genişletilmiş matematiksel morfolojik işlemler ile sınıflandırmayı önermişlerdir. Şekil 1.4’de HSG’den seçilmiş bir bant ve doğrulama verisi görülmektedir. 1 ve 2 olarak farklı türlerdeki ağaçlar işaretlenmiştir. Bu sınıfları birbirinden ayırmak amaçlanmıştır.



Şekil 1.4 Kullanılan HSG ve üzerindeki hedeflerin doğrulama görüntüsü [20]

1.2 Tezin Amacı

Bu tez kapsamında termal ve hiperspektral görüntüler üzerinde hareket sezme ve hedef izleme algoritması geliştirmek amaçlanmıştır. Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış yöntemi ve Kovaryans Tanımlayıcı kullanarak otomatik hedef tespiti ve izlenmesi planlanmaktadır.

1.3 Hipotez


Termal ve hiperspektral görüntülerde (HSG) hareket sezme problemi için bu tezde, Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış (ÖBÖDA) yöntemi önerilmiştir. Tespit edilen hareket bölgesinde hedef tanıma ve izleyen video çerçevelerinde hedefin izlenmesi için Kovaryans Tanımlayıcı (KT) kullanılmıştır. Termal görüntülerde otomatik hedef tespiti ve izlenmesi için ÖBÖDA ile KT destekli bir algoritma geliştirilmiştir. Bunların yanında, HSG üzerinde hedef tanıma amacıyla, verinin karakteristiğine göre uyarlanmış KT kullanılmıştır.

TERMAL VE HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ

2.1 Termal Görüntüler

Termal görüntüleme sistemleri, görüntüleme yöntemi olarak gözle görülemeyen IR enerjiyi (ısıyı) esas alan ve görüntünün genel yapısını IR enerjiye göre oluşmuş renkler ve şekillerin belirlediği görüntüleme sistemidir. Genelde güvenlik amaçlı kullanılmakla birlikte çok çeşitli sektörlerin de kullanımına açıktır. Isıya güdümlü füze, gece görüş sistemleri ve benzeri askeri tekniklerin gelişmesi ile önemi artmıştır.

Termal ya da infrared (IR) enerji dalga uzunluğu insan gözünün tespit edemeyeceği kadar uzun olduğu için görünmez olan ışıktır ve bizim sıcaklık olarak algıladığımız elektromanyetik spektrumun bir parçasıdır (Şekil 2.1).



Şekil 2.1 EM spektrum ve kızılötesi bandı [21]

Görünür ışığın aksine, infrared dünyasında mutlak sıfırın üzerinde sıcaklığa sahip her şey ısı yansıtır. Hatta buz küpleri gibi çok soğuk nesneler bile ısı yayarlar. Nesneler oldukça geniş bir tayfta kızılötesi ışınım yayarlar. Ancak algılayıcılar sadece belli bant genişliklerini algılayabildikleri için genellikle kızılötesinden kastedilen belirli bantlardır. Bu sebeple kızılötesi bandı daha küçük alt bantlara bölünmüştür. Uluslararası Aydınlatma Komisyonu (CIE) kızılötesi ışınımı aşağıdaki bantlara ayırmayı teklif etmiştir [22].

- Yakın kızılötesi (**NIR**): 0.75-1.4 μm dalga boyları arasındadır. Düşük kayıp miktarı yüzünden genellikle fiberoptik iletişimde kullanılmaktadır. Gece görüş donanımları da genellikle bu dalga boyunu kullanır.
- Orta dalga kızılötesi (**MWIR**): 3-8 μm . Güzümlü füze teknolojisinde kullanılmaktadır.
- Uzun dalga kızılötesi (**LWIR**): 8-15 μm . Dışarıdan bir ışınım kaynağına gerek duymadan sadece nesnelerin yaydığı ısıyla çalışan termal görüntüleme cihazları bu bandı kullanır.
- Uzak kızılötesi (**FIR**): 15-1,000 μm .

Termal algılayıcıların çektiği fotoğraflarda sıcak bölgeler açık renk, soğuk bölgeler ise koyu renkle gösterilir. En soğuk bölgeyi mavi, en sıcak bölgeyi ise sarı renk gösterir. Ortamın sıcaklığına göre maviden sarıya kırmızı renk kullanarak geçer. Elde edilen görüntüler kullanım amacına göre farklı renk uzaylarında da gösterilebilir. Şekil 2.2’de renkli bir termal görüntü ve aynı resmin gri seviyeli halleri görülmektedir.



(a)

(b)

(c)

Şekil 2.2 Termal görüntü a) Renkli b) Siyah sıcak c) Beyaz sıcak [23]

2.1.1 Termal Görüntüleme Sistemleri ve Kullanım Alanları

Normal kameralar görüntüyü ışık sayesinde oluştururken termal kameralar görüntüyü ısı sayesinde oluştururlar. İnsan beyni ve gözü görüntüyü oluşturmada renkleri ve ışığı kullanırken renk farklılıkları önem kazanmaktadır. Siyah bir duvar önünde bulunan siyah bir objenin farkedilmesi son derece zor olduğu gibi ortam sıcaklığına eşit bir sıcaklıktaki bir objenin termal kamera (Şekil 2.3) ile görüntülenmesi de zordur. Bu tür kameralarda kullanılan objektifler küçük sıcaklık farklarını yakalayabilen (0.01 °C gibi) ve bu farklılıktan görüntü oluşturabilen özelliklerdedir. Ayrıca görüntü oluşturabildikleri belli bir sıcaklık aralığına sahiptirler. Her sıcaklık değerinde farklı IR yayılımlar olduğundan ve her yayılımın farklı dalga boyuna sahip olmasından dolayı da bu objektifler belli sıcaklık aralıklarında görüntü verebilirler. Askeri amaçlı olanlar genellikle doğada bulunan cisimlerin ortak IR yayılımlarının olduğu 8 ile 14 mikrometre dalga boyuna duyarlı oldukları gibi endüstriyel tipte olanlar daha düşük dalga boylarına hassas üretilirler [24].



Şekil 2.3 Termal kamera


Termal görüntüleme sistemlerinin özellikle gece görüşü ve ısıya güdümlü füze tekniklerinin gelişmesiyle öneminin arttığından bahsedilmiştir. Bununla beraber kızılötesi görüntüleme askeri ve sivil birçok alanda kendisine uygulama alanı bulmuştur. Başlıca çalışma alanları:

- Gece görüş sistemleri
- Termografi
- Takip sistemleri

- Meteoroloji
- İklimbilim
- Gökbilim
- Sanat tarihi
- Biyolojik sistemler

Termal görüntülerin kullanıldığı ilgi çekici alanlardan birisi de sanat tarihidir. Sanat tarihçilerinin verdiği isimle kızılötesi reflektogramlar, resimlerin alt katmanlarında yer alan gizli çizimleri gün ışığına çıkartabilir. Karbon siyahı resmin tüm arka planını boyamak için kullanılmadığı sürece reflektogramda iyi görüntü vermektedir. Sanat tarihçileri, sanatçının resim üzerinde daha sonradan yaptıkları düzeltmeleri bu metotla tespit edebilmektedirler. Bu bilgi bir resmin orijinal olup olmadığını anlamada faydalıdır. Genellikle bir resimde ne kadar düzeltme (pentimento) varsa orijinal olma olasılığı o derece fazladır. Bu metot aynı zamanda sanatçının çalışma yöntemine dair de ipuçları verir [25]. Bu tarz bir kullanım diğer tarihçiler arasında da, özellikle eski yazılı eserlerin incelenmesinde kullanılmaktadır. Mürekkebin içinde kullanılan karbon oldukça iyi görüntü vermektedir.

Meteoroloji uyduları termal ve kızılötesi fotoğraflar çekebilen sistemlerle donatılmıştır. Bu fotoğrafları kullanarak analistler bulutların yüksekliklerini ve tiplerini belirleyebilir, kara ve deniz sıcaklıklarını ölçebilir ve okyanus yüzey olaylarını görebilirler. Tarama genellikle 10,3-12,5 μm dalga boylarında yapılır. Meteoroloji alanında bu tür sistemlerin kullanılmasının en önemli avantajı gece de kızılötesi fotoğraf çekmenin mümkün olması sayesinde hava durumunun sürekli izlenebilmesidir. Bu tip kızılötesi görüntüler nakliye endüstrisi için çok önemli olan Gulf Stream gibi okyanus akıntılarının ve anaforların görüntülenmesini de sağlar. Bilgisayarlı renklendirme teknikleri kullanılarak, normalde siyah-beyaz olan termal resimler, ilgilenilen bölgenin daha kolay göze çarpması için renklendirilebilir. Şekil 2.4’de yer yüzeyinin izlenmesi kapsamında 2012 yılında Alaska üzerinden alınmış uydu görüntüleri verilmiştir.



(a)

(b)

Şekil 2.4 Alaska bölgesinin meteoroloji uydusundan çekilmiş görüntüsü

a) Görünür dalga boyu b) Kızılötesi dalga boyu [26]

Kızılötesi görüntüler tıp alanında da özellikle hastalıklı bölgelerin teşhisinde kullanılmaktadır. Vücudun sağlıklı ve hasta bölgelerinin farklı sıcaklık değerlerine sahip olmasından yola çıkılarak kanser gibi ciddi durumların erken teşhisi için özel kameralar üretilmiştir. Gautherie vd. tarafından 1980 yılında 58.000 hasta üzerinde yapılan araştırmanın sonuçları, vücudun sıcaklık anormalliklerinin göğüs kanserinin erken teşhisinde yararlı bilgiler verdiğini göstermiştir [27]. Şekil 2.5’de söz konusu çalışmada yer verilen aynı hastadan farklı tarihlerde alınmış göğüs bölgesi termal görüntüsü gösterilmiştir. Eski tarihli görüntünün gösterildiği Şekil 2.5(a)’da sol kısımda olası kanser başlangıcı şüphesi dikkat çekmektedir. İleriki tarihli görüntüde ise bu teşhisin doğruluğu daha net görülmüştür.




(a)

(b)

Şekil 2.5 Aynı kişinin farklı zamanlara ait göğüs termografisi a) 1974 b) 1975 [27]

2.2 Hiperspektral Görüntüler

Hiperspektral görüntüler diğer sayısal görüntülerin aksine ışığın dalga boyunun insan gözü ile görülemeyen kısımları hakkında da bilgi içeren özel bir görüntü şeklidir. Özel sensörlerle alınan bu görüntülerle genellikle ultraviyole ışınları ile kızılötesi ışınları arasında kalan dalga boyu aralığı kaydedilebilmektedir. Şekil 2.6’da görüldüğü gibi insan gözünün algılayabileceği ışığın dalga boyu aralığı kabaca 400 nm ile 700 nm arasındayken, hiperspektral sensörler 350 nm ile 2500 nm arasını tespit edebilmektedir. Böylece elde edilen görüntülerde klasik görüntülere göre daha fazla karakteristik özellik bulunmaktadır.



Şekil 2.6 Işığın görülebilen dalga boyu aralığı [28]

Hiperspektral görüntüleri algılayan sensörlerin tasarımında bir deniz canlısından ilham alınmıştır. Mantis karidesi olarak bilinen bu canlı, gözlerindeki gelişmiş sensörler sayesinde dünya üzerinde başka hiçbir hayvanda bulunmayan bir algılama yeteneğine sahiptir. İnsanın göz yapısı 3 temel rengi görebilecek bir yapıdayken, mantis karidesinin (Şekil 2.7) 12 ayrı ana renge duyarlılığı vardır. Bu şekilde gözleri bir tür hiperspektral sensör gibi çalışabilmektedir.




Şekil 2.7 Mantis karidesinin göz yapısı

Gri seviyeli görüntü algılayıcıları ışığın sadece görülebilen dalga boyunu algılar ve o aralığı tek bir değer olarak kaydederler. Bu yüzden bu tür resimler sayısal ortamda tek bir matris ile ifade edilmektedir. Tek matris bir piksele ait tek değer dolayısıyla tek özellik anlamına gelmektedir.

Renkli resim algılayıcıları da gri seviyeli algılayıcılara benzer şekilde ışığın görülebilen dalga boyu aralığını algılar. Ancak bu aralığı, insan gözünün duyarlı olduğu 3 ana renge böler. Dalga boyu aralığı 3 parçaya bölündüğü için renkli görüntüler sayısal ortamda 3 farklı matrisin bir araya getirilmesi ile ifade edilir. Dolayısıyla görüntü üzerindeki her bir pikselin üç farklı değeri vardır.

Hiperspektral görüntülerde ise, kullanılan sensörün hassasiyetine göre seçilen bir dalga boyu aralığı çok sayıda parçaya ayrılabilir. Böylece görüntüyü temsil edecek çok sayıda matris oluşacaktır. Bu da her bir piksel için elde edilen matris sayısı kadar özellik anlamına gelmektedir (Şekil 2.8).




Şekil 2.8 Işığın dalga boylarına göre görüntü türleri

Şekil 2.8’den anlaşılacağı üzere, kullanılan kameranın hassasiyeti arttıkça her bir matris için alınan dalga boyu aralığı azalacak ve bu şekilde daha fazla matris elde edilecektir. Elde edilen matrislerin sayısının artması ile görüntünün daha fazla ayırt edici özelliğini ifade etmiş oluruz.

2.2.1 HSG ve Spektral İmza


Yüzeydeki maddenin cinsine göre güneş ışığının belirli dalga boyları emilip, belirli dalga boyları yansıtılır. Yansıyan kısmın bir kısmı insan gözü tarafından hissedilebilir. Hissedilebilenden daha büyük bir aralığa ulaşmak için ise daha duyarlı sensörler kullanılması gerekmektedir. Bu sensörler sayesinde, yüzeyden yansıyan güneş ışınları yakalanabilmektedir.

Şekil 2.9’da güneş ışığının yüzeydeki maddelere çarpıp farklı şekillerde yansması temsil edilmiştir. Bir uydu veya uçağa yerleştirilmiş bir sensör yardımıyla yansıyan ışınlar yakalandığında yüzeydeki nesneler ayırt edilebilmektedir.



Şekil 2.9 Işık yansıması ile HSG'in elde edilmesi [29]


Sensörler aracılığıyla görüntüleme işlemi gerçekleştirildikten sonra Şekil 2.10’da gösterilen küp şeklindeki veri elde edilmiş olur. Şekil incelendiğinde görüntü üzerinden bir piksel için alınan parçanın bir vektör olduğu görülür.



Şekil 2.10 Hiperspektral küp verisi ve spektral imza [29]


Hiperspektral görüntülerde maddenin cinsine göre farklı spektral band değerleri oluşacağından, görüntü üzerindeki piksel vektörleri, yine maddenin cinsine göre birbirlerine benzerlik yada farklılık göstereceklerdir. Şekil 2.11’de görüldüğü gibi resim üzerindeki farklı türdeki alanlara ait piksellerin vektörleri yakın değerlere sahip olacaklardır. Örneğin; göle ait piksellerin vektörleri birbirlerine daha çok benzerken, bir dereye ait piksellerin vektörleri birbirlerine daha çok bezeyecektir. Aynı mantıkla, bu vektörler kumlu bir alana veya bitki örtüsüne ait piksellerin vektörlerinden de farklılık göstereceklerdir.

Görüldüğü gibi bu vektörleri kullanarak görüntü üzerindeki bu alanları birbirlerinden ayırt etmek ve sınıflandırmak mümkündür. Bahsi geçen özellikten dolayı bu vektörlere “spektral imza” denilmektedir. Eğer elimizde, görüntü üzerinde bir karayoluna ait spektral imza varsa, bu görüntüdeki tüm benzer özellikteki yolları da bu imzayı kullanarak anlama imkânı vardır.



Şekil 2.11 Farklı türdeki maddeler için spektral imzalar [30]

Işığın yasıma sırasında uğradığı bozulmalardan dolayı elde edilen spektral bantların bir kısmı hatalı bilgi içerebilmektedir. Örneğin yakalanan görüntüde eğer 200 farklı bant varsa, bunların ortalama 20 ila 30 tanesinde söz konusu bozulmalara rastlanılabilmektedir. Yapılması gereken, görüntüler üzerinden anlamlı bilgiler çıkarmadan önce bozulmalara uğramış olan bantları görüntüden çıkarıp veriyi daha güvenilir bir hale getirmektir. Şekil 2.12’de bozulmuş bantları temizlenmemiş spektral imzalardan örnekler bulunmaktadır. Görüldüğü gibi 140 ile 160 numaralı bantlar arasında ve 200 numaralı banttan sonrasındaki değerler sürekliliği bozmaktadır.



Şekil 2.12 Spektral imzalardaki bozulmalar

2.2.2 Hiperspektral Sensörler ve Kullanım Alanları

HSG sensörler, havadan veya uzaydan dünya yüzeyini tarama amacıyla üretilmiş özel kameralardır. Genellikle bir hava aracında bulunan platform yardımıyla üzerinden geçilen alanın belirli bir kısmı taranır ve hiperspektral görüntü elde edilir. Daha büyük alanları taramak için uydulara yerleştirilmiş sensörler de mevcuttur. Bu sensörler daha çok askeri uygulamalar için kullanılmakta ve çok daha geniş alanların görüntülerini almaktadır. Çizelge 2.1’de bazı bilinen uydu ve uçak sensörleri ve bu sensörlerin özellikleri verilmiştir.

Çizelge 2.1 Başlıca HSG sensörleri

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

Çizelgede gösterilen sensörlerin yanında, daha özel alanlar için üretilmiş, küçük boyutlu görüntüler elde etmek amacıyla tasarlanmış HSG kameralar da vardır (Şekil 2.13). Bu kameralar yardımıyla çeşitli uygulamalar için farklı dalga boyu aralıklarını gözleyip amaca uygun sonuçlar almak mümkündür.




Şekil 2.13 Hiperspektral kamera

Gelişen teknoloji ile birçok alanda hiperspektral görüntüleme sistemleri kullanılır hale gelmiştir. Sonuçlarının diğer görüntüleme sistemlerine göre daha anlamlı olması ve daha fazla bilgi içermeleri sebebiyle savunma sanayiinden sağlık sektörüne birçok araştırmacı çok bantlı görüntüleri tercih etmektedir. Başlıca uygulama alanları:

- Uzaktan Algılama
- Uzay Araştırmaları
- Besin Güvenliği ve Kalitesi
- Adli Tıp
- Biyoteknoloji
- Medikal Bilimler
- Mikroskop Kullanım Alanları
- Askeriye ve Savunma
- Maden arama ve işleme
- İlaç Üretimi


Yukarıda belirtildiği gibi hiperspektral sensörler kullanılarak bahsi geçen alanlarda birçok probleme çözüm önerilmiştir. Kim vd. [31] 2001 yılında yaptıkları bir çalışma kapsamında Amerikan Tarım Bakanlığı bünyesinde besin sağlığı üzerinde durmuş, hiperspektral görüntüler kullanarak besinlerdeki sağlığı bozucu etkileri tespit etmişlerdir. Yaptıkları deneylerde taze elmalar ile bozulmuş elmaların spektral imzalarının farklı olduğunu görüp bu şekilde elmaları sınıflamışlardır (Şekil 2.14).




Şekil 2.14 Elma görüntülerindeki spektral imza farkları [31]

2003 yılında Carrasco vd. [32] hiperspektral sensörler kullanarak çeşitli kanser türleri üzerinde inceleme yapmışlardır. Aynı çalışmada, besinlerin sağlıklı ve taze olup olmadığını da HSG ile tespit etmişlerdir.

Pan ve vd. [33] ise 2003 yılında yayınladıkları çalışmada, hiperspektral görüntüleri kullanarak yüz tanıma gerçekleştirmişlerdir. Bahsedilen çalışmada 200'ün üzerinde yüz görüntüsü kaydedilip incelenmiştir. Sonraki aşamada, yüzün belirli bölgelerindeki imzaların aynı insanların farklı pozları için çok benzer, farklı insanlar için ise dikkat çekici biçimde farklı olduğu sonucuna ulaşmışlardır. Şekil 2.15'de 4 farklı insan resmi için, yüzün belirli bir kısmının spektral imzaları ve aynı insanın 4 farklı pozdaki teninin spektral imzası verilmiştir.



(a)



(b)

Şekil 2.15 İnsan yüzüne ait spektral imzalar (a) 4 farklı insanın yüz resmindeki ten kısmının imzaları (b) Aynı insanın 4 farklı pozdaki teninin spektral imzaları [33]

HEDEF TESPİTİ VE İZLEME

3.1 Hedef Tespiti ve İzleme Problemi

Sayısal görüntüler üzerinde hedef tanıma ve izleme problemi, zamanla daha çok dijital hale gelen dünyada oldukça önemli bir yere sahiptir. Özellikle savunma ve güvenlik sektörü olmak üzere birçok alanda, daha önce kaydedilmiş veya gerçek zamanlı sayısal görüntüler üzerinde hedef tespiti ve izlenmesi, en temel ihtiyaçlardan biridir ve önemi giderek artmaktadır. Hedef izleme algoritmalarında kullanılacak video analizinin üç temel basamağı vardır: ilgili hareketli nesnelerin tespiti, tespit edilen nesnelerin video kareleri boyunca izlenmesi ve nesnelerin davranışlarını tanımak için hareketlerinin analizi.

Basit bir ifadeyle izleme, görüntü üzerinde hareket eden nesnenin izlediği yolu tahmin etmektir. Başka bir deyişle, gözlemci hareket eden nesnelere video kareleri boyunca değişmeyen etiketler atamalıdır. Ek olarak, izleme bölgesine göre değişebilmek koşuluyla gözlemci, nesnenin şekli, bulunduğu bölge ve iki boyutlu koordinat düzlemindeki dönmesi gibi bilgileri de sağlayabilir. Nesne izleme bazı durumlarda ciddi zorluklar içermektedir. Bu durumlar:

- 3B dünyanın 2B’ye indirgenmesinden kaynaklanan bilgi kaybı
- Görüntüdeki gürültüler
- Karmaşık nesne hareketi
- Sabit olmayan nesne yapısı
- Kısmi ve tümüyle etkili olan engeller
- Karmaşık nesne şekilleri
- Görüntüdeki aydınlanmanın değişmesi
- Gerçek zamanlı işleme gereklilikleri

Hedef tanıma, görüntü üzerindeki hedef bölgeleri tespit ve tanıma işleminden oluşmaktadır. Öncelikle, görüntü üzerinde ilgilenilen hedeflerin doğru saptanması gerekir. Bu aşamada, hedefin özelliklerinin bilinmesine gerek yoktur, ileriki aşamada tespit edilen hedefin türünün anlaşılması ile hedef tanıma işlemi tamamlanmış olur. Hedef tespiti, görüntü üzerinde ilgilenilen bölgenin, bilgisayar yardımı ile ortaya çıkarılması anlamına gelmektedir. Oluşturulan algoritma, kendisine verilen görüntüler üzerindeki aranan bölgeyi dışarıdan bir insan desteği olmadan tespit eder. Tespit işleminin ardından hedefin hangi türde olduğunun belirlenmesi tanıma olarak adlandırılır. Hedefler, farklı türlerdeki görüntülerde bulunabilmektedir. Şekil 3.1’de 3 bantlı (renkli) bir görüntü ve üzerinde işaretlenmiş hedef görülmektedir. Çıplak gözle incelendiğinde bile tespit edilmesi zor olan bu tür bir hedef, bilgisayarla görü ile elde edilmeye çalışılmaktadır.




Şekil 3.1 Renkli görüntüdeki hedef [34]

Bir izleme senaryosunda, nesne, ileri aşamadaki analize bağlı olarak herhangi bir şekilde ifade edilebilir. Örneğin, denizdeki bot, akvaryumdaki bir balık, yoldaki araba, yürüyen insanlar gibi hedefler, belirli bir bölgede izlemeye verilebilecek önemli nesne kümeleridir. Nesneler şekilleri ve görünüşleri yardımıyla temsil edilebilirler. Bu kısımda genel olarak kullanılan nesne şekil temsillerinden bahsedilmiştir. Şekil 3.2’de nesne temsil yöntemlerinden bazıları gösterilmiştir.


- *Noktalar.* Bu gösterimde nesne, merkezde bir nokta ya da noktalar kümesi ile temsil edilir (bkz. Şekil 3.2(a)). Görüntüde küçük yer kaplayan nesnelerin izlenmesi için genellikle uygundur.
- *Basit geometrik şekiller.* Nesne, dikdörtgen, elips gibi geometrik şekillerle temsil edilir (bkz. Şekil 3.2(c), (d)). Bu tür geometrik şekiller basit ve sabit şekilli nesneler için daha uygun olmasına rağmen sabit şekilli olmayan nesneler için de kullanılabilir.
- *Nesne silueti ve kontur.* Kontur, bir nesnenin sınırlarını tanımlar (bkz. Şekil 3.2(g), (h)). Konturun içinde kalan bölge ise siluet olarak adlandırılır (bkz. Şekil 3.2(i)). Siluet ve kontur temsilleri sabit şekilli olmayan nesnelerin izlenmesi için uygundur.
- *Birleştirilmiş nesne modelleri.* Birleştirilmiş nesneler, farklı tarz yapıların bir araya getirilmesiyle elde edilir. Örneğin, insan için birleştirilmiş nesne, kol, bacak, baş ve gövde kısımlarının birleştirilmiş hali olarak ifade edilir. Nesne parçalarının temsili için elips ya da silindirler kullanılabilir (bkz. Şekil 3.2(e)).
- *İskelet modelleri.* Nesne iskeleti orta eksen dönüşümü kullanılarak elde edilebilir. Bu model genelde nesnelerin tanınması için kullanılır. İskelet temsili hem birleştirilmiş hem de sabit şekilli nesneler için kullanılabilir (bkz. Şekil 3.2(f)).

Doğru öznitelik seçimi, nesne izleme için kritik öneme sahiptir. Genel olarak, görsel bir öz niteliğin en çok arzu edilen özelliği nesneye has olmasıdır. Böylece, öznitelik uzayında kolayca ayırt edilebilmesi amaçlanır. Öznitelik seçimi, nesne temsiliyle yakından alakalıdır. Örneğin, renk, histogram tabanlı görünüm temsilleri için kullanılan bir öznitelik iken, kontur tabanlı temsil için nesne kenarları öznitelik olarak kullanılır. Birçok izleme algoritması, bu özniteliklerin bir birleşimini kullanmaktadır.



Şekil 3.2 Nesne temsilleri (a) Merkezî (b) Çoklu noktalar (c) Dikdörtgensel çerçeve (d) Eliptik çerçeve (e) Parça tabanlı çoklu çerçeve (f) İskelet (g) Konturdaki kontrol noktaları (h) Tam nesne konturu (i) Nesne silueti [35]

Kızılötesi görüntüler, hedef tespiti ve izlenmesi alanında daha yaygın kullanılan bir görüntü türüdür. Işık yerine ısıya duyarlı görüntüler elde edildiğinden, gece şartlarında da kullanılabilmesi bu tür görüntüleme sistemlerinin en büyük avantajıdır. Ayrıca, tek bantlı görüntüler olduğundan gerçek zamanlı uygulamalar için de daha elverişli oldukları bir gerçektir. Liu vd. çalışmasından [36] alınan kızılötesi bir görüntü üzerindeki hedefler Şekil 3.3’de gösterilmiştir.



Şekil 3.3 Kızılötesi görüntüdeki hedefler [36]


3.2 Kullanılan Yöntemler

Bu tez çalışmasında kullanılan Kovaryans Tanımlayıcı ve Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış yöntemleri için ayrıntılı bilgiye bu kısımda yer verilmiştir.

3.2.1 Kovaryans Tanımlayıcı

Örüntü tanıma alanında çeşitli yaklaşımlar mevcuttur. Bu yaklaşımlardan biri özniteliklere dayanır. Özniteliklere dayalı yaklaşımda, probleme iki alt grupta çözüm aranır. Öncelikle, ilgilenilen nesne, bölge ya da görüntü hakkında olabildiğince fazla bilgi içerecek özniteliklerin çıkarılması gerekir. Diğer aşama ise çıkarılan öznitelikler yardımıyla nesne ya da bölgenin iyi bir sınıflandırıcı ile tespit edilmesidir. Kovaryans Tanımlayıcı (KT) özniteliklere dayalı bir tanımlayıcı olarak F. Porikli vd. [37] tarafından 2006 yılında önerilmiştir. Birden fazla özniteliği bir arada kullanmaya imkân vermesi yöntemin önemli bir avantajı olarak öne çıkmaktadır. Ayrıca, hem istatistiki bilgileri hem uzamsal bilgiyi harmanlama niteliği de bu yöntemi cazip hale getirmiştir. Yöntem kısaca, bir bölgenin öznitelik matrisinden elde edilen kovaryans matrisinin o bölgeyi temsilen kullanılabileceği tezine dayanmaktadır. Yöntem hedef tespiti, yüz tanıma [37] ve nesne izleme [38] gibi alanlarda kullanılmıştır.

KT, gözetimli bir öğrenme yöntemidir denebilir. Yöntem eğitim ve test aşamalarından oluşur. Yöntemi, önerildiği alan olan 2 boyutlu görüntülerde nesne tespiti problemine yaklaşım biçimiyle açıklamaya başlamak yerinde olacaktır. Eğitim aşamasında, hedef bölge yada nesnenin her bir pikselinden elde edilen öznitelikler sütun vektörü haline getirilerek öznitelik matrisi (feature image) oluşturulur. Oluşturulan matrisin kovaryansı hesaplanıp hedefi temsilen kaydedilir. Test aşamasında ise, sorgu görüntüsü üzerinde hedefle aynı ya da farklı boyutlarda çerçevelerle gezilerek, eğitim aşamasında anlatılan biçimde kovaryans matrisleri oluşturulur. Oluşturulan matrislerin hedefin tanımlayıcı matrisi ile benzerlikleri hesaplanır ve sorgu görüntüsünde hedefin olup olmadığına karar verilir. Şekil 3.4’de doğrusal bir sınıflandırıcı kullanarak hedef sınıfın belirlenmesi temsili bir grafikte gösterilmiştir.



Şekil 3.4 Doğrusal sınıflandırıcı kullanarak hedef sınıfın ayrılması

Yöntemin matematiksel analizine geçecek olursak; I bir boyutlu (gri seviyeli) ya da üç boyutlu (renkli) bir görüntü olsun. F ise I görüntüsünden elde edilen $W \times H \times d$ boyutlu öznitelik matrisi olmak üzere,

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

şeklinde tanımlanır [37]. Burada ϕ , genlik, renk, filtre cevabı gibi herhangi bir eşleme fonksiyonu olabilir. Verilen bir $R \subset F$ dikdörtgensel bölgesi için, z_k R bölgesi içinde d -boyutlu öznitelik noktaları olsun. R bölgesi, $d \times d$ boyutlu kovaryans matrisi ile temsil edilebilir.

$$C_R = \frac{1}{n-1} \sum_{k=1}^n (z_k - \mu) (z_k - \mu)^T \quad (3.2)$$

Burada μ , noktaların ortalamasıdır.

Kovaryans matrisini tanımlayıcı olarak kullanmanın birçok avantajı vardır. Bir bölgeden çıkarılan tek bir kovaryans matrisi, o bölgeyi farklı poz ve görüş açılarında dahi tespit etmek için genellikle yeterlidir. Kovaryans matrisi, birbiriyle ilintili olabilecek çeşitli öznitelikleri harmanlamak için doğal bir yol önermektedir. Matrisin köşegenleri, her bir özneliğin değişimini (varyans), diğer bileşenleri ise ilgileşimleri

(korelasyon) vermektedir. Kovaryans hesabı sırasında gelen ortalama alan filtre (average filter) yardımı ile gürültü gidermeden de bahsetmek mümkündür [39].

Kovaryans matrisleri diğer tanımlayıcılara göre daha düşük boyutludur. Bunun sebebi kovaryans matrisinin simetrik olmasıdır, dolayısıyla C_R içerisinde yalnızca $(d^2+d) / 2$ farklı değer vardır. Oysa aynı bölge, ham matris ile temsil edilmek istenseydi, $n \times d$ boyutlu bir tanımlayıcı elde edilecekti.

R bölgesinin kovaryans matrisi, bölgenin nokta sayısı (piksel) ve noktaların sırası ile alakalı doğrudan bilgi içermemektedir. Bu da kovaryans matrisinin farklı görüntülerdeki ölçek (scale) ve dönme (rotation) değişimlerinden etkilenmemesi anlamına gelir. Ancak burada, öz nitelik çıkarımı yapılırken dönme ve aydınlatmaya (illumination) bağlı istatistiklerin seçiminin önemli olduğunu hatırlatmak gerekir.

3.2.1.1 Uzaklık Metriği


Kovaryans matrisleri Öklid uzayında değildir. Örneğin, negatif sayılarla çarpmaya karşı uzayları kapalı değildir. Başka bir deyişle pozitif tanımlı matrislerdir. Bu özelliklerinden dolayı örüntü tanımada sıklıkla kullanılan Öklid ya da Mahalanobis uzaklığı gibi yöntemlerin uygulanması mümkün değildir. Bunların yerine, W. Fröstner ve B. Moonen kovaryans matrislerinin benzeşmezliklerini ölçmek için bir uzaklık metriği önermişlerdir [40].

$$\rho(C_1, C_2) = \sqrt{\sum_{i=1}^n \ln^2 \lambda_i(C_1, C_2)} \quad (3.3)$$

Burada $\{\lambda_i(C_1, C_2)\}_{i=1 \dots n}$ C_1 ve C_2 matrislerinin genelleştirilmiş özdeğerleridir ve

$$\lambda_i C_1 x_i - C_2 x_i = 0 \quad i = 1 \dots d \quad (3.4)$$

şeklinde hesaplanır. Uzaklık ölçüsü ρ , pozitif tanımlı simetrik C_1 ve C_2 matrisleri için metrik aksiyomlarını sağlamaktadır. Tanımlanan metrik, benzeşmezlikleri ölçtüğünden Denklem 3.3 sonucu oluşan değer ne kadar küçükse, söz konusu matrislerin o kadar benzediği söylenebilir. Bu değerın sıfır olması, yalnız iki matrisin eşit olduğu durumda gerçekleşir. Kovaryans Tanımlayıcı kullanarak yapılan hedef bulma uygulaması sonuçları Şekil 3.5’de gösterilmiştir.



Şekil 3.5 Hedef bulma (a) Hedef alanlar (b) Kovaryans tanımlayıcı ile bulunan hedefler (c) Histogram ile bulunan hedefler [37]

3.2.2 Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış Yöntemi

Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış yöntemini anlayabilmek için öncelikle Ölçekten Bağımsız Öznitelik Dönüşümü'nü incelemek gerekmektedir.

3.2.2.1 Ölçekten Bağımsız Öznitelik Dönüşümü

Ölçekten Bağımsız Öznitelik Dönüşümü (ÖBÖD) 1999 yılında, David G. Lowe tarafından nesne tanıma problemine çözüm olarak önerilmiş bir yöntemdir [41]. D. Lowe yaptığı çalışmada nesnenin dönmesinden, ölçek değişiminden, gürültü ve ışık değişimi gibi bozucu faktörlerden etkilenmeyen bir dönüşüm geliştirmiştir. Yöntemle belirlenen nokta tanımlayıcılarının; görüntüdeki döngüsel, boyutsal, üç boyutlu ve parlaklık değişimleri ile gürültüye karşı en dayanıklı yöntemlerden biri olması sebebiyle özellikle 2000'li yıllardan itibaren bu metod, örüntü tanıma alanında sıklıkla kullanılmıştır.

ÖBÖD metodu genel olarak dört aşamadan oluşmaktadır:

- Ölçeksel uzaydaki uç noktaların (minimum - maksimum) elde edilmesi
- Kilit noktaların konumlarının belirlenmesi
- Döngüsel değişime karşı dayanıklılık kazanılması
- Kilit nokta tanımlayıcılarının bulunması

Ölçeksel uzayda değişmeyen kilit noktalar bulmak için birçok teknik kullanılabileceği düşünülmekteydi. Bunlardan biri de DoG (Difference of Gaussians, Gauss Farkı) metodudur. Koenderink ve Lindeberg yaptıkları çeşitli varsayımlar sonucunda ölçeksel uzayın Gauss fonksiyonu kullanılarak oluşturulabileceği sonucuna varmışlardır [42]. ÖBÖD yönteminde de, DoG metodu kullanılmıştır.

Uç noktaları aramaya geçmeden önce ölçeksel uzayın oluşturulması gerekir. Bunun için orijinal resim farklı standart sapmaya sahip Gauss filtrelerinden geçirilir. I , orijinal resim, G , değişken orantıya sahip Gauss fonksiyonu olmak üzere, ölçeksel uzay fonksiyonu,

$$L(x, y, k\sigma) = G(x, y, k\sigma) * I(x, y) \quad (3.5)$$

şeklinde tanımlanır. G ile gösterilen Gauss fonksiyonunun ise,


$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (3.6)$$

olduğu bilinmektedir.

DoG fonksiyonu olan $D(x, y, \sigma)$, biri diğerine göre k kadar orantılı büyüklüğe sahip Gauss filtreli iki resim arasındaki farkın sonucunda elde edilir.


$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) \quad (3.7)$$

Yapılan analizler, resmi Gauss filtresinden geçirmek ile Laplace dönüşümünü elde etmek arasında ciddi bir benzerlik olduğunu göstermiştir. Şekil 3.6'da ölçeksel uzayın oluşumu ve DoG resimlerinin elde edilmesi gösterilmiştir.



Şekil 3.6 Ölçeksel uzay ve DoG elde edilmesi

Uç noktaların bulunması için her DoG resmi taranır. Resimlerdeki her pikselin 3 x 3 çerçevede tüm komşulukları gezilerek noktanın uç nokta (minimum ya da maksimum) olup olmadığı araştırılır. Burada komşuluklara ölçeksel uzaylar da dâhildir. Böylece bir pikselin 26 tane komşusu oluşmaktadır. Şekil 3.7'de uç nokta taraması için olası komşuluklar gösterilmiştir.




Şekil 3.7 Uç nokta taraması

Şekil 3.8’de uç nokta taraması gösterilmiştir.



Şekil 3.8 Görüntüde uç nokta taraması (a) Orijinal resim (b) Uç noktalar

Elde edilen uç noktalar ham piksel sayısından küçüktür ama halen oldukça fazla sayılır, üstelik gerçek uç noktalar olmayabilir. Şekil 3.9’da gerçek ve hatalı uç noktalara örnekler gösterilmiştir.



Şekil 3.9 Gerçek ve hatalı uç noktalar [43]

Bir önceki aşamada elde edilen uç noktalar kilit nokta adaylarıdır. Bu aşamada kararlı olmayan yani düşük zıtlığa (kontrast) sahip (dolayısıyla gürültüden daha çok etkilenen) veya kenarlarda zayıf olarak tespit edilmiş kilit nokta adaylarının ayıklanması sağlanır. Düşük kontrasta sahip noktaların ayıklanması, DoG fonksiyonunun kilit aday nokta

temel olmak üzere ikinci dereceden Taylor serisi açılımı yapılarak gerçekleştirilir. Uç noktaların yeni konumları,

$$\hat{x} = -\frac{\partial^2 D^{-1}}{\partial x^2} \frac{\partial D}{\partial x} \quad (3.8)$$

ile hesaplanır. Ardından,

$$D(\hat{x}) = D + \frac{1}{2} \frac{\partial D^T}{\partial x} \hat{x} \quad (3.9)$$

elde edilir. Burada, DoG fonksiyonu olan $D(x,y,\sigma)$ ve türevi, her uç nokta için hesaplanır ve $|D(x)| < 0.02$ ise elenir.


Kenarlarda tespit edilen kilit noktalar ise Hessian matrisi kullanılarak elenir. D , DoG fonksiyonu olmak üzere, Hessian matrisi H ile gösterilir.

$$H = \begin{bmatrix} D_{xx} & D_{xy} \\ D_{yx} & D_{yy} \end{bmatrix} \quad (3.10)$$

a , büyük olan öz değeri, b , küçük olan öz değeri göstermek ve $r = a/b$ olmak üzere, ÖBÖD kriteri,

$$R = \frac{(r+1)^2}{r} \quad (3.11)$$

olarak belirtilmiştir [44]. Şekil 3.10'da resmin, düşük zıtlık kurtulumu ve kenar nokta elemesi gerçekleştirilmiş hali gösterilmiştir.



(a)

(b)

Şekil 3.10 (a) Düşük zıtlık kurtulumu (b) Zıtlık kurtulumu ve kenar elemesi

Taylor serileri kullanılarak uç nokta hataları temizlenmeye çalışılırken, filtreleme ve eşiklemeler uygulanarak kilit noktaların sayısı düşürülür. Bu amaçla, her bir nokta etrafında bir bölge seçilir. Uygun yumuşatılmış görüntü üzerinde gradyan değerinin büyüklüğü ve açı değerleri hesaplanır [45]. Yöntemin bu aşaması, resmin ya da hedefin iki boyutlu eksen etrafında dönmesine karşı dayanıklılık kazanılması için önemlidir. Bu aşamada, her kilit noktaya bir veya birden fazla döngüsel atama yapılmaktadır. Daha önce, σ ölçekli Gauss filtresinden geçirilmiş resim olan $L(x, y, \sigma) = G(x, y, \sigma) * I(x, y)$ kullanılarak gradyan büyüklüğü $m(x,y)$ ve açısı $\theta(x,y)$ hesaplanır.


$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2} \quad (3.12)$$

$$\theta(x, y) = \tan^{-1}((L(x, y + 1) - L(x, y - 1)) / (L(x + 1, y) - L(x - 1, y))) \quad (3.13)$$

Büyüklik ve yön hesaplaması, Gauss filtresinden geçirilmiş resimde bulunan kilit noktaların her komşu pikseli için yapılır. Kilit noktaların etrafında, her biri 10 derecelik bir yönü kapsayan 36'lık bir döngüsel histogram oluşturulur. Ardından, histograma eklenen komşu her örnek nokta, kendi gradyan büyüklüğü ile ağırlıklandırılır. Kilit nokta tanımlaması, histogramda en büyük değere sahip nokta, %80'i içinde kalan noktadır şeklinde yapılmıştır. Noktaların yaklaşık %15'i için çoklu döngüsel atama

yapılmış olmasına rağmen bu işlem eşleşmelerdeki kararlılığı önemli ölçüde artırmaktadır.

ÖBÖDA yöntemine geçmeden önce kilit nokta tanımlayıcılarının bulunması gerekir. Bu aşamada, diğer değişimlere (parlaklık değişimleri, üç boyutlu görünüm vb.) karşı dayanıklılık kazanılması amaçlanmaktadır. İlk olarak, kilit nokta etrafında gradyan büyüklükleri ve açıları kilit noktanın ölçeksel büyüklüğü kullanılarak $n \times n$ 'lik alanda örneklenir. Döngüsel değişmezliği sağlamak için, kilit nokta tanımlayıcının konumu ve gradyan açıları, kilit nokta açısı temel alınarak döndürülür. Bu aşamanın adımları, döngüsel dayanıklılık kazanım işleminde yapılanlara benzemektedir. Sekizlik vektörler, kilit noktanın etrafında bulunan $n \times n$ 'lik alanın içinde kalan her bir nokta için tanımlanır. Dolayısıyla her bir kilit nokta için tanımlanan vektörün uzunluğu $(n \times n \times r)$ olur. Güncel uygulamalarda 4×4 'lük tanımlayıcı kullanılmaktadır. Dolayısıyla $4 \times 4 \times 8 = 128$ noktalı tanımlayıcı, her kilit nokta için elde edilmiş olur. Şekil 3.11'de 4×4 'lük tanımlama değerlerinin 16×16 'lık örnekten nasıl oluşturulduğu gösterilmiştir.



Şekil 3.11 Kilit nokta tanımlayıcıları

Şekil 3.12'de gri seviyeli bir resimde ÖBÖD yöntemi ile tespit edilmiş nesneler gösterilmiştir.



(a)

(b)

(c)

Şekil 3.12 (a) Sorgu görüntüleri (b) Orijinal resim (c) ÖBÖD ile tespit edilmiş konumlar


3.2.2.2 Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış

Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış (ÖBÖDA) yöntemi Ce Liu ve arkadaşları tarafından 2008 yılında önerilmiş bir yöntemdir [46]. Yöntem klasik optik akışa [47, 48, 49] ÖBÖD üzerinden yeni bir yaklaşımla gerçekleştirilmiştir. Yöntem, ÖBÖD ile elde edilen tanımlayıcıların, piksel yer değişimlerine karşı sabit oldukları varsayımıyla başlar. ÖBÖD tanımlayıcıları, pozla değişmeyen ve parlaklıktan bağımsız karakterleriyle, önemli ölçüde farklı içeriklere sahip resimlerde bile anlamlı eşleştirmeler yapabilmektedir. Önemli bir diğer nokta, bir görüntüdeki bir pikselin diğer görüntüdeki bir pikselle eşleşebilmesine imkân tanınmıştır. Bu, piksel değişiminin görüntünün boyutu kadar olabileceği anlamına gelmektedir. Bununla birlikte, yöntem uzamsal uyumluluğu (spatial coherence) sağlamayı da ihmal etmemektedir.

Görüntü kafesi [50, 51] üzerinde bir ayırık en uygun şekle sokma problemi olarak uyum araştırması için maliyet fonksiyonu tanımlanmıştır.

$$E(w) = \sum_p \|s_1(p) - s_2(p + w)\|_1 + \frac{1}{\sigma^2} \sum_p (u^2(p) + v^2(p)) + \sum_{(p,q) \in \mathcal{E}} \min(\alpha|u(p) - u(q)|, d) + \min(\alpha|v(p) - v(q)|, d) \quad (3.14)$$

Fonksiyonda, $w(p) = (u(p), v(p))$, $p = (x, y)$ piksel noktasındaki yer deęiřtirme vektörü, $s_i(p)$, i görüntüsünün p noktasından çıkarılmış ÖBÖD tanımlayıcısı ve ε bir pikselin uzamsal komřuluklarını ifade etmektedir. Yöntem 4-komřuluk üzerinden hesaplarını yapmaktadır. Maliyet fonksiyonunun parametreleri yapılan deneyler sonucu, $\sigma = 300$, $\alpha = 0.5$ ve $d = 2$ olarak bulunmuřtur. řekil 3.13’de ÖBÖDA yöntemi ile elde edilmiř uyumluluk karřılıkları gösterilmiřtir.




řekil 3.13 Aynı nesne ya da sahne çiftleri için ÖBÖDA sonuçları (a) Sorgu resimleri (b) ÖBÖD tanımlayıcıları (c) En iyi eřleřmeler (d) ÖBÖD tanımlayıcıları (e) (c)’nin (a) resmi üzerine bükülmesi (f) Bükülmüř ÖBÖD görüntüsü ((d)’nin (b) üzerine) (g) Tahmin edilen yer deęiřtirme alanı [46]

TERMAL GÖRÜNTÜLERDE HAREKETLİ HEDEF TESPİTİ VE İZLENMESİ

Bu bölümde Ölçekten Bağımsız Öznitelik Dönüşümü tabanlı Akış ve Kovaryans Tanımlayıcı yöntemleri kullanılarak termal görüntüler üzerinde hareketli hedef tespiti ve izlenmesi üzerinde durulmuştur. Ardışık video karelerinde hareket sezme için ÖBÖDA kullanılmıştır. Hareketli bölgelerdeki örüntünün tanınması ve hedef olup olmadığına ise KT yöntemiyle karar verilmiştir. Tespit edilen hedef, yine KT kullanılarak videoda bulunduğu süre boyunca izlenmiştir. Performans ölçütü olarak karışıklık matrisleri kullanılmıştır.


4.1 ÖBÖDA ile Hareket Sezme

Hareket sezme ÖBÖDA yöntemiyle gerçekleştirilmiştir. Yöntemde uygun parametrelerin kullanılmasıyla ardışık video karelerinde hareketli bölgelerin tespit edilmesi mümkün olmuştur. Şekil 4.1’de ardışık iki video karesi verilmiştir.



Şekil 4.1 Ardışık termal video kareleri (a) İlk kare (b) İkinci kare

Şekil 4.1’de gösterilen iki kareye ÖBÖDA uygulandığında elde edilen yatay ve dikey akış sonuçları Şekil 4.2’de verilmiştir.




Şekil 4.2 ÖBÖDA çıkışı (a) Yatay akış (b) Dikey akış

Yatay ve dikey akışların birleştirilmesi ve renklendirilmesiyle elde edilen toplam akış Şekil 4.3’de gösterilmiştir.



Şekil 4.3 ÖBÖDA ile elde edilen akış

Şekil 4.3’de renkli olarak gösterilen bölgeler yöntemin tahmin ettiği hareketli bölgelerdir. Bu bölgelerde, açma, kapama gibi sık kullanılan morfolojik işlemler ve eşikleme gibi görüntü işleme yöntemleri kullanılarak, videoda hedef aramaya uygun hareket bölgeleri elde edilebilir. ÖBÖDA çıkışına yapısal eleman olarak karenin kullanıldığı kapama işlemi uygulandığında elde edilen sonuç Şekil 4.4’de gösterilmiştir.



Şekil 4.4 Morfoloji ile değiştirilen ÖBÖDA çıkışı

4.2 Kovaryans Tanımlayıcı kullanarak Hedef İzleme


Kovaryans tanımlayıcı ile hedef izleme uygulamasında, öncelikle hedefin bir başlangıç değeri olarak gözlemci tarafından işaretlenmesi gerekmektedir. Bu çalışmada hedef konumu dikdörtgen çerçeve ile temsil edilmiştir. Bu çerçevenin her pikselinden elde edilen öznitelik vektörlerinin oluşturduğu öznitelik matrisinin kovaryansı ise hedef tanımlayıcısı olarak kullanılmıştır. Öznitelik vektörünün oluşturulması için her pikselden 7 adet öznitelik çıkarılmıştır.

$$F(x, y) = [x \ y \ I(x, y) \ \left| \frac{\partial I(x, y)}{\partial x} \right| \ \left| \frac{\partial I(x, y)}{\partial y} \right| \ \left| \frac{\partial^2 I(x, y)}{\partial x^2} \right| \ \left| \frac{\partial^2 I(x, y)}{\partial y^2} \right|]^T \quad (4.1)$$

Çıkarılan özniteliklerin bir matriste toplanmasıyla ilgili bölgeye ait öznitelik matrisi elde edilir. Matriste n , öznitelik sayısını, m ise piksel sayısını göstermek üzere; öznitelik matrisi,

$$\begin{bmatrix} F_{11} & \cdots & F_{1m} \\ \vdots & \ddots & \vdots \\ F_{1n} & \cdots & F_{mn} \end{bmatrix} \quad (4.2)$$

Hedefin bulunduğu ilk video karesi için hedefe ait kovaryans tanımlayıcı elde edildikten sonra ardışık karelerde hedefin konumu belirlenmeye çalışılmıştır. Çalışılan videolarda saniyede yaklaşık 20 kare gösterildiği düşünüldüğünde, hedefin bir kare sonra, önceki konumundan fazla ilerleyemeyeceği göz önünde bulundurularak arama çerçevesi (alt çerçeve) daraltılmıştır. Sistemin genel çalışması özet olarak Şekil 4.5’de gösterilmiştir.




Şekil 4.5 Kovaryans Tanımlayıcı ile hedef izleme için genel gösterim

4.3 Otomatik Hedef Tespiti ve İzlenmesi

Termal görüntülerde otomatik hareketli hedef tespiti ve izlenmesi ÖBÖDA ve KT yöntemlerinin bir arada kullanıldığı bir algoritma geliştirilerek yapılmıştır. ÖBÖDA yöntemi ile hareketin sezildiği bölgelerde, hedef tespiti ve tespit edilen hedefin daha sonraki karelerde izlenmesi KT ile gerçekleştirilmiştir. Algoritma çeşitli senaryolar altındaki farklı hedefler üzerinde denenmiştir.

Algoritma uygulama aşamasında tekil hedef izleme problemi üzerinde durmuştur. Hedef olarak ise yaya ve uçaklar seçilmiştir. Bu amaçla eğitim aşaması da denebilecek aşamada yaya hedefi için üç şablon, uçak hedefi için ise tek şablon çıkarılmıştır. Yayalar için üç şablon çıkarılmasının sebebi, insanın yürüme esnasında belden aşağı ve yukarısının farklı karakterde hareket etmesidir. Sistemin bu hareketlerden az


etkilenmesi için belden yukarısı için bir şablon, belden aşağısı için ise ayaklarının açık ve kapalı olduğu durumlar için birer yani toplamda üç şablon çıkarılmıştır. Çıkarılan hedef şablonları Şekil 4.6’da gösterilmiştir.



(a) Gövde (b) Ayaklar kapalı (c) Ayaklar açık (d) Uçak

Şekil 4.6 Hedef şablonları

Sistemin genel akış diyagramı Şekil 4.7’de gösterilmiştir.



Şekil 4.7 Otomatik hedef tespiti ve izlenmesi genel akış diyagramı

Algoritmanın hedef tespiti performansı karışıklık matrisleri ile ölçülmüştür. Karışıklık matrislerine, ROC eğrilerini çizebilmek ihtiyaç duyulmaktadır. Karışıklık matrisi basit bir ifadeyle doğrulama verisi ile sınıflandırıcının sonuçlarının yer aldığı bir tablodur. Tek sınıf olması durumunda karışıklık matrisi Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1 Tek sınıf için karışıklık matrisi

	Doğru Sınıf		
		Sınıf 1	Sınıf 0
	Öngörü	Sınıf 1	Sınıf 0
		Dp	Yp
		Yn	Dn

D_p (doğru pozitif), hedefin doğru bir şekilde sınıflandırıldığı durumların sayısıdır. $P(D_p)$ ise doğru sınıflandırma oranını verir.

$$P(D_p) = \frac{D_p}{D_p + Y_n} \quad (4.3)$$

Bu oran ayrıca tespit etme oranı olarak da adlandırılır.

D_n (doğru negatif), hedef olmayan bölgenin doğru olarak sınıflandırıldığı durumların sayısıdır. $P(D_n)$ ise bu durumların oranı ya da olasılığını göstermektedir.

$$P(D_n) = \frac{D_n}{D_n + Y_p} \quad (4.4)$$

Y_p (yanlış pozitif), hedef olmayan bölgelerin yanlış bir sınıflandırma neticesinde hedef olarak etiketlendiği durumların sayısıdır. $P(Y_p)$ yanlış pozitiflerin oranını göstermektedir.

$$P(Y_p) = \frac{Y_p}{D_n + Y_p} \quad (4.5)$$

Bu oran ayrıca yanlış alarm olasılığı olarak da bilinmektedir.

Y_n (yanlış negatif), hedef bölgenin yanlış bir kararla hedef değil olarak etiketlendiği durumların sayısıdır. $P(Y_n)$ yanlış negatif oranını göstermektedir.

$$P(Y_n) = \frac{Y_n}{Y_n + D_p} \quad (4.6)$$

Bu oranın yüksek olması hedefin kaçırılma ihtimalinin yüksek olması anlamına gelmektedir.

4.3.1 Kısmi Engel Durumunda Hedef Takibi

Önerilen yöntem termal görüntüler üzerinde hedefin bir engel tarafından kısmen örtüldüğü durumlar için denenmiştir. Burada amaç, hedefin kaçırılmaması için oran olarak en fazla ne kadarının gizlenebileceğini tespit etmektir. Şekil 4.8’de sonuçları gösterilecek örnek videonun ilk karesi gösterilmiştir.




Şekil 4.8 Videonun ilk karesi


Yöntemin hedefin kaçırıldığı duruma kadar çalışma sonuçları Şekil 4.9’da gösterilmiştir.




(a) 1. kare



(b) 2. kare (tespit)



(c) 3. kare



(d) 4. kare



(e) 5. kare



(f) 6. kare



(g) 7. kare



(h) 8. kare



(i) 9. kare (hedef engel arkasında)

Şekil 4.9 Engel durumunda hedefin izlenememesi

Şekil 4.9 incelendiğinde, hedefin 9. karede kaybolduğu görülecektir. Sistem, hedefi 8. kareye kadar doğru bir şekilde izlemiştir. Bu uygulamada hedef yaklaşık 90 pikselden oluşmaktadır. Hedefin yakalandığı son karede hedefe ait 8 piksel görülmüştür. Uygulama benzer hedef ve engellerin bulunduğu 10 video üzerinde denenmiştir. Ortalama hedef piksel sayısı ve hedefin yakalandığı son karedeki ortalama hedefe ait piksel sayıları Çizelge 4.2’de verilmiştir.

Çizelge 4.2 Engel durumunda hedefin tespit edildiği son duruma ait piksel sayıları

	Hedef piksel sayısı	
Video sayısı	ilk kare	son kare
10	91	8,5

Tablodaki bilgiler kullanılarak hedefin kaybolmadan önce oransal olarak ne kadarının görüntüde olduğu hesaplanabilir.


$$\frac{8,5}{91} = \%9,3$$

Yani hedefin yaklaşık % 91 oranında kaybolması durumunda dahi sistem hedef konumunu tespit edebilmektedir.

4.3.2 Engelin Hedefi Tümüyle Gizlemesi Durumu

Engelin kısmen ya da tümüyle hedefi kapattığı durumlar, hedef izlemede karşılaşılan zorlukların başında gelmektedir. Hedefin, bir engel tarafından tamamen örtüldükten sonra tekrar görünmesi durumu bu aşamada incelenmiştir. İnceleme tekil yaya hedefi

üzerinde ve toplamda 520 resim çerçevesi içeren 5 video parçasında gerçekleştirilmiştir. Videolardan birine ait algoritma çıkışı Şekil 4.10'da gösterilmiştir.



Şekil 4.10 Tam engel durumunda hedef izleme sonuçları

Şekil 4.10 incelendiğinde, hedefin engelden çıktıktan sonra 3. karede tekrar yakalandığı görülmüştür. Sistem, nesneyi çevreleyen çerçeve belli bir süre eski yerinde kaldığında, hedefin kaybolup kaybolmadığını anlamak için KT ile kontrol yapmaktadır. Eğer, KT sonucu elde edilen metrik eşik değerinden büyükse hedefin izlenemediği kararı verilmektedir. Bu aşamada, ÖBÖDA tekrar devreye girerek hareketli bölge sezilmesi yapılır. Ardından bulununan hareketli bölgelerde, KT ile tespit işlemi

gerçekleştirilmektedir. Böylece, engel tarafından tamamı örtülen hedefin, ortaya çıktıktan tekrar yakalanması sağlanmaktadır. Uygulama sonucunda elde edilen karışıklık matrisi verilmiştir (Çizelge 4.3). Bu çizelgeden de görüleceği üzere hedef tespit oranı % 95 olarak hesaplanmıştır.

Çizelge 4.3 Tam engel durumu için karışıklık matrisi

		Doğrulama	
Tahmin		Hedef	Hedef değil
	Hedef	316	5
	Hedef değil	15	184


4.3.3 Hedefe Benzer Hareketli Nesne Durumu

Hedef takibinde, hedefe benzeyen nesnelerin hedef olarak etiketlenmesi yanlış alarm olarak adlandırılır. Bu tez kapsamında önerilen yaklaşımın yanlış alarm olasılığını incelemek için yaya takibinde, hayvanların da hareket ettiği videolar için uygulamalar yapılmıştır. Şekil 4.11’de videoya ait ilk kare gösterilmiştir.



Şekil 4.11 Hedefe benzer hareketli nesne durumu için ilk kare

Toplamda 61 kareden oluşan videonun yaya ve hayvan karşılaşmasını içeren 8 karelik sonucu Şekil 4.12’de verilmiştir.




4.3.4 Hedef ve Arka Plan Benzerliği Durumu

Hedef tespiti ve izleme uygulamalarında arka plan gürültüsü karşılaşılan başka bir problem türüdür. Bu tez kapsamında önerilen yöntemin etkinliği, arka planın hedefe benzerliğinin yüksek olduğu durumlar için de araştırılmıştır. Uygulama hem yayalar hem de uçak hedefleri için gerçekleştirilmiştir. Uçak takibi için 90 resim çerçevesi içeren bir video sonuçlarına yer verilmiştir. Videoya ait ilk kare Şekil 4.13’de gösterilmiştir.



Şekil 4.13 Uçak takibi için ilk video karesi

Şekil 4.14’de uçak takibi uygulamasının sonucu 8 kare için gösterilmiştir.



(a) 1. kare

(b) 2. kare

(c) 7. kare

(d) 12. kare



(e) 29. kare

(f) 32. kare

(g) 33. kare

(h) 34. kare


Şekil 4.14 Uçak takibi sonuçları

Arka plana benzerlik durumunda yaya takibi için ilk video karesi Şekil 4.15’de gösterilmiştir.



Şekil 4.15 Yaya takibi için ilk video karesi


Şekil 4.16’da yaya takibi sonuçlarına yer verilmiştir. Video gündüz çekildiğinden ısının yüksek olduğu kısımlar yani beyaz bölgeler çoğunluktadır. Bu yüzden, hedef siyah çerçeve ile gösterilmiştir.



(a) 1. kare

(b) 2. kare

(c) 3. kare



(d) 4. kare

(e) 5. kare

(f) 6. kare

Şekil 4.16 Arka plan benzerliği durumunda yaya takibi sonuçları

HİPERSPEKTRAL GÖRÜNTÜLERDE HEDEF TESPİTİ VE İZLENMESİ

Bu bölümde Ölçekten Bağımsız Öznitelik Dönüşümü tabanlı Akış (ÖBÖDA) yöntemi ve Kovaryans Tanımlayıcı (KT) kullanılarak hiperspektral veri seti üzerinde hedef tanıma işlemi gerçekleştirilmiştir. Performans ölçümlerinde, hedef bölgelerindeki her bir piksel ayrı birer hedef olarak düşünülerek her birinin ilgili sınıfa ait olup olmadığı üzerinde durulmuştur.

5.1 ÖBÖDA ile HSG’de Hareket Sezme


Bu tez kapsamında, Ölçekten Bağımsız Öznitelik Dönüşümü tabanlı Akış yöntemi ile hiperspektral görüntülerde hareket sezme yapılması amaçlanmıştır. HSG’in yüksek boyutlu olması ve zamanda ardışık veri kümelerinin elimizde olmaması problemin çözülmesinin önündeki başlıca engellerdir. Yüksek boyut problemini aşmak için, ÖBÖDA yöntemine RGB (Red Green Blue) bantların uygulanması uygun görülmüştür.

Görüntü, HYDICE sensörleri tarafından bir kasabanın üstten kaydedilmesi ile elde edilmiştir [52]. Her biri 307 x 307 piksellik, 210 adet spektral banttı oluşturan görüntü, zamanda tek bir anı gösterdiğinden veride akış, yapay olarak oluşturulmuştur. Görüntü yakından incelendiğinde, evlerin önünde havuzlar olduğu görülecektir. Bu havuzların bir türünden alınan spektral imza hedef olarak kabul edilip, farklı sayıda piksellerden oluşan hedeflerin farklı konumlarda olduğu yapay hareket senaryoları oluşturulmuştur. Böylece hedefin aynı anda hem sabit kaldığı hem de hareket ettiği durum için akışın önerilen yöntemle doğru tespit edilip edilmediği üzerinde durulmuştur. Şekil 5.1’de kullanılan görüntünün doğal görüntüsü bulunmaktadır.



Şekil 5.1 HYDICE verisi doğal görünümü

HSG'in karakteristik özelliklerinden dolayı, bir veya birkaç piksellik alanda hedef tanıma yapmak mümkündür. Hareketli hedeflerin tespit edilmesi ve tanınması gerek HSG'de gerekse diğer görüntü türlerinde önemli bir çalışma alanıdır. Hareketli hedef tespiti ve tanınmasının görüntünün tamamı üzerinde yapılması yerine, doğru tespit edilmiş hareketli bölgelerde yapılması daha anlamlıdır. Buradan hareketle, olası hedefleri içerecek hareketli bölgelerin doğru tespiti hem sistemin başarısını artıracak hem de işlem süresini kısaltacak önemli bir aşamadır. Bu amaçla 1, 3 ve 4 piksel boyutlu yapay hedefler HYDICE – URBAN hiperspektral verisine farklı konumlarda gömülmüş ve bu konumların tespitine çalışılmıştır. İlk olarak görüntü üzerinden alınmış bir havuza ait bir imza vektörü her defasında farklı konumda olmak koşuluyla gömülmüş ve bu şekilde 5 adet HSG'den oluşan veri kümesi oluşturulmuştur. Şekil 5.2'de veriye gömülen normal ve gürültülü imza vektörleri verilmiştir.



Şekil 5.2 HYDICE verisindeki havuza ait imza vektörleri (a) Normal imza (b) Gürültü eklenmiş imza vektörü (SNR = 8)


Piksel boyutu 1 olan hedefin ardışık iki veri için RGB görüntüsü Şekil 5.3’de gösterilmiştir.



Şekil 5.3 Bir piksel boyutlu hedefin hareketi (a) Başlangıç (b) Ardışık veri

Noktasal yer kaplayan bu hedef için hareket sezme ÖBÖDA ile mümkün olmamıştır.

Şekil 5.4’de 3 piksel boyutlu hedefin hareketi, hedefin görünürlüğünü artırmak için bölge üzerinde büyütme yapılarak gösterilmiştir.




(a)



(b)

Şekil 5.4 Üç piksel boyutlu hedefin hareketi (a) Başlangıç (b) Ardışık veri

Bahsedilen hedefin hareketine ait ÖBÖDA çıkışı Şekil 5.5’de verilmiştir.



Şekil 5.5 Üç piksel boyutlu hedef için ÖBÖDA çıkışı

Aynı hedefin hareket senaryosu için bu kez hedefe gürültü eklenmiş ($SNR = 5$) ve başlangıç konumu değiştirilmiştir. Başlangıç ve ardışık veri Şekil 5.6’da gösterilmiştir.




(a)



(b)

Şekil 5.6 Üç piksel boyutlu hedefin hareketi (a) Başlangıç (b) Gürültülü ardışık veri

Hareketli ve gürültülü hedef için ÖBÖDA çıkışı Şekil 5.7’de gösterilmiştir.



Şekil 5.7 Üç piksel boyutlu gürültü eklenmiş hedef için ÖBÖDA çıkışı


Üç piksel boyutlu hedef için ardışık, veri setlerinden elde edilen hareketli bölgeler Şekil 5.8’de gösterilmiştir.



(a) Veri 1-2



(b) Veri 2-3



(c) Veri 3-4

Şekil 5.8 Üç piksel boyutlu hedef için hareketli bölgeler

Çizelge 5.1’de farklı boyutlardaki hedefler için, gürültülü ve gürültüsüz halde ÖBÖDA yöntemiyle tespit edilen hareket alanlarının boyutları verilmiştir. Örneğin, 3 piksel boyutlu veri için başlangıç ve bitiş konumları arası uzamsal olarak yaklaşık 25 piksel iken ÖBÖDA 18 noktalı bir hareket sezmiştir. Bu alan üzerinde yoğunlaşarak hareketli nesnenin ne olduğu hakkında bilgi edinmek mümkündür. Aynı hedefe gürültü eklendiğinde ise yaklaşık 40 piksel boyutlu bir akış sonucu elde edilmiştir.

Çizelge 5.1 HYDICE verisinde ÖBÖDA yöntemi ile ölçülen hareketli alanlar


Hedef boyutu (piksel)	ÖBÖDA (alan)	
	Normal	Gürültülü
1	—	—
3	18 piksel	40 piksel
4	30 piksel	60 piksel

5.2 Kovaryans Tanımlayıcı ile Hedef Tespiti

ÖBÖDA yöntemi ile hareketli bölgelerin tespit edildiği görüntülerde KT ile spektral bilgi kullanılarak hedef tespiti gerçekleştirilmiştir. Hareketli bölgedeki her piksel ayrı ayrı işleme sokulup, sınıflandırıcının hedef olup olmadığına dair karar vermesi istenmiştir. Eğitim ve test aşamalarında her banttan 5 adet öznitelik çıkarılmıştır. Öznitelik seçimi O. Kurşun vd. [53] tarafından yapılan çalışma referans alınarak gerçekleştirilmiştir.

$$F(x) = [x I(x) I_x I_{xx} (I_x^2 + I_{xx}^2)^{1/2}] \quad (5.1)$$

Öznitelik vektöründe x bandın sırasını, $I(x)$ genlik değerini, I_x birinci türevi, I_{xx} ise ikinci türevi göstermektedir. Bir piksel için akış ÖBÖDA ile elde edilemediğinden hedef tespiti gerçekleştirilmemiştir. Uygulamada hedefin uzamsal boyutunun bilindiği ve değişmediği varsayılmıştır. Üç piksel boyutlu hedef için, KT ile gerçekleştirilen tespit sonucu Şekil 5.9’da gösterilmiştir. Burada, hedef imzaların birebir aynısı yerine SNR = 10 olacak şekilde gürültülü hali tanınmaya çalışılmıştır.



Şekil 5.9 Kovaryans tanımlayıcı ile üç piksel boyutlu hedef tespit sonucu

Üç piksel boyutlu hedef için yapay olarak üretilen 5 HSG verisi için yöntem performansı Çizelge 5.2’de gösterilmiştir. Performanslar tespit oranı ($P(D_p)$) ve yanlış alarm oranı ($P(Y_p)$) üzerinden değerlendirilmiştir. İşaret gürültü oranı (SNR) dB cinsinden çizelgede yer almıştır.

Çizelge 5.2 Üç piksel boyutlu hedef için performans sonuçları

Gürültü (SNR)	$P(D_p)$	$P(Y_p)$
1	0.73	0.01
5	0.8	0.01
10	0.93	0.006

Dört piksel boyutlu hedef için ise yapay olarak üretilen 5 HSG verisi için yöntem performansı Çizelge 5.3’de gösterilmiştir.

Çizelge 5.3 Dört piksel boyutlu hedef için performans sonuçları


Gürültü (SNR)	$P(D_p)$	$P(Y_p)$
1	0.75	0.018
5	0.85	0.012
10	0.95	0.005

Sonuçları değerlendirirken, hedef boyutlarının bilindiği göz önünde bulundurulmalıdır.

5.3 Parçalı Kovaryans Tanımlayıcı ile HSG’de Hedef Tanıma

Bu kısımda hiperspektral veri seti olarak AVIRIS sensörleri tarafından 1992 yılında alınan bir görüntü seçilmiştir. Bu görüntü Amerika’da Indiana eyaletinin kuzeyinde bulunan tarlaları içermektedir. Çalışma kapsamında tarlalara ekilmiş farklı türden ürünleri tanımak amaçlanmıştır. Veri 220 tane spektral bant içermekte ve her bir bant 145×145 piksellik görüntülerden oluşmaktadır [54].

Doğrulama verisi üzerinde tanımlanmış 16 farklı sınıf bulunmaktadır. Şekil 5.10’da veriye ait bir bant ve doğrulama görüntüsü gösterilmiştir. Bazı sınıflar birbirlerine ciddi bir biçimde benzediğinden tanıma yapabilmek için oldukça zorlu bir veridir.



(a)

(b)

Şekil 5.10 (a) AVIRIS verisi (b) Doğrulama görüntüsü

Veri üzerinde, ışığın yansıması sırasında oluşan durumlardan dolayı anlamsız bantlar da bulunmaktadır. Bu bantlar daha önce bu konuda yapılmış çalışmalar [55, 56] göz önüne alınarak görüntüden ayrılmışlardır. Görüntü üzerinde bulunan 16 sınıftan farklı sınıflandırma zorluklarına sahip çeşitli bölgeler seçilmiş ve uygulama sonuçları üzerinde durulmuştur. Yapılan deneylerde ilk olarak tezde önerilen yöntemin klasik KT’ya olan üstünlüğü gösterilmiştir. Ardından KT’da yer alan öznelilik vektörünün veriyi daha iyi karakterize edebilecek şekilde değiştirilmesi üzerinde durulmuştur. Bu aşamada referans öznelilik vektörüne [53], dağılımı daha iyi karakterize etmek amacıyla elemanlar eklenmiş ve eski vektörle elde edilen sonuçlar ile karşılaştırılmıştır. Son olarak yeni öznelilik vektörü ve KT’ya önerilen yaklaşımın bir arada kullanılmasıyla

elde edilen tanımlayıcının performansı güçlü bir sınıflandırıcı olan Destek Vektör Makinaları (DVM) yöntemi ile de karşılaştırılmıştır. Alınan sonuçlar ve çıktılar gösterilmiştir. Karşılaştırmalarda kullanılan yöntemlerde eğitim için her bir sınıftan 30 tane eğitim vektörü kullanılmış, kalan tüm piksel vektörleri de test için kullanılmıştır. I , spektral imza vektörünü göstermek üzere, referans öznitelik vektörü,

$$F(x) = [x \ I(x) \ I_x I_{xx} \ (I_x^2 + I_{xx}^2)^{1/2}] \quad (5.2)$$

olarak alınmıştır. Dağılımı daha iyi karakterize etmek amacıyla eklenecek öznitelikler ise çarpıklık (skewness), basıklık (kurtosis) ve entropi olarak seçilmiştir.

Çarpıklık (Skewness):

$$S_S = \frac{\sum_{i=1}^N (I_i - \bar{I})^3}{(N-1)\sigma^3} \quad (5.3)$$

Basıklık (Kurtosis):

$$S_K = \frac{\sum_{i=1}^N (I_i - \bar{I})^4}{(N-1)\sigma^4} \quad (5.4)$$

Entropi:

$$S_E = - \sum_{i=1}^N p(I_i) \log_{10} p(I_i) \quad (5.5)$$

Çarpıklık ve basıklık bir dağılımın sırasıyla 3. ve 4. mertebeden momentleridir. Eşitliklerde I , N noktalı veriyi, σ ise standart sapmayı ifade etmektedir [57]. Eşitlik 5.4’de verilen $p(I_i)$ ifadesi rasgele bir dağılımın olasılığını ifade etmektedir. Bu çalışmada rastlantısal bir veri kullanılmadığı için bu ifade yerine,

$$p(I_i) = |I[i] - \bar{I}[i]| \quad (5.6)$$


yaklaşıklığı kullanılmıştır. Eski (F1) ve yeni (F2) öznitelik vektörleri Çizelge 5.4’de gösterilmiştir.

Çizelge 5.4 Öznitelik vektörleri

	Öznitelikler
F1	$[x \ I(x) \ I_x \ I_{xx} (I_x^2 + I_{xx}^2)^{1/2}]$
F2	$[x \ I(x) \ I_x \ I_{xx} (I_x^2 + I_{xx}^2)^{1/2} \ S_S \ S_K \ S_E]$


HSG’de hedef tanıma KT kullanarak klasik yaklaşımda spektral imzalar üzerinden işlem yapılmıştır. Her sınıfı temsilen, belirli sayıda imza vektörünün ortalaması seçilmiş ve bu vektörün her bandından, Çizelge 5.4’de F1 ile gösterilen öznitelikler elde edilmiştir. Bant sayısının elde edilen öznitelikler sütun vektörü haline getirilerek tek bir matriste toplanmış ve bu matrisin kovaryansı hesaplanmıştır. Böylece eğitim aşaması tamamlanmış olan tanıma sürecinde, test aşamasında veri setinden gelen her bir vektör için de aynı işlemler gerçekleştirilmiştir. Daha sonra uzaklık metriği ile eğitim ve test matrisleri karşılaştırılarak benzerlik oranlarına göre tanıma gerçekleştirilmiştir.

Klasik yaklaşım, bir imza vektörü için her bir bandın özniteliklerini tek bir matriste topladığından bilgi kaybı ya da daha az anlamlı bilgi elde edildiği düşünülmektedir. Bu eksikliği gidermek için, tez çalışması kapsamında KT ile hedef tanıma geçmeden önce veri setinin karakteristiğini daha iyi gözlemleyebilmek için, bantlar arası korelasyon değerleri hesaplanmıştır. Bu değerlerin bir matrise atanmasıyla 159 x 159 boyutunda simetrik bir matris elde edilmiştir (Şekil 5.11).



Şekil 5.11 Her bir piksele ait imza vektörlerinin korelasyon matrisi

Matriste beyaz kısımlar pozitif korelasyonu, siyah kısımlar ise negatif korelasyonu göstermektedir. Matris incelendiğinde üç ayrı bölgenin olduğu görülmektedir. Örneğin; 1-26, 27-66 ve 67-159 arası bantlar birbirleriyle pozitif korelasyon göstermektedir. Ancak, 1-26 arası bantların 27-66 arası bantlarla negatif korelasyon gösterdiği görülmüştür. Bu kısımlar Şekil 5.12’de gösterilmiştir.



Şekil 5.12 İmzaların farklı karakterdeki kısımları


Buradan hareketle bir imzanın, üç ayrı bölgeye bölünmesi ve her kısımdan hesaplanan kovaryans matrislerinin tek bir matrise diyagonal yerleştirmenin, o imzayı tanımlayan kovaryans matrisi olarak alınması önerilmiştir.

Bu matris,


$$C_i = \begin{pmatrix} C_1 & 0 & 0 \\ 0 & C_2 & 0 \\ 0 & 0 & C_3 \end{pmatrix} \quad (5.7)$$

olarak gösterilebilir. C_1 , C_2 ve C_3 sırasıyla imzaların üç alt parçalarından elde edilmiş kovaryans matrisleridir. Bu yaklaşım, tez çalışması kapsamında Parçalı Kovaryans Tanımlayıcı (P-KT) olarak adlandırılmıştır.

P-KT yönteminin klasik yöntemle olan üstünlüğü zorluk dereceleri farklı 2 sınıf üzerinde test edilmiştir. Eğitim aşamasında, her sınıftan 30 tane vektör alınmış ve vektörlerin ortalaması sınıfı temsilen kullanılmıştır. Test aşamasında ise gelen her vektör için referans tanımlayıcı (K-KT) ve önerilen yöntem ayrı ayrı kullanılarak hedef sınıfına ait olup olmadıkları tespit edilmeye çalışılmıştır. Sonuçta elde edilen ROC eğrileri Şekil 5.13 ve 5.14’de gösterilmiştir. ROC eğrilerinde eğri altında kalan alanın büyük olması tanıma başarısının iyi olduğu anlamına gelmektedir.



Şekil 5.13 AVIRIS 2 numaralı sınıf için P-KT ve K-KT sonuçları



Şekil 5.14 AVIRIS 6 numaralı sınıf için P-KT ve K-KT sonuçları

Sonuçlar incelendiğinde P-KT yönteminin başarı oranını 2. sınıf için %9.5, 6. sınıf için ise %5.6 oranında artırdığı görülmüştür.

Öznitelik vektörünün değişiminin performansa etkisinin hesaplanması için 4 sınıf üzerinde inceleme yapılmıştır. Referans çalışmada yer alan Kovaryans Tanımlayıcı kullanılarak eski ve yeni öznitelik vektörleri 4 sınıf için test edilmiş ve sonuçlara Çizelge 5.5’de yer verilmiştir.

Çizelge 5.5 Öznitelik vektörlerinin tanıma başarıları (%)

	sınıf 2	sınıf 5	sınıf 6	sınıf 8
F1	63,52	83,48	91,32	98,06
F2	66,12	84,36	94,08	98,73

Sonuçlar incelendiğinde önerilen F2 öznitelik vektörünün tanımada başarı oranını artırdığı görülmüştür. Bununla beraber parçalı KT yaklaşımına göre performans artışı daha düşük seviyelerde kalmıştır.

Son olarak hem parçalı kovaryans matrisi yaklaşımının hem de öznitelik vektörünün değişiminin hedef tanıma başarısına etkisi incelenmiştir. Bu amaçla AVIRIS veri

setinde ayırt edilebilirlikleri farklı 8 sınıf seçilmiştir. Her bir sınıf için K-KT ve öznitelik vektörü güncellenmiş P-KT 10'ar kez çalıştırılmış ve ortalama başarı oranları kaydedilmiştir. Bu aşamada önerilen yöntem DVM ile de karşılaştırılmıştır. Deneylerde doğrusal ve radyal tabanlı DVM kullanılmış, daha iyi sonuçlara ulaşıldığı radyal tabanlı DVM'nin çıktılarına yer verilmiştir. Söz konusu 3 yöntemin karşılaştırmalı başarı oranları Çizelge 5.6'da gösterilmiştir. Çizelgede yer alan değerler ROC eğrisi altında kalan alan değerini göstermektedir.

Çizelge 5.6 8 sınıf için yöntemlerin karşılaştırmalı sonuçları

	sınıf 2	sınıf 5	sınıf 6	sınıf 8	sınıf 10	sınıf 11	sınıf 13	sınıf 14
P - KT	0,7149	0,8619	0,9814	0,9962	0,7708	0,7998	0,9963	0,9745
K - KT	0,6352	0,8348	0,9132	0,9806	0,7428	0,7962	0,9904	0,9715
DVM	0,8248	0,8937	0,9512	0,9827	0,8788	0,9512	0,974	0,92

Çıktılar incelendiğinde 4 sınıf için P-KT'nin, kalan 4 sınıf için ise DVM'nin daha iyi sonuçlar verdiği görülmektedir. Burada DVM'nin daha iyi performans gösterdiği sınıfların görece ayırt edilebilirliklerinin daha zor olduğunu söylemek gerekir. Çizelge incelendiğinde önerilen yöntemin klasik yaklaşıma göre her durumda daha iyi sonuçlar verdiği görülecektir.

SONUÇ VE ÖNERİLER

Bu çalışmada termal ve hiperspektral görüntülerde hedef tespiti ve izleme problemi için Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış ve Kovaryans Tanımlayıcı yöntemlerinin bir arada kullanılması önerilmiştir. Kovaryans Tanımlayıcı için yeni öznitelik vektörlerinin kullanılması ve Parçalı-Kovaryans Tanımlayıcı yaklaşımının hiperspektral görüntülerde tanıma amaçlı kullanılabilirliği incelenmiştir.

Termal görüntüler üzerinde ÖBÖDA yöntemi ile hareketli bölge sezme gerçekleştirilmiştir. Sezilen hareketli bölgeler içinde KT kullanılarak, hedef olup olmadığı araştırılmıştır. Hedefin tespit edildiği durumlarda videonun kalanı için hedefin takibi yine KT ile yapılmıştır. Farklı senaryo ve hedef türleri üzerinde denenen algoritmanın, hedef tespiti ve izlemesinde başarılı olduğu görülmüştür.

Engel durumunda izlenebilirliğin incelendiği uygulamalarda, yaklaşık %91'inin gizlendiği durumda dahi hedefin takip edilebildiği görülmüştür. Tam engel durumunda kaybolan hedefin, ortaya çıktığında tekrar yakalanması, önerilen algoritma sayesinde mümkün olmuştur. Bu amaçla yapılan deneylerde % 95 tespit oranı elde edilmiştir. Aynı uygulamada yanlış alarm oranı ise % 2 seviyesinde kalmıştır.

Hiperspektral görüntülerde ise birkaç piksel boyutlu küçük hedeflerin tespiti ve izlenmesi amaçlanmıştır. ÖBÖDA ile hareket akışı bulunan bölgede her bir imzaya hedef gözüyle bakılarak KT ile tespit gerçekleştirilmiştir. Bu uygulamada hedefin boyutunun önceden bilindiği varsayımı karar aşamasında kolaylık sağlamıştır. Performans ölçümlerinde hedefin birebir aynısının değil, gürültülü halinin hareketi tespit edilmeye çalışılmıştır. Ayrıca, KT ile HSG üzerinde hedef tanıma yapılırken farklı öznitelik vektörlerinin etkisi araştırılmıştır. Bu doğrultuda, verinin karakteristiğine göre bölge tanımlayıcısı kovaryans matrisinin yapısı değiştirilmiş ve

klasik yapıya göre daha iyi sonuçlar alındığı görülmüştür. Destek Vektör Makinaları ile de karşılaştırma yapılmış, önerilen yaklaşımın bazı sınıflarda radyal DVM'den iyi sonuçlar verdiği anlaşılmıştır. Çizelge 5.6 incelendiğinde, örneğin 2. sınıf için % 63 olan başarı oranı % 71'e yükselmiştir. Yine aynı çizelgede 6. sınıf için çıktılar yorumlanırsa, önerilen yaklaşım % 91 olan başarı oranını % 99'a çıkarmıştır. Bu değer aynı zamanda, % 95 olan radyal DVM sonucundan da daha iyidir.

Deney çıktıları incelendiğinde 3 piksel boyutlu hedef için, SNR = 10 olacak şekilde gürültü eklendiğinde tespit oranı % 93 olarak gerçekleşmiştir. Aynı gürültü oranında 4 piksel için ise % 95 doğru pozitif oranına ulaşılmıştır. Yanlış alarm oranları ise sırasıyla, % 0.6 ve % 0.5 olarak bulunmuştur.

Yapılan çalışmada yukarıda değinilen sonuçlar elde edilmekle beraber, çalışma sonrasında ileriye dönük üzerinde çalışılabilecek yeni konuların da ortaya çıktığı görülmüştür.

HSG üzerinde spektral bantların seçim yöntemini değiştirmek ve güçlü bir bant seçim yöntemi kullanmak tanıma performansına etki eden önemli bir işlem basamağıdır. Bölüm 2'de değinildiği gibi HSG'de her bir piksel için yüzlerce elemandan oluşan bir imza vektörü bulunmaktadır. Bu vektör değerlerinin bir kısmı anlamlı bilgi içermediğinden uygun bir bant sayısı azaltma yöntemi kullandıktan sonra tespit ve tanıma yapılması performansı daha da artıracaktır. Bunun yanında düşük sayıda eleman içeren piksel vektörleri ile işlem yükü de azalacak bu da çalışma zamanını belirgin bir biçimde düşürecektir. Bu nedenlerden dolayı iyi bir bant seçim yöntemi kullanmak yerinde bir devam çalışması olarak görülmektedir.

Bu tez kapsamında çoklu hedef tespiti ve izlenmesi üzerinde durulmamıştır. Ayrıca, algoritmaların çalışma ortamı olarak Matlab paket programı seçildiğinden tespit ve izleme işlemlerinin gerçek zamanlı uygulamalar için uygun olup olmadığı da irdelenmemiştir. Güvenlik uygulamaları için oldukça önemli olan bu iki konunun da çalışılması ileriki aşamalara bırakılmıştır.

Tüm bu bilgiler ışığında, Ölçekten Bağımsız Öznitelik Dönüşümü Tabanlı Akış yönteminin HSG ve termal görüntüler üzerinde uzamsal hareket sezme problemi için tercih edilebilir olduğu görülmektedir. Kovaryans Tanımlayıcı yöntemi de hem hesap maliyetinin düşük olması hem de istatistiksel ve uzamsal bilgiyi bir arada kullanmaya elverişli olması avantajıyla tespit ve izleme alanında başarılı sonuçlar vermektedir.

- [1] Lombardi, P.,(2001). "A Survey on Pedestrian Detection for Autonomous Driving Systems", Technical Report, University of Pavia.
- [2] Gavrilin, D.,(1999). "The Visual Analysis for Human Movement: A Survey", Computer Vision and Image Understanding, 13: 82-98.
- [3] Cielniak G. ve Duckett, T, (2004). "People Recognition by Mobile Robots", Journal of Intelligent and Fuzzy Systems, 15: 21-27.
- [4] Fang, Y., Yuamada, K., Ninomiya, Y. ve Horn, B., (2004). "A shape-Independent Method for Pedestrian Detection with Far-Infrared Images", IEEE Transactions on Vehicular Technology, 53(6).
- [5] Conaire, C., Cooke, E., O'Connor, N., Murphy, N. ve Smeaton, A., (2005). "Background Modelling in Infrared and Visible Spectrum Video for People Tracking", Proc. of IEEE Int'l workshop on Object Tracking & Classification Beyond the Visible Spectrum.
- [6] Torresan, H., Turgeon, B., Ibarra-Castaneda, C., Hebert, P. Ve Maldague X., (2004). "Advanced Surveillance Systems: Combining Video and Thermal Imagery for Pedestrian Detection", SPIE Thermosense XXVI.
- [7] Darrell, T., Gordon, G. ve Woodfill, J., (2000). "Integrated person tracking using stereo, color, and pattern detection", International Journal of Computer Vision, 37: 175-185.
- [8] Martinkauppi, B., Soriano, M. ve Pietikainen, M., (2003). "Detection of skin color under changing illumination: a comparative study", 12th International Conference on Image Analysis and Processing, 652-657.
- [9] Sigal, L., Sclaroff S. ve Athitsos, V., (2004). "Skin color-based video segmentation under time-varying illumination", IEEE Transactions on Pattern Analysis and Machine Intelligence, 26: 862-877.
- [10] Harville, M., (2004). "Stereo person tracking with adaptive plan-view templates of height and occupancy statistics", Image and Vision Computing, 2: 127-142.
- [11] Hanville, M., Gordon, G. ve Woodfill, J., (2001). "Foreground segmentation using adaptive mixture models in color and depth", IEEE Workshop on Detection and Recognition of Events in Video, 3-11.

- [12] Yasuno, M., Yasuda, N. ve Aoki, M., (2004). "Pedestrian detection and tracking in far infrared images", Conference on Computer Vision and Pattern Recognition Workshop, 125-131.
- [13] Xu, F. L., Liu, X. ve Fujimura, K., (2005). "Pedestrian detection and tracking with night vision", IEEE Transaction on Intelligent Transportation Systems, 6(1): 63-71.
- [14] Cenci, A., Fusiello, A. ve Roberto, V. (1999). "Image stabilization by feature tracking", 10th International Conference on Image Analysis and processing, 665-667, Venice, Italy.
- [15] Strehl, A. ve Aggarwal, J. K. "Detecting moving objects in airborne Forward Looking infrared sequences", machine Vision Applications, 11(200): 267-276.
- [16] Srinivasan, S. Ve Chellappa, R. (1997) "Image stabilization and mosaicking using the overlapped bases optical flow field", In Proceedings of IEEE International Conference on Image Processing.
- [17] Irani, M., Rousso, R. ve Peleg, S. (1994). "Recovery of ego motion using image stabilization". In Proceedings of the IEEE Computer Vision and pattern Recognition, 454-460.
- [18] Braga-N, U. Ve Goutsias, J. (1999). "Automatic target detection and Tracking in forward looking infrared image sequences using Morphological connected operators", 33rd Conference of Information Sciences and Systems.
- [19] Howard, A. ve Padgett, C., (1999). "Intelligent Target Detection in Hyperspectral Imagery", 13th International Conference on Applied Geologic Sensing, Vancouver, Canada.
- [20] Plaza, A. ve Martinez P., (2003). "A New Method for Target Detection in Hyperspectral Imagery Based on Extended Morphological Profiles", IEEE Geoscience and Remote Sensing Symposium, Toulouse, France.
- [21] EM spektrum ve kızılötesi bandı, <http://www.sentezgroup.com.tr/termal>, 7 Mayıs 2012.
- [22] Kızılötesi bantlar, <http://www.ipac.caltech.edu/outreach/Edu/Regions.html>, 7 Mayıs 2012.
- [23] Termal görüntüler, <http://www.infrared1.com/ANIR.html>, 7 Mayıs 2012.
- [24] Termal kameralar, <http://en.wikipedia.org/wiki/Thermography>, 7 Mayıs 2012.
- [25] Termal görüntülerin sanat tarihi uygulamaları, <http://www.sensorsinc.com/artanalysis.html>, 8 Mayıs 2012.
- [26] Alaska bölgesinin meteoroloji uydusu görüntüsü, http://pafc.arh.noaa.gov/home_sat.php, 8 Mayıs 2012.
- [27] Gautherie, M. Ve Gros, C. M., (1980). "Breast Thermography and Cancer Risk Prediction", American Cancer Society, 45: 51-56.
- [28] Görünen ışığın dalga boyu aralığı, <http://www.overidon.com/wp-content/uploads/2010/06/wavelength-light1.jpg>, 24 Mart 2012.
- [29] Hiperspektral görüntüleme sistemi, http://www.csiro.au/news/-newsletters/0611_metals/story2.htm, 7 Mayıs 2012.

- [30] Spektral imzalar, http://rst.gsfc.nasa.gov/Intro/Part2_24.html, 24 Mart 2012.
- [31] Kim, M. S. ve Chen, Y. R., (2001). "Hyperspectral Reflectance and Fluorescence Imaging System for Food Quality and Safety", American Society of Agricultural Engineers, 44: 721-729.
- [32] Carrasco, O. ve Gomez, R. B., (2003). "Hyperspectral Imaging Applied to Medical Diagnostics and Food Safety", Geo-Spatial and Temporal Image and Data Exploitation III, Orlando, Amerika.
- [33] Pan Z. ve Healey, G.E., (2003). "Face recognition in hyperspectral images", IEEE Computer Society Conference, Irwine, Amerika.
- [34] Hedef tanıma örneği, <http://ilab.usc.edu/classes/2001cs599/i018c.gif>, 2 Mayıs 2012.
- [35] Yılmaz, A., Javed, O. Ve Shah, M., (2006). "Object tracking: A Survey", ACM Computing Surveys, 38(4), Article 13.
- [36] Liu, R. ve Zhi, H., (2010). "Infrared Point Target Detection with Fisher Linear Discriminant and Kernel Fisher Linear Discriminant", Journal Of Infrared Millimeter and Terahertz Waves, 31: 1491-1502.
- [37] Tuzel, O., Porikli, F. ve Meer, P., (2006). "Region Covariance: A fast descriptor for detection and classification", Lecture Notes in Computer Science, 3952: 589.
- [38] Porikli, F., Tuzel, O. ve Meer, P., (2006). "Covariance tracking using model update based on lie algebra", Proc. Int. Conf. On Comp. Vision and Pattern Recognition, 1: 728-735.
- [39] Mikolajczyk, K. ve Schmid, C. (2005). "A performance evaluation of local descriptors", IEEE Trans. Pattern Anal. Mach. Intell. 27: 1615-1630.
- [40] Förstner, W., Moonen, B. (1999). "A metric for covariance matrices". Technical report, Dept. Of Geodesy and Geoinformatics, Stuttgart University.
- [41] Lowe, D. G. (1999). "Object recognition from local scale-invariant features", Proc. ICCV, 1150–1157, Kerkyra, Yunanistan.
- [42] Lindeberg, T. (1993). "Detecting salient blob-like image structures and their scales with a scale-space primal sketch: a method for focus-of-attention", International Journal of Computer Vision, 11(3): 283–318.
- [43] Eski, S., (2008). Görüntü İşleme Yöntemleri ile Araç Marka ve Plaka Tanınması, Yüksek Lisans Tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- [44] Özgen, N., (2008). "Bilgisayar Kontrollü Hedef Takibi", Gazi Üniversitesi, FBE, Ankara.
- [45] Morency, L. P., (2002). "Stereo-Based Head Pose Tracking Using Iterative Closest Point and Normal Flow Constraint".
- [46] Liu, C., Yuen, J., Torralba, A., Sivic, J. ve Freeman, W. T. (2008). "SIFT Flow: Dense Correspondence across Different Scenes", ECCV, Part III, pp. 28-42.
- [47] Horn, B. K. P. ve Schunck, B.G. (1981). "Determining optical flow", Artificial Intelligence, 17: 185–203.

- [48] Lucas, B. ve Kanade, T. (1981). "An iterative image registration technique with an application to stereo vision", Proceedings of the International Joint Conference on Artificial Intelligence, 674–679.
- [49] Bruhn, A., Weickert, J. ve Schnörr, C. (2005). "Lucas/Kanade meets Horn/Schunk: combining local and global optic flow methods", Intl. J. of Computer Vision 61(3): 211–231.
- [50] Boykov, Y., Veksler, O. ve Zabih, R. (2001). "Fast approximate energy minimization via graph cuts", IEEE Trans. On Pattern Analysis and Machine Intelligence 23(11): 1222–1239.
- [51] Shekhovtsov, A., Kovtun, I. ve Hlavac, V. (2007). "Efficient MRF deformation model for non-rigid image matching", Proc. CVPR.
- [52] HYDICE Görüntüleri, <http://www.agc.army.mil/hypercube/>, 10 Mayıs 2012.
- [53] Kurşun O., Karabiber F., Koç C., ve Bal A., (2009). "Hyper-Spectral Image Segmentation Using Spectral Clustering With Covariance Descriptors", SPIE Image Processing: Algorithms and Systems VII.
- [54] AVIRIS Hiper spektral sensörü, <http://aviris.jpl.nasa.gov/html/data.html>, 16 Mayıs 2012.
- [55] Rajadell, O. ve García-Sevilla, P. (2009). "Textural Features for Hyperspectral Pixel Classification", Proceedings of the 4th Iberian Conference on Pattern Recognition and Image Analysis, Portekiz.
- [56] Faulconbridge, R. I. ve Pickering, M. R., (2006). "Unsupervised band removal leading to improved classification accuracy of hyperspectral images", Proceedings of the 29th Australasian Computer Science Conference, Avustralya.
- [57] Groeneveld, R. A., ve Meeden, G. (1984). "Measuring skewness and kurtosis ", The Statistician, 33 (4): 391-399.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hamidullah BİNOL
Doğum Tarihi ve Yeri : 06.02.1988 - GİRESUN
Yabancı Dili : İngilizce
E-posta : hbinol@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Telekomünikasyon Müh.	İstanbul Teknik Üniversitesi	2010
Lise	Fen Bilimleri	Konya Meram Fen Lisesi	2005

İŞ TECRÜBESİ

Yıl	Kurum	Görevi
2010 –	Yıldız Teknik Üniversitesi	Araştırma Görevlisi

YAYINLARI

Bildiri

1. **Binol H.**, Dinç S. ve Bal A., “Classification on Hyperspectral Images using Enhanced Covariance Descriptor”, IEEE 20th Conference on Signal Processing and Communications Applications, Nisan 2012, Muğla, Türkiye.