

**KOCAELİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ  
ANABİLİM DALI**

**DOKTORA TEZİ**

**VIDEO İÇİN BÖLGESEL ORTAK DEĞİŞİM BETİMLEYİCİ  
TABANLI İYİLEŞTİRİLMİŞ HEDEF TAKİBİ**

**Orhan AKBULUT**

**KOCAELİ 2014**

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**DOKTORA TEZİ**

**VIDEO İÇİN BÖLGESEL ORTAK DEĞİŞİM BETİMLEYİCİ**  
**TABANLI İYİLEŞTİRİLMİŞ HEDEF TAKİBİ**

**Orhan AKBULUT**

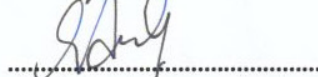
**Prof.Dr. Sarp ERTÜRK**  
**Danışman, Kocaeli Üniv.**

**Doç.Dr. Cabir VURAL**  
**Jüri Üyesi, Marmara Üniv.**

**Doç.Dr. Oğuzhan URHAN**  
**Jüri Üyesi, Kocaeli Üniv.**

**Doç.Dr. M. Kemal GÜLLÜ**  
**Jüri Üyesi, Kocaeli Üniv.**

**Yrd. Doç.Dr. Gökçen ÇETİNEL**  
**Jüri Üyesi, Sakarya Üniv.**



**Tezin Savunulduğu Tarih: 28.02.2014**

## ÖNSÖZ VE TEŞEKKÜR

Tez içeriğinin, görsel hedef takibi konularında çalışmak isteyen bilim insanlarına faydalı olmasını temenni ederim.

Bilimsel çalışmalarda ilham aldığım ve gerek lisans gerekse yüksek lisans dönemlerinde ders aldığım tez danışman hocam Prof. Dr. Sarp Ertürk'e samimi teşekkürlerimi ifade etmek isterim. Bilgi ve deneyimlerini paylaşan, çalışma ortamı sağlayan saygıdeğer hocama bir kez daha teşekkür ederim.

Doktora tez çalışmalarım süresince yardımlarını esirgemeyen, değerli fikirleriyle ufku genişleten, başta Doç. Dr. Oğuzhan Urhan, Doç. Dr. Cabir Vural ve Doç. Dr. M. Kemal Güllü'ye teşekkür ederim.

Sevgi ve saygılarını eksik etmeyen KULİS ArGe laboratuvarı çalışma arkadaşlarıma, özellikle Yrd. Doç. Dr. Aysun Taşyapı Çelebi, Davut Çeşmeci ve Alev Söke'ye teşekkür ederim.

Doktora eğitimim süresince tam zamanlı burs kapsamında maddi destek sağlayan TÜBİTAK kurumuna özellikle teşekkür ederim.

Manevi destekleriyle beni her daim ayakta tutan, bana güvenen sevgili aileme teşekkür ederim. Mahsun ama kederli bakışlarıyla doktorayı bitirmemi sabırla bekleyen sevgili anneme ve babama ayrıca çok teşekkür ederim.

Ve tabiki; özgüvenimi koruyan, dertlerimi paylaşan, hayat arkadaşım, sevgili eşim Münevver Akbulut'a, sabrından ve yardımlarından dolayı teşekkür ederim.

Şubat - 2014

Orhan AKBULUT

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ .....	iv
TABLOLAR DİZİNİ .....	vii
SİMGELER DİZİNİ VE KISALTMALAR .....	viii
ÖZET .....	xi
ABSTRACT .....	xii
GİRİŞ .....	1
1. DOĞRUSAL VE DOĞRUSAL OLMAYAN DURUM UZAY MODELLERİ .....	6
1.1. Doğrusal Durum Uzay Modeli .....	7
1.1.1. Bayes kestirimi .....	7
1.1.2. Kalman süzgeci .....	9
1.2. Doğrusal Olmayan Durum Uzay Modeli .....	12
1.2.1. Genişletilmiş Kalman süzgeci .....	13
1.2.2. Kokusuz Kalman süzgeci .....	16
1.2.3. Parçacık süzgeci .....	19
2. HEDEF TESPİTİ VE HEDEF TAKİBİ .....	27
2.1. Hedef Tespiti .....	27
2.2. Hedef Takibi .....	29
2.3. Tez Kapsamında Kullanılan Veri Setleri .....	34
2.4. Tez Kapsamında Kullanılan Performans Ölçütleri .....	38
2.4.1. Öklid uzaklığı .....	38
2.4.2. F-ölçütü .....	39
3. ORTAK DEĞİŞİNTİ BETİMLEYİCİLER İLE HEDEF TAKİBİ .....	41
3.1. Ortak Değişinti Betimleyiciler .....	42
3.1.1. Ortak değişinti betimleyicilerin oluşturulması .....	43
3.1.2. Ortak değişinti betimleyicilerde benzemezlik ölçütü ve model güncellemesi .....	46
3.1.2.1. Forstner benzemezlik ölçütü .....	46
3.1.2.2. Model güncelleme yaklaşımı .....	47
3.1.3. Tümlev imge gösterim yaklaşımı ile ortak değişinti betimleyicilerin elde edilmesi .....	51
3.2. Ortak Değişinti Betimleyici Temelli Hedef Tespit ve Takip Çalışmalarına Genel Bakış .....	54
4. ORTAK DEĞİŞİNTİ BETİMLEYİCİLERİ İÇİN İYİLEŞTİRİLMİŞ BENZEMEZLİK ÖLÇÜTÜ .....	63
4.1. Giriş .....	63
4.2. Forstner Benzemezlik Ölçütünün İyileştirilmesi .....	64
4.3. Önerilen Yöntemin Nesnel Başarımı .....	69
4.4. Önerilen Yöntemin Görsel Başarımı .....	75
4.5. Sonuç .....	77

5. GAUSS AĞIRLIKLANDIRMA VE KALMAN SÜZGECİ İLE ORTAK DEĞİŞİNTİ TEMELLİ GÜRBÜZ HEDEF TAKİBİ .....	79
5.1. Giriş .....	79
5.2. Gauss Ağırlıklandırma ve Kalman Süzgeci ile Hedef Takibi .....	79
5.2.1. Gauss ağırlıklandırma yaklaşımı .....	80
5.2.2. Kalman süzgeci yaklaşımı .....	82
5.2.3. Örtüşme tespiti .....	82
5.3. Önerilen Yöntemin Nesnel Başarımı .....	83
5.4. Önerilen Yöntemin Görsel Başarımı .....	90
5.5. Sonuç .....	95
6. ORTAK DEĞİŞİNTİ BETİMLEYİCİ TEMELLİ HEDEF TAKİBİNDE PİKSEL SEYRELTME YAKLAŞIMLARI .....	96
6.1. Piksel Seyreltme Yaklaşımları .....	96
6.2. Piksel Seyreltme Yaklaşımları ile Ortak Değişinti Betimleyicilerin Oluşturulması .....	98
6.3. Nesnel Hedef Takip Sonuçları .....	100
6.4. Görsel Hedef Takip Sonuçları .....	102
6.5. Sonuç .....	103
SONUÇLAR ve ÖNERİLER .....	105
KAYNAKLAR .....	107
KİŞİSEL YAYINLAR ve ESERLER .....	116
ÖZGEÇMİŞ .....	117

## ŞEKİLLER DİZİNİ

Şekil 1.1.	Özyinelemeli Kalman süzgeç yapısı .....	11
Şekil 1.2.	GKS ile doğrusal olmayan fonksiyonun doğrusallaştırılması.....	15
Şekil 1.3.	Kokusuz dönüşümde özel noktaların oluşturulması.....	17
Şekil 1.4.	SR yaklaşımı ile parçacıkların güncellenmesi .....	23
Şekil 1.5.	(a) DPS (37. çerçeve), (b) PS (37. çerçeve), (c) DPS (43. çerçeve), (d) PS (43. çerçeve) .....	25
Şekil 1.6.	Parçacık süzgecin genel yapısı.....	26
Şekil 2.1.	Hedef tespit yaklaşımları.....	28
Şekil 2.2.	Harris nokta tanımlayıcısı ile bulunan noktalar .....	28
Şekil 2.3.	(a) Dikdörtgensel gösterim, (b) eliptik gösterim, (c) çevrit gösterim, (d) silüet gösterim, (e) eklemli gösterim .....	30
Şekil 2.4.	Hedef takip sistemin genel yapısı.....	31
Şekil 2.5.	Hedef takip yaklaşımları .....	33
Şekil 2.6.	OneLeaveShop ReenterI front görüntü dizisinde hedef nesne .....	35
Şekil 2.7.	EnterExitCrossing PathsI cor görüntü dizisinde hedef nesne.....	35
Şekil 2.8.	(a) Hedef nesne (Jogging1), (b) hedef nesne (Jogging2) .....	36
Şekil 2.9.	Race görüntü dizisinde hedef nesne.....	36
Şekil 2.10.	Subway görüntü dizisinde hedef nesne .....	37
Şekil 2.11.	Crowd görüntü dizisinde hedef nesne .....	37
Şekil 2.12.	Couple görüntü dizisinde takip edilen nesne.....	38
Şekil 2.13.	Woman görüntü dizisinde takip edilen nesne .....	38
Şekil 2.14.	Öklid uzaklığına göre performans ölçütü.....	39
Şekil 2.15.	(a) Doğruluk/Anma: Yüksek/Düşük, (b) Doğruluk/Anma: Düşük/Yüksek, (c) Doğruluk/Anma: Yüksek/Yüksek.....	40
Şekil 3.1.	Ortak değişinti betimleyici temelli hedef takip çalışmalarına genel bir bakış .....	42
Şekil 3.2.	(a) İlişkisiz, (b) pozitif-ilişki, (c) negatif-ilişki .....	43
Şekil 3.3.	Her bir piksel için öznitelik vektörlerinin elde edilmesi .....	44
Şekil 3.4.	(a) Hedef imge $C_R$ , (b) tüm bölge $C_R^1$ , (c) üst bölge $C_R^2$ , (d) alt bölge $C_R^3$ , (e) sol bölge $C_R^4$ , (f) sağ bölge $C_R^5$ .....	45
Şekil 3.5.	Lie cebri ve Lie grubu elemanları arasındaki geometrik ilişki.....	50
Şekil 3.6.	Tümlev imge oluşturma .....	51
Şekil 3.7.	Herhangi bir R bölgesinin alanının hesaplanmasında tümlev imge kullanımı.....	52
Şekil 4.1.	(a) “Crowd” imgesi ve imge üzerinden alınan bir bölge, (b) Forstner uzaklık hesabına göre oluşturulan olabilirlik haritası .....	64
Şekil 4.2.	(a) Forstner benzemezlilik ölçütüne göre oluşturulan olabilirlik haritası, (b) önerilen yaklaşıma göre oluşturulan olabilirlik haritası .....	66
Şekil 4.3.	“Race1” dizisi için PS temelli nesne takibinde referans yöntem ile önerilen yöntemde elde edilen hedef takip hata performansları .....	72

Şekil 4.4.	“Subway” dizisi için tam arama temelli nesne takibinde referans yöntem ile önerilen yöntemde elde edilen hedef takip hata performansları .....	72
Şekil 4.5.	“Crowd” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma .....	73
Şekil 4.6.	“Jogging1” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma.....	74
Şekil 4.7.	“Jogging2” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma.....	74
Şekil 4.8.	“OneLeaveShop1front” dizisi için SBODB yöntem ile önerilen yöntemin tam arama yaklaşımı kullanarak elde edilen görsel takip performansları .....	75
Şekil 4.9.	“Jogging1” dizisi için SBODB yöntem ile önerilen yöntemin PS kullanarak elde edilen görsel takip performansları .....	76
Şekil 4.10.	“Jogging2” dizisi için SBODB yöntem ile önerilen yöntemin PS kullanarak elde edilen görsel takip performansları .....	76
Şekil 4.11.	“Couple” dizisi için SBODB yöntem ile önerilen yöntemin tam arama yaklaşımı kullanarak elde edilen görsel takip performansları .....	77
Şekil 5.1.	Önerilen yöntemin akış şeması .....	80
Şekil 5.2.	Gauss tipi fonksiyon.....	81
Şekil 5.3.	FAR değerine göre parametre eniyilemesi (a) en uyguna yakın <i>Coeff</i> seçimi (b) en uyguna yakın M seçimi (c) en uyguna yakın ÖHOD seçimi (d) en uyguna yakın ÖGOD seçimi.....	85
Şekil 5.4.	Önsel ve sonsal <i>Coeff</i> parametre değerlerinin FAR sonucuna göre karşılaştırılması .....	86
Şekil 5.5.	“EnterExit1cor” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı.....	87
Şekil 5.6.	“Jogging2” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı.....	87
Şekil 5.7.	“Reenter1front” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı.....	88
Şekil 5.8.	“Crowd” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı.....	88
Şekil 5.9.	“Couple” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları .....	91
Şekil 5.10.	“Woman” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları .....	92
Şekil 5.11.	“Race1” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları .....	92
Şekil 5.12.	“Jogging2” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları .....	93
Şekil 5.13.	“Subway” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları .....	94

Şekil 5.14. Önerilen yöntemde sadece KS, sadece GTF ve her iki yaklaşımın birarada kullanılmasıyla elde edilen hedef takip sonuçları .....	94
Şekil 6.1. Pıksel seyreltme örüntüleri. (a) Tam, (b) Quarter, (c) Rectangular, (d) Hexagonal, (e) Quincunx, (f) Yu, (g) 4-Queen, (h) 8-Queen .....	98
Şekil 6.2. 8×8 blok boyutu üzerinden 8-queen yaklaşımına göre öznitelik vektörlerin seçilmesi .....	99
Şekil 6.3. 16×16 blok boyutuna genişletilmiş 8-queen pıksel örüntüsü.....	100
Şekil 6.4. “Jogging1” dizisi için farklı pıksel seyreltme yaklaşımları kullanılarak elde edilen hedef takip performansları (a) tam kesit, (b) küçük bir kesit .....	101
Şekil 6.5. “Jogging2” dizisi için farklı pıksel seyreltme yaklaşımları kullanılarak elde edilen hedef takip performansları (a) tam kesit, (b) küçük bir kesit .....	101
Şekil 6.6. “Couple” dizisi için farklı pıksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibin görsel sonuçları .....	103
Şekil 6.7. “Race1” dizisi için pıksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibin görsel sonuçları .....	103



## TABLolar DİZİNİ

Tablo 1.1. Dinamik sistemler için durum uzay modelleri .....	7
Tablo 4.1. Farklı görüntü dizileri için tam arama yaklaşımına göre referans yöntem ile önerilen yöntemle ait hedef takip hatalarının ortalama ve standart sapma değerleri .....	69
Tablo 4.2. Farklı görüntü dizileri için olasılıksal arama yaklaşımına göre referans yöntem ile önerilen yöntemle ait hedef takip hatalarının ortalama ve standart sapma değerleri .....	70
Tablo 4.3. Farklı görüntü dizileri için tam arama yaklaşımına göre referans yöntem ile önerilen yöntemle ait ortalama F-ölçüt değerleri .....	71
Tablo 4.4. Farklı görüntü dizileri için olasılıksal arama yaklaşımına göre referans yöntem ile önerilen yöntemle ait ortalama F-ölçüt değerleri.....	71
Tablo 5.1. Durağan kamera kayıtları içeren görüntü dizilerinde Öklid uzaklığına göre elde edilen hedef takip hatalarının ortalama ve standart sapma değerleri.....	89
Tablo 5.2. Hareketli kamera kayıtları içeren görüntü dizilerinde Öklid uzaklığına göre elde edilen hedef takip hatalarının ortalama ve standart sapma değerleri.....	89
Tablo 5.3. Durağan kamera kayıtları içeren görüntü dizilerinde F-ölçütüne göre elde edilen ortalama hedef takip hata değerleri.....	90
Tablo 5.4. Hareketli kamera kayıtları içeren görüntü dizilerinde F-ölçütüne göre elde edilen ortalama hedef takip hata değerleri.....	90
Tablo 6.1. Piksel seyreltme örüntülerinin uzamsal homojenlik ve yönlü kapsama değerleri.....	97
Tablo 6.2. Tam piksel örüntü ve farklı piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibinde tüm çerçeveler için elde edilen ortalama F-ölçüt değerleri.....	102

## SİMGELER DİZİNİ VE KISALTMALAR

$k$	: Ayrık zaman
$t_i$	: Öklid uzayında taban vektör
$f()$	: Süreç modeli
$h()$	: Ölçüm modeli
$u$	: Kontrol girişi
$z$	: Sistem çıkışı, ölçüm vektörü
$w$	: Süreç gürültüsü
$r$	: Ölçüm gürültüsü
$x$	: Durum değişkeni, durum vektörü
$\mu$	: Ortalama değer
$\sigma$	: Standart sapma
$A_k$	: Durum geçiş matrisi
$H_k$	: Gözlem matrisi
$Q_k$	: Süreç gürültüsünün ortak değişinti matrisi
$R_k$	: Ölçüm gürültüsünün ortak değişinti matrisi
$\delta_{ij}$	: Kronecker delta fonksiyonu
$P_k^-$	: Önsel hata ortak değişinti matrisi
$P_k$	: Sonsal hata ortak değişinti matrisi
$K_k$	: Kalman kazancı
$\nabla f$	: Kısmi türev
$L$	: Alt üçgenel matris
$d$	: Boyut sayısı
$w_i^m$	: Ağırlıklı ortalama ağırlık katsayısı
$w_i^c$	: Ağırlıklı ortak değişinti ağırlık katsayısı
$s_i$	: Kokusuz dönüşümde özel nokta
$N$	: Örnek sayısı
$w_i$	: Parçacık süzgeci ağırlık parametresi
$c_i$	: i. parçacığın kopya sayısı
$u_r$	: Düzgün dağılımlı rasgele sayı
$N_{eff}$	: Efektif örnek sayısı
$h$	: Çekirdek bant genişliği
$f_i$	: Öznitelik vektörü
$n$	: Toplam piksel sayısı
$\mu_R$	: R bölgesi için ortalama öznitelik vektörü
$n_R$	: R bölgesinde toplam piksel sayısı
$C_R$	: R bölgesi için ortak değişinti matrisi

$Sym_d^+$	: Simetrik pozitif tanımlı matris
$\lambda$	: Genelleştirilmiş özdeğer matrisi
$X$	: Genelleştirilmiş özvektör matrisi
$F$	: Tensör imge matrisi
$W$	: İmge genişliği
$H$	: İmge yüksekliği
$T$	: Toplam ortak değişinti matris sayısı
$\mu_{ref}$	: Referans bölgeye ait ortalama öznitelik vektörü
$\mu_{aday}$	: Aday bölgeye ait ortalama öznitelik vektörü
$\alpha$	: Ağırlıklandırma faktörü
$\beta$	: Düzgeleme sabiti
$q_k$	: Gauss gürültü vektörü
$v_x$	: x-yönünde konum bilgisi
$\dot{v}_x$	: x-yönünde hız bilgisi
$v_y$	: y-yönünde konum bilgisi
$\dot{v}_y$	: y-yönünde hız bilgisi
$S$	: Gauss Tipi Fonksiyonun minimum genlik katsayısı
$B$	: Gauss Tipi Fonksiyonun maksimum genlik katsayısı
$Coeff$	: Eşik katsayısı
$M$	: Örtüşme tespitinde kullanılan toplam çerçeve sayısı
$I$	: Birim matris
$I^J(x, y)$	: Tümlev imge

### Kısaltmalar

BODB	: Bölgesel Ortak Değişinti Betimleyici
DPS	: Düzenlenmiş Parçacık Süzgeci
FAR	: False Alarm Rate (Yanlış Alarm Oranı)
GKS	: Genişletilmiş Kalman Süzgeci
GTF	: Gauss tipi fonksiyon
ICDF	: Inverse Cumulative Distribution Function (Ters Birikimli Dağılım Fonksiyonu)
ICTL	: Incremental Covariance Tensor Learning (Artımsal Ortak Değişinti Tensör Öğrenme)
IS	: Importance Sampling (Önem Örnekleme)
KKS	: Kokusuz Kalman Süzgeci
KS	: Kalman Süzgeci
MC	: Monte Carlo
MR	: Multinomial Resampling (Çoklu Yeniden Örnekleme)
ODB	: Ortak Değişinti Betimleyici
OTKH	: Ortalama Tümlev Karesel Hata
SIR	: Sampling Importance Resampling (Örnekleme Önem Yeniden Örnekleme)
PDF	: Probability Density Function (Olasılık Yoğunluk Fonksiyonu)
PS	: Parçacık Süzgeci

RR	: Residual Resampling (Artıklı Yeniden Örnekleme)
SBODB	: Standart Bölgesel Ortak Değişinti Betimleyici
SIS	: Sequential Importance Sampling (Ardışık Önem Örnekleme)
SMC	: Sequential Monte Carlo (Ardışık Monte Carlo)
SR	: Systematic Resampling (Sistematik Yeniden Örnekleme)
STR	: Stratified Resampling (Katmanlı Yeniden Örnekleme)
YÖ	: Yeniden Örnekleme

## VIDEO İÇİN BÖLGESEL ORTAK DEĞİŞİM BETİMLEYİCİ TABANLI İYİLEŞTİRİLMİŞ HEDEF TAKİBİ

### ÖZET

Video dizilerinde görsel takip; bilgisayar-insan etkileşimi, araç navigasyonu, video indeksleme ve görsel denetim uygulamalarında önemli bir konudur. Hedef nesnelerin görünümünde değişikliğe neden olan konum değişimi, aydınlatma değişikliği, örtüşme ve gürültü gibi faktörlerin üstesinden gelmek için birçok görsel takip yaklaşımı önerilmiştir. Takip işleminde hedefi temsil etmek için genellikle renk histogramı veya gradyan temelli histogram gibi tek bir öznitelik betimleyici kullanılmaktadır. Literatürde, hedefi temsil etmek için tek bir öznitelik betimleyici yerine çoklu öznitelik betimleyiciler de tercih edilmiştir. Bu yaklaşımlar, artan hesapsal yük pahasına hedef takip performansını arttırmakta ve hedef takibinde gürbüzlük sağlamaktadır.

Öznitelik vektörleri arasında ilintiye sahip, bununla birlikte uzamsal ve istatistiksel özellikleri içeren bölgesel ortak değişinti betimleyiciler, görsel takipte hedef gösterimi için yaygın bir şekilde kullanılmaktadır.

Bu tez kapsamında, bölgesel ortak değişinti betimleyicilerini karşılaştırmak için yeni bir benzeme ölçütü önerilmektedir. Önerilen özgün yöntem ile ortak değişinti betimleyici temelli hedef takip yaklaşım performansının artırılması amaçlanmıştır. Bu yöntemde, standart ortak değişinti temelli hedef takip yaklaşımına göre daha iyi bir hedef takip performansı elde etmek için uzaklık metriğine, öznitelik vektörlerinin birinci dereceden istatistikleri dahil edilmiştir.

Bu tezde, görünüm değişikliği, sahnede benzer nesnelerin olması, örtüşme gibi nispeten karmaşık durumlarda görsel takip performansını arttırmak için yeni bir yaklaşım önerilmektedir. Önerilen özgün yöntem, Gauss ağırlıklandırmasına ve Kalman süzgecine dayanmaktadır. Ayrıca uzaklık ölçütüne bağlı yeni bir örtüşme tespit aşaması, bu yöntemde dahil edilmiştir.

Bu tezde ayrıca, düşük hesapsal yüke sahip bölgesel ortak değişinti betimleyici temelli hedef takibi önerilmiştir. Önerilen yöntemin temeli, hedef bölge içinde daha az sayıda piksel seçerek ortak değişinti betimleyicilerin oluşturulmasıdır.

**Anahtar Kelimeler:** Bölgesel Ortak Değişinti Betimleyicileri, Hedef/Nesne Takibi, Kalman Süzgeci, Parçacık Süzgeci.

## **REGIONAL COVARIANCE DESCRIPTOR BASED ENHANCED TARGET TRACKING FOR VIDEO**

### **ABSTRACT**

Visual tracking of objects in video sequences is an important topic in computer vision applications, including visual surveillance, video indexing, vehicle navigation, human-computer interaction. Various visual tracking approaches have been proposed to handle changes in appearance of objects caused by pose variation, illumination changes, occlusions and noise etc. . Conventionally, a single feature descriptor such as color histogram or gradient based histogram has been used to represent the target for tracking purposes. Instead of using a single feature descriptor, multi-feature descriptors have also been used for target representation in the literature. These approaches can improve the target tracking performance and achieve robustness at the expense of computational load.

The region covariance descriptor, which includes statistical and spatial features as well as correlation between features, has been widely used for target representation in visual tracking.

In this thesis, a new dissimilarity criterion has been proposed to compare region covariance descriptors. It is aimed that the performance of the covariance descriptor based object tracking approach increases using the proposed original method. In this method, the first-order statistics of the features have been integrated into the distance metric to obtain a better tracking performance with respect to standard covariance tracking.

In this thesis, it has been proposed as a novel approach to increase performance of visual tracking in relatively complex situations such as occlusion, similar objects within the scene, appearance changes etc. The proposed method is based on Gaussian weighting and Kalman Filtering approaches. In addition, a new occlusion detection stage, which depends on the distance metric, is integrated to the proposed method.

In this thesis, region covariance descriptor based target tracking with low computational load has also been proposed. The fundamentals of the proposed method is to select fewer pixels within the target region to construct the region covariance descriptor.

**Key Words:** Region Covariance Descriptor, Target/Object Tracking, Kalman Filter, Particle Filter.

## **GİRİŞ**

Günümüzde algıyacılar, güvenlik uygulamaları başta olmak üzere birçok alanda hayatımıza girmiş ve günlük yaşantımızda yaygın bir şekilde kullanılmaktadır. Tipik görüntü algılayıcıları olan kameralar ile akıllı güvenlik sistemleri, ürün kalite denetimi, biyometrik tanıma ve medikal görüntüleme uygulamalarını gerçekleştirmek mümkündür. Özellikle kentsel ortamlarda, trafik olaylarını gözetlemek için kullanılan kameraların sayısı her geçen gün artmaktadır. Bununla birlikte, el kameraları (harici kameralar) veya cep telefonlarında gömülü halde bulunan dâhili kameralar gelişen teknolojiye paralel olarak yüksek çözünürlükte kayıt yapabilir hale gelmiştir.

Kameralar ile yapılan kayıtları, elle, yarı-otomatik veya tam-otomatik olarak incelemek mümkündür. Elle yapılan video gözetiminde, kayıtlar bir insan tarafından incelenmektedir. Yarı-otomatik bir gözetlemede, sahnede önemli bir hareket olduğu durumlarda kayıt yapan bir kamera bulunmakta, kayıtlar daha sonra yine insan tarafından incelenmektedir. Tam otomatik bir gözetlemede ise, insandan bağımsız; kontrol, analiz ve raporlama işlemleri gerçekleştirilmektedir.

Görsel gözetleme sistemleri, insanların veya nesnelerin davranışlarını/hareketlerini gözlemlenmede sıklıkla tercih edilmektedir. Örneğin yüz tanıma, anormal olayların belirlenmesi, aktivite tanıma gibi sistemler, görsel gözetleme sistemlerinin birer parçası haline gelmiştir. Özellikle şehir merkezi veya alışveriş merkezlerinde bulunan gözetleme sistemlerindeki algoritmalar sayesinde, şüpheli şahıslarda görülen anormal hareketlerin doğru bir şekilde tespiti, devamında olabilecek muhtemel tehlikeleri engelleyebilecektir.

Nesne/Hedef tespiti ve takibi, görsel denetim, insan-bilgisayar etkileşimi ve trafik kontrolü, araç navigasyonu gibi bilgisayar görü uygulamalarında önemli bir rol üstlenmektedir. Görsel denetimde, hedefin bulunduğu yerin doğru bir şekilde belirlenmesi, anormal olayların tespit edilmesinde kolaylaştırıcı bir unsur olmaktadır.

Hedef takibinin amacı, takip edilen nesnelerin pozisyon, hız ve yön gibi zamansal bilgilerini çıkartmaktır. Bu doğrultuda, videonun ardışık çerçeveleri kullanılarak takip edilen nesnelere arasında benzerlik ilişkisi aranmaktadır.

Hedef takibi, hedef tespiti ile yakından ilişkili olup takip işleminin gerçekleştirilebilmesi için dolaylı olarak tespit işleminin yapılması gerekmektedir. Literatürde görsel takip olarak da bilinen hedef takibi, bilgisayarda görü uygulamalarında zorluk derecesi yüksek bir problemdir. 3 boyutlu gerçek uzaydan 2 boyutlu imge düzlemine geçiş sonrası yaşanan bilgi kaybı, imgelerde bulunan gürültü, karmaşık arkaplan yapısı, karmaşık nesne hareketi, nesnenin eklemli bir yapıya sahip olması, yarı veya tam örtüşme/kapatma olayları, sahnede değişen aydınlatma koşulları gibi faktörler hedef takibini zorlaştıran unsurlardır. Ancak tüm bu zorluklara rağmen, hedef takip işleminin gerçek zamanlı ve gürbüz bir performans göstermesi istenmektedir. Gürbüz bir hedef takip sistemi, en basit ifadeyle sahnede takip işlemini olumsuz etkileyen etkilere karşı duyarsız kalan bir sistemdir. Örneğin, kameralar ile alınan görüntülerin gürültü içermesi kaçınılmaz bir durumdur. Bu durumda işaret-gürültü oranına bağlı olarak (Signal to Noise Ratio-SNR) hedefi takip etmek güçleşmekte hatta hedef kaybedilebilmektedir.

Hedef takibini, takip edilen hedef sayısı ve takip işleminde kullanılan kamera sayısı olmak üzere iki ana sınıfa ayırmak mümkündür. Uygulamaya göre tek bir hedef takip edileceği gibi, sahnede bulunan tüm hareketli nesnelere takip etmek de mümkündür. Bununla birlikte hedef, sabit veya hareketli tek bir kamera ile izleneceği gibi birden fazla kamera kullanarak da izlenebilmektedir. Çoklu kamera kullanımı, özellikle sahnede sınırlı görüş açısı durumlarında veya örtüşme problemlerinde fayda sağlamaktadır. Çoklu kameralar ile alınan görüntülerde, kameralar arası veri iletişimi sağlıklı bir hedef takibinde önemli bir rol oynamaktadır. Bununla birlikte, takip edilen hedef sayısının ya da kamera sayısının artması işlem karmaşıklığını arttırabilmektedir.

Literatürde yapılan hedef takibi çalışmalarında, takip edilen hedef için genellikle görünüm modeli oluşturulmakta ve sonraki ardışık çerçevelerde bu görünüm modeline en uygun aday görünüm modeli aranmaktadır. Hedefe ait görünüm modeli, zamana göre sabit kalmakta ya da geçmiş çerçevelerde bulunan aday görünüm



modellerine göre güncellenmektedir. Görünüm modeli oluşturmada önemli ölçüt, hedefin karakteristik özelliklerinin kullanılmasıdır. Diğer bir ifadeyle, hedefi diğer nesnelere ayırt edecek betimleyicilerin ortaya çıkarılması ve bu betimleyicileri kullanarak görünüm modelinin oluşturulmasıdır. Hedefe ait renk bileşenleri yaygın olarak kullanılan betimleyicilerden olup, görünüm modelinin oluşturulmasında sıklıkla tercih edilmektedir. Gradyan bilgileri de alternatif olarak tercih edilen betimleyicilerdir. Hedef bölgenin görünüm modeli için birden fazla betimleyiciyi ya da öznitelik vektörünü bir arada kullanarak yüksek performanslı bir hedef takip sistemi elde etmek mümkündür.

Birden fazla betimleyicinin bir arada etkin bir şekilde kullanılmasına olanak tanıyan diğer bir yaklaşım ise ortak değişinti matrislerinin kullanılmasıdır. Simetrik ve pozitif tanımlı özelliğe sahip ortak değişinti matrisleri, yapısında hedefe ait renk, gradyan, pozisyon bilgileri gibi hedefi diğer nesnelere ayırt edecek karakteristik özellikler barındırmaktadır. Ortak değişinti matrislerinin boyutu, kullanılan özniteliklerin sayısına bağlıdır. Bu matrisler, yapısı gereği Riemannian manifoldlarında tanımlıdır. Ancak, yaklaşım (approximation) yöntemleriyle ortak değişinti matris temelli istatistiksel işlemleri, Öklid uzayında da gerçekleştirmek mümkündür.

Hedef takibinde, takip edilen hedef ya da hedeflerin konum, hız ve ivme gibi kinematik bileşenleri ya da rotasyon ve ölçekleme gibi ek bilgileri durum vektörüyle ifade edilebilmektedir. Durum değişkenleri ya da durum vektörleri, dinamik bir sistemin durum-uzay modelinde kullanılmaktadır. Durum-uzay modellerinde, sistemin doğrusal veya doğrusal olmamasına göre en uygun ya da en uyguna yakın durum kestirim yaklaşımları önerilmiştir. En uygun durum kestirim yaklaşımları, belirli varsayımlar altında gerçekleşmektedir. Bununla birlikte, sistemde doğrusal olmayan bir model mevcut ise, sistem farklı yakınlaştırma yöntemleriyle doğrusal hale getirilebilmektedir. Hedef takibinde, hedefin çevreler arası hareketleri arasında bir ilişki bulunmaktadır. Bu ilişkinin doğrusal veya doğrusal olmamasına göre uygun bir durum-uzay modeli seçilerek hedefin hareketi modellenmektedir. Durum kestiriminde kullanılacak model seçimi, hedef takip performansını doğrudan etkilemektedir. Diğer yandan, seçilen durum uzay modelinin karmaşıklığı hedef takibinin gerçek zamanlı çalışmasında da etkili olmaktadır.

Literatürde, ortak deęişinti matris temelli birçok hedef tespit ve hedef takip yöntemi mevcuttur. Bu yöntemlerin genel amacı, öncelikle hedef takip performansını arttırmaya yöneliktir. Bununla birlikte, hedef takip performansından en düşük düzeyde ödün vererek hedef takip işlem karmaşıklığını azaltmaya çalışan yöntemler de önerilmiştir. Arka plan karmaşıklığı içermeyen, örtüşmenin olmadığı görüntü dizilerinde, ortak deęişinti temelli birçok yöntem, hedefi başarıyla takip edebilmektedir. Hedef takibini zorlaştıran koşulların olduğu görüntü dizilerinde ise ortak deęişinti temelli yöntemlerin birçoğu hedefi yer yer tespit edememekte hatta hedefi kaybedebilmektedir.

Tez kapsamında gerçekleştirilen çalışmada, ortak deęişinti temelli hedef takibinin iyileştirilmesine yönelik özgün yöntemler geliştirilmiştir. Önerilen özgün yöntemlerin hesapsal yükü düşük olup, bu yöntemlerin genel amacı hedef takip performansını arttırmaya yöneliktir. Bu bağlamda, bu tez çalışmasında aşağıda belirtilen özgün yöntemler önerilmiştir.

1. Ortak deęişinti temelli hedef takibinde, hedefe ait referans ortak deęişinti matrisi ile aday ortak deęişinti matrisleri karşılaştırılırken, her iki ortak deęişinti matrisine ait ortalama öznitelik vektörleri karşılaştırmaya dahil edilmemektedir. Diğer bir ifadeyle ortalama deęişinti matrisleri, ortalama öznitelik vektörlerinden bağımsız bir yapıdadır. Önerilen yöntemde, ortalama deęişinti matrislerinin karşılaştırılmasına ilave olarak karşılaştırmaya ortalama öznitelik vektör bilgisi de dahil edilmiştir. Önerilen yöntemin başarımı, deterministik ve olasılıksal arama yaklaşımlarıyla değerlendirilmiştir. Bu yöntem sayesinde, standart ortak deęişinti temelli hedef takibine göre daha başarılı bir takip performansı elde edilmiştir.

2. Bu tez kapsamında ortak deęişinti temelli gürbüz bir hedef takip yaklaşımı önerilmiştir. Hedef takibinde, hedefi betimleyen yapıya benzer, birden fazla aday hedef bölgesi bulunabilmektedir. Bu durumda, doğru hedef bölgesi olmayan fakat en yüksek benzerlik gösteren bölgenin aday hedef bölgesi seçilmesi, hedef takibinin performansını düşürmekte hatta bir süre sonra hedefin kaybolmasına neden olabilmektedir. Betimleyiciler için bahsedilen bu durum, ortak deęişinti matrisleri için de geçerli olmaktadır. Bu doğrultuda, iki boyutlu Gauss fonksiyonu ile oluşturulan ağırlıklandırma fonksiyonu, o anki çerçevede, hedefin bulunma

olasılığının yüksek olduğu konum etrafında, aday hedef konumları için hesaplanan uzaklık değerleriyle ağırlıklandırılmaktadır. Diğer yandan bulunma olasılığı yüksek, aday hedefin konumunu kestirebilmek için sisteme Kalman süzgeci dâhil edilmiştir. Ayrıca bu çalışmada, zamana göre elde edilen en düşük uzaklık bilgileri kullanılarak örtüşme tespit yaklaşımı önerilmiştir.

3. Bu tezde, ortak değişinti temelli hedef takibinin düşük işlemsel yük ile gerçekleştirilmesi için özgün bir yöntem önerilmiştir. Hedef bölge üzerinde tüm pikseller kullanarak ortak değişinti betimleyiciler oluşturulmaktadır. Önerilen yöntem ile daha az sayıda piksel kullanarak ortak değişinti betimleyicilerin oluşturulması amaçlanmıştır. Farklı piksel seyreltme yaklaşımlarından yola çıkılarak oluşturulan ortak değişinti betimleyicilerin hedef takip performansları irdelenmiştir.

Tez kapsamının ilk bölümünde, doğrusal ve doğrusal olmayan durum-uzay modelleri anlatılmıştır. Bu bölümde, önerilen özgün yöntemler ile bütünlük sağlaması açısından Kalman süzgeci ve Parçacık süzgecinden detaylı olarak bahsedilmiştir. 2. bölümde, hedef tespiti ve takibi ve hedefi betimlemede kullanılan görünüm modelleri anlatılmıştır. Hedef takibinde karşılaşılan temel problemlere değinilmiştir. Ayrıca, tez kapsamında önerilen özgün yöntemlerin başarımını değerlendirmede kullanılan görsel veri setleri açıklanmıştır. 3. bölümde, ortak değişinti betimleyiciler detaylı olarak anlatılmış, ortak değişinti temelli hedef takibi konusunda yapılmış literatür çalışmalarına detaylı olarak yer verilmiştir. 4. 5. ve 6. bölümlerde ise tez kapsamında önerilen özgün yöntemlerden bahsedilmiştir. Son bölümde, sonuçlar hakkında değerlendirme yapılmış, gelecekte konu ile ilgili yapılabilecek çalışmalar hakkında önerilerde bulunulmuştur.

## 1. DOĞRUSAL VE DOĞRUSAL OLMAYAN DURUM UZAY MODELLERİ

Mühendislik, ekonomi vb. alanlara ait süreçler, durum-uzay modelleri ile tanımlanabilmektedir. Herhangi bir sürecin matematiksel model ile ifade edilmesi durumunda, sürecin denetimi mümkün olmaktadır.

Dinamik bir sistemde  $k$  anında sisteme ait özellikler durum değişkenleriyle ifade edilebilmektedir. Durum değişkenlerinin bir arada bulunması, sistemin durum vektörüne karşılık gelmektedir. Sistemin gelecekteki durum vektörü, o anki durum vektöründen ve sistem girdilerinden belirlenmektedir. Durum değişkenleri arasında bir ilişki olması durumunda, durum uzay modelini oluşturmak mümkündür. Bu bağlamda dinamik bir sistemde durum uzay modeli, sürekli zamanda doğrusal differansiyel denklemler veya ayrık zamanda fark denklemleri arasındaki fonksiyonel ilişkiyle gösterilmektedir. Diğer bir ifadeyle, differansiyel veya fark eşitlikleri, dinamik bir sistemin davranışını göstermektedir [1].

Durum uzay modelleriyle tanımlanan bir sistem, zamana bağımlı ya da zamandan bağımsız olabilmektedir. Bununla birlikte, sürekli zaman veya ayrık zamana göre incelenen durum uzay modelleri, doğrusal ya da doğrusal olmayan bir yapıda da olabilmektedir.

Durum uzay modelleri iki model kullanarak geliştirilebilmektedir. Bunlardan ilki, durum vektörünün zaman göre gürültü ve harici girdilere bağılı olarak değişimini gösteren süreç modeli ya da dinamik modeldir. Diğer model ise, süreçten gürültülü ölçümlerin alındığı ölçüm ya da gözlem modelidir. Tablo 1.1'de dinamik sistemler için durum uzay modelleri gösterilmektedir.

Tezin bu bölümünde ayrık zamanlı doğrusal ve doğrusal olmayan durum uzay modellerinden bahsedilmiş, bu modellerde yaygın olarak kullanılan durum ve parametre kestirim yaklaşımları irdelenmiştir.

Tablo 1.1. Dinamik sistemler için durum uzay modelleri

Model türü	Sürekli zamanlı model	Ayrık zamanlı model
Zamanla değişmeyen	$\dot{x}(t) = f(x(t), u(t), w(t))$ $z(t) = h(x(t), r(t))$	$x_k = f(x_{k-1}, u_{k-1}, w_{k-1})$ $z_k = h(x_k, r_k)$
Zamanla değişen	$\dot{x}(t) = f(t, x(t), u(t), w(t))$ $z(t) = h(t, x(t), r(t))$	$x_k = f_k(x_{k-1}, u_{k-1}, w_{k-1})$ $z_k = h_k(x_k, r_k)$

Tablo 1.1’de,  $f(\cdot)$  ve  $h(\cdot)$  sırasıyla süreç ve ölçüm model fonksiyonlarına karşılık gelmektedir.  $x$  ve  $\dot{x}$  sırasıyla durum modeline ait durum değişkenini ve durum değişkeninin türevini göstermektedir. Sistem çıkışı ve kontrol girişi ise sırasıyla  $z$  ve  $u$  ile gösterilmiştir.  $w$  ve  $r$  sırasıyla sistemin süreç ve ölçüm gürültülerine karşılık gelmektedir.

### 1.1. Doğrusal Durum Uzay Modeli

Doğrusal durum-uzay modeli  $f(\cdot)$  ve  $h(\cdot)$  fonksiyonlarının doğrusal olduğu modeldir. Doğrusal durum modelleri, doğrusal süreçler üzerine kurulmuş modellerdir. Doğrusal veya doğrusal olmayan bir süreçte, durumun olasılık yoğunluk fonksiyonunu kestirme problemi, durum kestirime karşılık gelmektedir. Durum kestirimi için bilinen en yaygın yöntem, Bayes kestirimidir.

#### 1.1.1. Bayes kestirimi

Bayes teoremi [2], olasılığın bir dalı olup, gözlemsel verilerin ve ön bilgilerin bir arada değerlendirilerek belirsiz bir olayın modellenmesine dayanmaktadır. Olasılık teorisinde  $B$  olayına bağlı/koşullu  $A$  olayı  $P(A|B)$  ile  $A$  olayı bilindiğinde  $B$  olayının gerçekleşme olasılığı  $P(B|A)$  birbirinden farklı olmaktadır. Bununla birlikte  $P(A|B)$  ve  $P(B|A)$  koşullu olasılıklar arasında bir ilişki bulunmaktadır. Bu ilişki Bayes teoremi olarak bilinmektedir. Bu teorem Eşitlik (1.1)’de gösterilmektedir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (1.1)$$

$P(A)$  ve  $P(B)$ , önsel olasılıklarına karşılık gelmektedir.

Özellikle hedef takip uygulamalarında, nesnelerin durum vektörleriyle gösterildiği durumlarda durum kestirimi, hedef takip performansı açısından önemli bir rol oynamaktadır. Durum kestirimi, süreçlere ait durumların sonsal olasılık yoğunluk fonksiyonlarını (Probability density function- PDF) kestirme problemidir.

Durum kestiriminde yaygın olarak tercih edilen Bayes kestirimi, Eşitlik (1.2)'de süreç ve ölçüm modeli verilen bir sistemin durumlarının sonsal PDF'lerini, özyineli olarak kestirmede kullanılmaktadır.

$$\begin{aligned}\mathbf{x}_k &= f_k(\mathbf{x}_{k-1}, \mathbf{w}_{k-1}) \\ \mathbf{z}_k &= h_k(\mathbf{x}_k, \mathbf{v}_k)\end{aligned}\tag{1.2}$$

Burada  $\mathbf{x}_k$  ayrık zamanlı durum vektörü ve  $\mathbf{z}_k$  ölçüm vektörüne karşılık gelmektedir. Sonsal PDF  $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ ,  $k$  anına kadar elde edilen ölçüm değerlerinin kullanılarak,  $k$  anındaki  $\mathbf{x}_k$  durum vektörünün hesaplanmasıdır. Özyinelemeli Bayes kestirimi, iki varsayıma dayanmaktadır.

Varsayım 1: Durum vektörleri Eşitlik (1.3)'te gösterildiği gibi 1. derece Markov süreciyle tanımlanmaktadır. 1. derece Markov özelliğinde,  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$ , geçmişteki durum vektörlerinden bağımsızdır.

$$p(\mathbf{x}_k | \mathbf{x}_{1:k-1}) = p(\mathbf{x}_k | \mathbf{x}_{k-1})\tag{1.3}$$

Varsayım 2:  $k$  anındaki ölçüm değeri  $\mathbf{z}_k$ , o anki durum vektörüne bağlı olup önceki durumlardan bağımsızdır. Bu durum Eşitlik (1.4)'te gösterilmektedir.

$$p(\mathbf{z}_k | \mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_1) = p(\mathbf{z}_k | \mathbf{x}_k)\tag{1.4}$$

( $k-1$ ) anında sonsal PDF  $p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1})$  bilindiğinde,  $p(\mathbf{x}_k | \mathbf{z}_{1:k-1})$  önsel olasılık yoğunluk fonksiyonunu hesaplamak için Eşitlik (1.5)'te verilen Chapman-Kolmogorov eşitliği kullanılmaktadır.

$$p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} \quad (1.5)$$

Eşitlik (1.3), (1.4) ve (1.5)'ten yola çıkarak, sonsal PDF'in Bayes kestirim teoremiyle hesaplanması Eşitlik (1.6)'da verilmektedir.

$$\begin{aligned} p(\mathbf{x}_k | \mathbf{z}_{1:k}) &= \frac{p(\mathbf{z}_{1:k} | \mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{z}_{1:k})} \\ &= \frac{p(\mathbf{z}_k, \mathbf{z}_{1:k-1} | \mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{z}_k, \mathbf{z}_{1:k-1})} \\ &= \frac{p(\mathbf{z}_k | \mathbf{z}_{1:k-1}, \mathbf{x}_k) p(\mathbf{z}_{1:k-1} | \mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{z}_k | \mathbf{z}_{1:k-1}) p(\mathbf{z}_{1:k-1})} \\ &= \frac{p(\mathbf{z}_k | \mathbf{z}_{1:k-1}, \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) p(\mathbf{z}_{1:k-1}) p(\mathbf{x}_k)}{p(\mathbf{z}_k | \mathbf{z}_{1:k-1}) p(\mathbf{z}_{1:k-1}) p(\mathbf{x}_k)} \\ &= \frac{p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1})}{\int p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) d\mathbf{x}_k} \end{aligned} \quad (1.6)$$

$\int p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) d\mathbf{x}_k$  normalizasyon sabitidir.

Eşitlik (1.2)'de verilen süreç ve ölçüm modeli sırasıyla  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$  ve  $p(\mathbf{z}_k | \mathbf{x}_k)$  olasılık dağılımları yönünden tanımlanabilmektedir. Bu bağlamda Bayes kestirimi, süreç modelinden elde edilen durum ilerleme dağılımını  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$  kullanarak önsel bir kestirim yapmaktadır. Bir sonraki aşamada önsel kestirim, ölçüm modelinden elde edilen ölçüm olabilirliği  $p(\mathbf{z}_k | \mathbf{x}_k)$  kullanılarak güncellenmektedir. Diğer bir ifadeyle sonsal kestirim yapılmaktadır.

Çok boyutlu durum vektörlerine ait sonsal PDF'lerin hesaplanması, çok boyutlu tümlev alma işlemlerinden dolayı oldukça zorlaşmaktadır. Bu nedenle Bayes kestirimi, genellikle kavramsal bir çözüm sunmaktadır. Bayes kestiriminin analitik çözümü, belirli koşullar altında alternatif yaklaşımlar kullanılarak yapılabilmektedir.

### 1.1.2. Kalman süzgeci

Kalman süzgeci [3] (KS), Bayes kestiriminin gerçekleştirilebilir yapıda olmasını sağlayan bir durum kestirim yaklaşımıdır. KS, durum vektör dağılımlarını 1. ve 2.dereceden momentlerle temsil etmekte ve doğrusal sistemler için en uygun Bayes

kestirimini sağlamaktadır. KS, olasılık dağılımlarının sadece ortalama ( $\mu$ ) ve değişinti ( $\sigma^2$ ) değerinden faydalanmaktadır.

Doğrusal bir durum uzay modeline Gauss dağılımlı bir giriş durum vektörü verildiğinde, durum uzay modelinin çıktısı da Gauss dağılımlı olmaktadır [4]. KS, durumların Gauss dağılımlı olduğu varsayılarak, süreç/ölçüm modelinin doğrusal olması ve süreç/ölçüm gürültüsünün de Gauss dağılımlı olması koşuluyla en uygun durum kestirimini gerçekleştirmektedir. Diğer bir ifadeyle KS, Bayes kestiriminden sınırlı koşullar altında en uygun çıkarım yapmaktadır.

Eşitlik (1.2)'de gösterilen süreç ve ölçüm modelleri KS'ye göre Eşitlik (1.7)'de yeniden tanımlanmaktadır.

$$\begin{aligned}\mathbf{x}_k &= \mathbf{A}_k \mathbf{x}_{k-1} + \mathbf{w}_{k-1} \\ \mathbf{z}_k &= \mathbf{H}_k \mathbf{x}_k + \mathbf{r}_k\end{aligned}\tag{1.7}$$

Burada  $\mathbf{A}_k$ , durum geçiş matrisini,  $\mathbf{H}_k$  ise gözlem matrisini göstermektedir.  $\mathbf{w}_{k-1}$  ve  $\mathbf{r}_k$  sırasıyla süreç ve ölçüm gürültüsüne karşılık gelmektedir.  $\mathbf{w}_{k-1}$ , sıfır ortalamalı ve  $\mathbf{Q}_k$  ortak değişintili normal dağılıma sahip bir gürültüdür.  $\mathbf{r}_k$ , sıfır ortalamalı ve  $\mathbf{R}_k$  ortak değişintili normal dağılıma sahip bir gürültüdür.  $\mathbf{w}_{k-1}$  ve  $\mathbf{r}_k$  gürültüleri Eşitlik (1.8)'de gösterildiği gibi birbirinden bağımsızdır.  $\mathbf{A}_k$ ,  $\mathbf{H}_k$ ,  $\mathbf{Q}_k$  ve  $\mathbf{R}_k$  zamana bağlı matrislerdir. Bununla birlikte, bu matrisler süreç boyunca zamandan bağımsız, sabit değerler alabilmektedir.

$$\begin{aligned}\mathbf{w}_{k-1} &\sim N(0, \mathbf{Q}_{k-1}) \quad \mathbf{r}_k \sim N(0, \mathbf{R}_k) \\ E(\mathbf{w}_i \mathbf{w}_j^T) &= \mathbf{Q}(i) \delta_{ij} \\ E(\mathbf{r}_i \mathbf{r}_j^T) &= \mathbf{R}(i) \delta_{ij} \\ E(\mathbf{w}_i \mathbf{r}_j^T) &= 0\end{aligned}\tag{1.8}$$

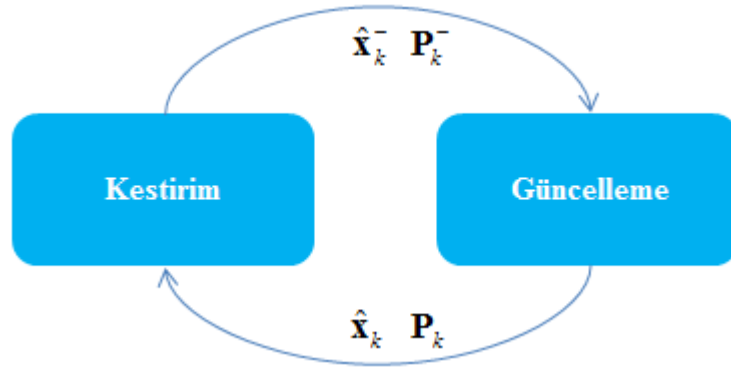
$\delta_{ij}$ , Kronecker delta fonksiyonudur. KS, Şekil 1.1'de gösterildiği gibi kestirim ve güncelleme olmak üzere iki temel aşamadan oluşmaktadır. İlk aşama; ölçümlerin henüz dikkate alınmadığı, bir sonraki durum hakkında tahmin yapıldığı Eşitlik (1.9)



ile verilen kestirim aşamasıdır. Önsel kestirimlerin yapıldığı bu aşama, sistemin durumu hakkında önsel bilgi vermektedir.

$$\begin{aligned}\hat{\mathbf{x}}_k^- &= \mathbf{A}_k \hat{\mathbf{x}}_{k-1} \\ \mathbf{P}_k^- &= \mathbf{A}_k \mathbf{P}_{k-1} \mathbf{A}_k^T + \mathbf{Q}_{k-1}\end{aligned}\quad (1.9)$$

$\hat{\mathbf{x}}_k^-$  k anındaki önsel durum kestirimini,  $\mathbf{P}_k^-$  ise k anındaki önsel hata ortak değışinti kestirimini göstermektedir.



Şekil 1.1. Özyinelemeli Kalman süzgeç yapısı

KS'nin diğer aşamasında önsel kestirimler, k anında alınan ölçümler ile Eşitlik (1.10)'da verildiği gibi güncellenmektedir.

$$\begin{aligned}K_k &= \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \\ \hat{\mathbf{x}}_k &= \hat{\mathbf{x}}_k^- + K_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^-) \\ \mathbf{P}_k &= (\mathbf{I} - K_k \mathbf{H}_k) \mathbf{P}_k^-\end{aligned}\quad (1.10)$$

$\hat{\mathbf{x}}_k$ , güncelleme işlemi sonrası elde edilen sonsal durum kestirimidir.  $\mathbf{P}_k$ , sonsal hata ortak değışintisi olup kestirimin doğruluğu hakkında fikir vermektedir.  $K_k$  ise Kalman kazancıdır. Kalman kazancı, Eşitlik (1.11)'de verildiği gibi sonsal hata özdeğışintisini minimum yapmayı amaçlamaktadır.

$$\begin{aligned}
\mathbf{e}_k &= \mathbf{x}_k - \hat{\mathbf{x}}_k = \mathbf{x}_k - \left( \hat{\mathbf{x}}_k^- + K \left( \mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^- \right) \right) \\
\mathbf{P}_k &= E \left\{ \mathbf{e}_k \mathbf{e}_k^T \right\} = E \left\{ \left( \mathbf{x}_k - \left( \hat{\mathbf{x}}_k^- + K \left( \mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^- \right) \right) \right) \left( \mathbf{x}_k - \left( \hat{\mathbf{x}}_k^- + K \left( \mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^- \right) \right) \right)^T \right\} \\
\frac{d}{dK} (\mathbf{P}_k) &= 0 \Rightarrow K_k = P_k^- \mathbf{H}^T (\mathbf{H} P_k^- \mathbf{H}^T + \mathbf{R})^{-1}
\end{aligned} \tag{1.11}$$

Burada  $\mathbf{e}_k$ , gerçek durum vektörü ile sonsal durum kestirimi arasındaki hata vektörüdür. Kalman kazancı, önsel durum kestirimi ile alınan ölçüm arasında bir dengeleme yapmaktadır. Örneğin,  $\mathbf{R}_k$  ölçüm ortak değişinti matrisi büyük olduğu takdirde Kalman kazancı azalacaktır. Bu durumda, sonsal kestirim hesabında o anda hesaplanan ölçüm değerinin etkisi azalacaktır. Diğer yandan  $\mathbf{R}_k$ , küçük olduğu takdirde Kalman kazancı artacaktır. Bu durumda alınan ölçüm değeri, önsel kestirime göre daha güvenilir olmaktadır. Bununla birlikte,  $\mathbf{P}_k^-$  önsel hata ortak değişinti matrisinin sıfıra yaklaşması durumunda, alınan ölçüm değeri, önsel kestirime göre daha az güvenilir olmaktadır.

Bayes kestiriminden elde edilen KS, Eşitlik (1.12)'de verildiği gibi Gauss dağılımlı olasılıksal bir biçimde özyinelemeli olarak tanımlanabilmektedir.

$$\begin{aligned}
p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) &= \mathbf{N}(\hat{\mathbf{x}}_{k-1}, \mathbf{P}_{k-1}) \\
p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) &= \mathbf{N}(\hat{\mathbf{x}}_k^-, \mathbf{P}_k^-) \\
p(\mathbf{x}_k | \mathbf{z}_{1:k}) &= \mathbf{N}(\hat{\mathbf{x}}_k, \mathbf{P}_k)
\end{aligned} \tag{1.12}$$

Günümüzde düşük işlem yüküne sahip KS, işaret işleme uygulamalarında [5], ekonomide ve özellikle hedef takip uygulamalarında [6] yaygın bir şekilde kullanılmaktadır.

## 1.2. Doğrusal Olmayan Durum Uzay Modeli

KS, doğrusal durum uzay modelinde belirli varsayımlar altında en uygun durum kestirim sonucunu vermektedir. Ancak birçok sistem, doğrusal olmayan süreç modeli ve/veya ölçüm modeli içermektedir. Bu tür sistemlerde, KS'nin durum kestirim başarımı azalmaktadır. Tezin bu bölümünde, doğrusal olmayan durum uzay modelleri için kullanılan en uyguna yakın durum kestirim yaklaşımlarından bahsedilmektedir.

### 1.2.1. Genişletilmiş Kalman süzgeci

Doğrusal olmayan sistemlerde durum kestirimi için önerilen yaklaşımlardan biri Genişletilmiş Kalman süzgecidir (GKS) [7,8]. GKS, dinamik bir sistemin doğrusal olmayan süreç ve ölçüm modellerini Taylor serisi açılımını kullanarak doğrusallaştırmaktadır. Böylelikle doğrusal bir yapıya dönüşen sistemin KS ile durum kestirimini gerçekleştirmek mümkündür. GKS’de, KS’de olduğu gibi gürültülerin Gauss dağılımlı ve birbirinden bağımsız olduğu varsayılmaktadır.

GKS, Eşitlik (1.13)’te verilen doğrusal olmayan  $f_k(\cdot)$  ve  $h_k(\cdot)$  fonksiyonlarını beklendik durum vektörü etrafında Jacobian matrisini hesaplayarak çözmektedir. Jacobian işlemi, durum değişkenlerin kısmi türevlerini hesaplamaktadır.

$$\begin{aligned}\mathbf{x}_k &= f_k(\mathbf{x}_{k-1}) + \mathbf{w}_{k-1} \\ \mathbf{z}_k &= h_k(\mathbf{x}_k) + \mathbf{r}_k\end{aligned}\tag{1.13}$$

Burada süreç ve ölçüm gürültüleri, toplanır özelliğe sahiptir. Gürültülerin toplanır olmaması durumunda, Jacobian matris hesabının süreç ve ölçüm gürültülerine göre de hesaplanması gerekmektedir.

(k-1) anında sonsal durumu  $\mathbf{x}_{k-1}$  ve sonsal ortak değişinti matrisi  $\mathbf{P}_{k-1}$  olarak bilinen bir sistemin durumu,  $\bar{\mathbf{x}} = \mathbf{x}_{k-1}$  ortalamalı ve  $\mathbf{P}_{xx} = \mathbf{P}_{k-1}$  ortak değişintili rasgele bir durum vektörü olarak tanımlanabilmektedir. Bu bağlamda Eşitlik (1.13)’te belirtilen doğrusal olmayan süreç modeli,  $y = f(x)$  notasyonu ile Taylor serisi açılımını kullanarak Eşitlik (1.14)’teki gibi yazılabilmektedir.

$$\begin{aligned}f(\mathbf{x}) &= f(\bar{\mathbf{x}} + \Delta\mathbf{x}) \\ &= f(\bar{\mathbf{x}}) + \nabla f \Delta\mathbf{x} + \frac{1}{2!} \nabla^2 f \Delta\mathbf{x}^2 + \dots + \frac{1}{n!} \nabla^n f \Delta\mathbf{x}^n\end{aligned}\tag{1.14}$$

$$\nabla f = \left. \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\bar{\mathbf{x}}}, \text{ kısmi türev operatörü ve } \Delta\mathbf{x} \sim N(0, \mathbf{P}_{xx}), \text{ Gauss formundadır. } f(x)$$

fonksiyonu Taylor serisine açıldığında, fonksiyona ait beklendik ve ortak değişinti hesabı Eşitlik (1.15)’te gösterilmektedir.

$$\begin{aligned}\bar{y} &= f(\bar{\mathbf{x}}) + \frac{1}{2} \nabla^2 f \mathbf{P}_{xx} + \frac{1}{2} \nabla^4 f \mathbf{E}(\Delta \mathbf{x}^4) + \dots \\ \mathbf{P}_{yy} &= \nabla f \mathbf{P}_{xx} (\nabla f)^T + \frac{1}{2 \times 4!} \nabla^2 f \left[ \mathbf{E}(\Delta \mathbf{x}^4) - \mathbf{E}(\Delta \mathbf{x}^2 \mathbf{P}_{xx}) - \mathbf{E}(P_{yy} \Delta \mathbf{x}^2) + \mathbf{P}_{yy}^2 \right] (\nabla^2 f)^T + \dots\end{aligned}\quad (1.15)$$

Taylor serisi açılımında, gerek ortalama gerekse ortak değişinti hesabında düşük dereceli ifadelerin fonksiyona etkisi daha fazladır. Derece arttıkça fonksiyona olan etkileri azalmaktadır. GKS, Eşitlik (1.15)'te gösterilen  $f(\mathbf{x})$  fonksiyonuna ait Taylor serisi açılımında  $\Delta \mathbf{x}$ 'e bağlı ikinci ve daha yüksek dereceli terimleri ihmal etmektedir. Dolayısıyla ortalama ve ortak değişinti değerleri, birinci dereceden doğrusallaştırılarak Eşitlik (1.16)'daki gibi hesaplanmaktadır.

$$\begin{aligned}\bar{y} &= f(\bar{\mathbf{x}}) \\ \mathbf{P}_{yy} &= \nabla f \mathbf{P}_{xx} (\nabla f)^T\end{aligned}\quad (1.16)$$

GKS durum kestirimi, ortalama hesabında ikinci ve daha yüksek dereceden terimlerin, ortak değişinti hesabında ise dördüncü ve daha yüksek dereceden terimlerin fonksiyona bir etkisi olmadığı durumlarda iyi sonuç vermektedir.

GKS'de süreç modeli için gerçekleştirilen Taylor serisi açılımları, ölçüm modeli için de yapılmaktadır. Buna göre, KS'de kullanılan  $\mathbf{A}_k$  durum geçiş matrisi ve  $\mathbf{H}_k$  gözlem matrisi, GKS'de Eşitlik (1.17)'deki gibi hesaplanmaktadır.


$$\begin{aligned}\hat{\mathbf{A}}_k &= \left. \frac{\partial f_k(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1}} \\ \hat{\mathbf{H}}_k &= \left. \frac{\partial f_k(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_k^-}\end{aligned}\quad (1.17)$$

GKS, zamanla değişiklik gösteren durum geçiş matrisi ve gözlem matrisi dışında KS yapısındadır. GKS'de kullanılan kestirim ve güncelleme aşamaları sırasıyla Eşitlik (1.18) ve Eşitlik (1.19)'da gösterilmektedir.

$$\begin{aligned}\hat{\mathbf{x}}_k^- &= f_k(\hat{\mathbf{x}}_{k-1}) \\ \mathbf{P}_k^- &= \hat{\mathbf{A}}_k \mathbf{P}_{k-1} \hat{\mathbf{A}}_k^T + \mathbf{Q}_{k-1}\end{aligned}\quad (1.18)$$

$$\begin{aligned}
K_k &= \mathbf{P}_k^- \hat{\mathbf{H}}_k^T (\hat{\mathbf{H}}_k \mathbf{P}_k^- \hat{\mathbf{H}}_k^T + \mathbf{R}_k)^{-1} \\
\hat{\mathbf{x}}_k &= \hat{\mathbf{x}}_k^- + K_k (\mathbf{z}_k - h_k(\hat{\mathbf{x}}_k^-)) \\
\mathbf{P}_k &= (\mathbf{I} - K_k \hat{\mathbf{H}}_k) \mathbf{P}_k^-
\end{aligned} \tag{1.19}$$

GKS yaklaşımının bazı dezavantajları bulunmaktadır. Örneğin, örnekleme zaman aralığı yeterince küçük olmadığı durumlarda GKS'nin başarımı kararsız bir hale gelebilmektedir. Jacobian matrisinin hesaplanması, işlem yükünü arttırmaktadır. Bununla birlikte, ölçüm gürültüsünün fazla olduğu durumlarda, GKS'nin başarımı azalmaktadır. Şekil 1.2'de  $y = e^{x(t)}$  fonksiyonu, GKS ile ortalama  $\mu = 0$  etrafında 1. dereceden Taylor serisi ile doğrusallaştırılmaktadır. Fonksiyon girişi,  $p(x) = N(\mu, \sigma^2)$  Gauss rasgele değişkeni iken, doğrusal olmayan fonksiyon çıktısı Gauss formunda değildir. Buna rağmen fonksiyon çıktısı  $p(y)$ 'ye, Gauss modeliyle yakınsanabilmektedir. Şekil 1.2'de gösterildiği gibi, GKS ile  $y = ax + b$  doğrusallaştırma işlemi sonrasında elde edilen fonksiyon çıktısı Gauss formunda olup  $p(y)_{GKS} = N(\mu + b, a^2 \sigma^2)$  ile ifade edilmektedir. Doğrusal olmayan fonksiyonun derecesine bağlı olarak  $p(x)_{GKS}$  ile yanlış bir kestirim yapılacaktır.



Şekil 1.2. GKS ile doğrusal olmayan fonksiyonun doğrusallaştırılması


### 1.2.2. Kokusuz Kalman süzgeci

Doğrusal olmayan dinamik sistem modellerinde kullanılan bir diğer yaklaşım ise Kokusuz Kalman Süzgecidir (KKS). GKS, doğrusal olmayan sistemler için her zaman en uygun sonucu vermemektedir [9]. KKS yaklaşımı, GKS'deki gibi doğrusal olmayan süreç ve ölçüm model fonksiyonlarını doğrusal hale getirmek yerine, özel noktalar (sigma points) olarak isimlendirilen noktalar kümesini kullanarak, bu özel noktaların doğrusal olmayan fonksiyonlar üzerinden ilerletilmesini sağlamaktadır.

Kokusuz dönüşümde (unscented transform) [10] öncelikle  $\Sigma$  ortak değişinti matrisli ve  $\bar{\mathbf{x}}$  ortalamalı  $d$  boyutlu Gauss dağılımı üzerinden pozitif ve negatif karekök matrisi  $\pm\sqrt{d\mathbf{P}}$  ile  $2 \times d + 1$  adet özel noktalar oluşturulmaktadır. Özel noktalar ile hesaplanan ortalama ve ortak değişinti değerleri, orijinal Gauss dağılımının parametreleriyle aynı olmaktadır.  $\Sigma$  simetrik matrisin karekökü, hesapsal kolaylık bakımından Cholesky yöntemiyle hesaplanabilmektedir. Bu bağlamda  $\Sigma$  matrisi, çarpanlarına  $\Sigma = \mathbf{L}\mathbf{L}^T$  formunda ayrılabilir.  $\mathbf{L}$  alt üçgenel matrisi,  $\Sigma$  matrisin kareköküdür. Bununla birlikte karekök hesabı, Cholesky dışında farklı yaklaşımlar kullanarak da hesaplanabilmektedir.

Şekil 1.3'te özel noktaların oluşturulması gösterilmektedir. Şekil 1.3'te,  $\mathbf{t}_i$   $d$  boyutlu standart Öklid uzayı taban vektörlerine karşılık gelmektedir.  $\mathbf{t}_0$  ortalamalı ve  $\mathbf{I}$  birim ortak değişinti matrisine sahip bir dağılım üzerinden koordinat dönüşümüyle  $\mathbf{s}_0$  ortalamalı ve  $\Sigma$  ortak değişintisine sahip bir dağılım elde edilmektedir. Bu dağılımın özel noktaları ise  $\mathbf{s}_i$  ile gösterilmektedir. Her bir  $\mathbf{t}_i$  noktası, dönüşüm sonrası  $\mathbf{s}_i$  ile temsil edilmektedir.

Kokusuz dönüşüm, doğrusal olmayan dönüşümlere maruz kalan rasgele değişkenlerin istatistiksel özelliklerini hesaplamada yardımcı olmaktadır.  $\bar{\mathbf{x}}$  ortalamalı ve  $\mathbf{P}_{xx}$  ortak değişintili  $d$  boyutlu bir  $\mathbf{x}$  rasgele vektör, doğrusal olmayan  $\mathbf{y} = f(\mathbf{x})$  fonksiyonu ile ilerlemesi durumunda,  $\mathbf{y}$  rasgele vektörün ortalama  $\bar{\mathbf{y}}$  ve ortak değişinti matrisi  $\mathbf{P}_{yy}$ , kokusuz dönüşümle hesaplanabilmektedir.



Şekil 1.3. Koksuz dönüşümde özel noktaların oluşturulması

Eşitlik (1.20)'de,  $2 \times d + 1$  adet  $s_i$  özel noktaların oluşturulması ve bu özel noktalara ait ağırlıkların belirlenmesi gösterilmektedir.

$$\begin{aligned}
 \mathbf{s}_0 &= \bar{\mathbf{x}} \\
 \mathbf{s}_i &= \bar{\mathbf{x}} + \left( \sqrt{(d + \lambda) \mathbf{P}_{xx}} \right)_i \quad i=1, \dots, d \\
 \mathbf{s}_i &= \bar{\mathbf{x}} - \left( \sqrt{(d + \lambda) \mathbf{P}_{xx}} \right)_{i-d} \quad i=d+1, \dots, 2d \\
 \lambda &= \alpha^2 (d + \kappa) - d \\
 w_0^m &= \lambda/d + \lambda \\
 w_0^c &= \lambda/d + \lambda + (1 - \alpha^2 + \beta) \\
 w_i^m &= w_i^c = 1/2(d + \lambda) \quad i=1, \dots, 2d
 \end{aligned} \tag{1.20}$$

$\left( \sqrt{(d + \lambda) \mathbf{P}_{xx}} \right)_i$ ,  $\mathbf{P}_{xx}$  matris karekökünün  $i$ . sütununa karşılık gelmektedir.  $\lambda$ ,  $\kappa$ ,  $\beta$  ölçekleme parametreleridir.  $\alpha$  ise  $\bar{\mathbf{x}}$  etrafında bulunan özel noktaların yayılımını belirlemektedir.  $w_i^m$  ve  $w_i^c$  sırasıyla ağırlıklı ortalama ve ağırlıklı ortak değişinti hesabında kullanılacak ağırlık katsayılarıdır. Her bir  $\mathbf{s}_i$  özel noktasının,  $\mathbf{y}_i = f(\mathbf{s}_i)$  fonksiyonundan geçirilmesi sonrasında  $\mathbf{y}_i$  özel noktaları elde edilmektedir. Bu noktalara ait ağırlıklı ortalama ve ağırlıklı ortak değişinti matrisinin yaklaşık olarak ifadesi Eşitlik (1.21)'de gösterilmektedir.

$$\begin{aligned}
 \bar{\mathbf{y}} &\approx \sum_{i=0}^{2d} w_i^m \mathbf{y}_i \\
 \mathbf{P}_{yy} &\approx \sum_{i=0}^{2d} w_i^c (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})^T
 \end{aligned} \tag{1.21}$$

Kokusuz dönüşüm yaklaşımı, doğrusal olmayan fonksiyonlarda Gauss rasgele değişken durumları için Taylor serisi açılımına göre üçüncü dereceden doğruluk sağlamaktadır. Gauss olmayan rasgele değişken durumları için en az ikinci dereceden doğruluk elde edilmektedir.  $\alpha$  ve  $\beta$  parametrelerine bağlı olarak, daha yüksek dereceden doğruluklar elde etmek mümkündür [11].

Doğrusal olmayan sistemlerde, kokusuz dönüşüm kullanılarak KS ile durum kestirimi yapılabilmektedir [12]. KKS olarak bilinen bu yaklaşım, doğrusal olan sistemlerde KS'ye paralel olarak en uygun durum kestirim sonucunu vermektedir. Doğrusal olmayan sistemlerde ise durum kestirimi, KKS ile doğrusal olmayan süreç ve ölçüm fonksiyonu üzerinden özel noktalar kullanılarak tahmin edilmekte ve KS'ye göre daha başarılı bir sonsal durum kestirimi elde edilmektedir. KKS'de durum dağılımları KS'de olduğu gibi Gauss rasgele değişkeniyle gösterilmektedir. Bununla birlikte KKS'de, takviyeli (augmented) ve takviyesiz (non-augmented) olmak üzere iki farklı yaklaşım bulunmaktadır. Takviyesiz KKS, süreç ve ölçüm gürültüsünün doğrudan eklenebilir olduğu durumlarda kullanılmaktadır. Özel nokta sayısının takviyeli KKS'ye göre daha az olmasından dolayı işlem yükü takviyeli KKS'ye göre daha düşüktür.

$\bar{\mathbf{x}} = \hat{\mathbf{x}}_{k-1}$  ortalamalı ve  $\mathbf{P}_{k-1}$  ortak değişintisine sahip rasgele bir  $\mathbf{x}$  vektörü için takviyesiz KKS yönteminin durum kestirim ve ölçüm güncelleme aşamaları sırasıyla Eşitlik (1.22) ve Eşitlik (1.23)'te gösterilmektedir.

$$\begin{aligned}
\chi_{k-1} &= \left[ \bar{\mathbf{x}} \quad \bar{\mathbf{x}} + \left( \sqrt{(d+\lambda)\mathbf{P}_{k-1}} \right)_i \quad \bar{\mathbf{x}} - \left( \sqrt{(d+\lambda)\mathbf{P}_{k-1}} \right)_i \right] \quad i=1, \dots, 2d \\
\hat{\chi}_k &= f(\chi_{k-1}) \\
\hat{\mathbf{x}}_k^- &= \sum_{i=0}^{2d} w_i^m \hat{\chi}_{i,k} \\
\mathbf{P}_k^- &= \sum_{i=0}^{2d} w_i^c \left[ \hat{\chi}_{i,k} - \hat{\mathbf{x}}_k^- \right] \left[ \hat{\chi}_{i,k} - \hat{\mathbf{x}}_k^- \right]^T + \mathbf{Q}_{k-1} \\
\chi_k &= \left[ \hat{\mathbf{x}}_k^- \quad \hat{\mathbf{x}}_k^- + \left( \sqrt{(d+\lambda)\mathbf{P}_k^-} \right)_i \quad \hat{\mathbf{x}}_k^- - \left( \sqrt{(d+\lambda)\mathbf{P}_k^-} \right)_i \right] \quad i=1, \dots, 2d \\
\hat{\mathbf{Y}}_k &= h(\chi_k) \\
\hat{\mathbf{y}}_k^- &= \sum_{i=0}^{2d} w_i^m \hat{\mathbf{Y}}_{i,k}
\end{aligned} \tag{1.22}$$



$$\begin{aligned}
\mathbf{P}_{\hat{y}_k, \tilde{y}_k} &= \sum_{i=0}^{2d} w_i^c [\hat{Y}_{i,k} - \hat{y}_k^-] [\hat{Y}_{i,k} - \hat{y}_k^-]^T + \mathbf{R}_k \\
\mathbf{P}_{x_k, y_k} &= \sum_{i=0}^{2d} w_i^c [\hat{\chi}_{i,k} - \hat{x}_k^-] [\chi_{i,k} - \hat{y}_k^-]^T \\
\mathbf{K}_k &= \mathbf{P}_{x_k, y_k} \mathbf{P}_{\tilde{y}_k, \tilde{y}_k}^{-1} \\
\hat{x}_k &= \hat{x}_k^- + \mathbf{K}_k (\mathbf{y}_k - \hat{y}_k^-) \\
\mathbf{P}_k &= \mathbf{P}_k^- - \mathbf{K}_k \mathbf{P}_{\tilde{y}_k, \tilde{y}_k} \mathbf{K}_k^T
\end{aligned} \tag{1.23}$$

Eşitlik (1.22)'de özel noktalar, hem süreç fonksiyonu hem de ölçüm fonksiyonu için hesaplanmaktadır. Özel nokta hesabı, doğrusal olmayan süreç fonksiyonu sonrası elde edilen örneklem ortalama  $\hat{x}_k^-$  etrafında  $\mathbf{P}_k^-$  matrisine göre yeniden hesaplanmaktadır. Yeniden hesaplanan özel noktalar, doğrusal olmayan ölçüm fonksiyonundan geçirilerek ağırlıklı örneklem ortalama  $\hat{y}_k^-$  elde edilmektedir.

Eşitlik (1.23)'te ise Kalman kazancı ( $\mathbf{K}_k$ ) hesaplanıp ölçüm alınarak ( $\mathbf{y}_k$ ), sonsal durum kestirimi ( $\hat{x}_k$ ) ve sonsal hata ortak değişinti matrisi ( $\mathbf{P}_k$ ) elde edilmektedir. KS'de olduğu gibi KKS'de de özyinelemeli yapı korunmaktadır.

### 1.2.3. Parçacık süzgeci

En uygun Bayes kestiriminin analitik olarak çözülemediği durumlarda, kestirimin yaklaşık olarak ifade edilebilmesi için Monte Carlo (MC) örnekleme gibi en uyguna yakın yöntemler kullanılmaktadır. MC örnekleme,  $p(x)$  olasılık dağılımından örnekleme yapmadığı veya bir  $f(x)$  fonksiyonun beklendiği değerinin hesaplanmasının zor olduğu durumlarda tercih edilmektedir. Önem örnekleme (Importance Sampling- IS), MC örnekleme algoritmalarından olup ardışık önem örnekleme (Sequential Importance Sampling-SIS) temelini oluşturmaktadır. IS'de  $p(x)$  olasılık dağılımı yerine, örnekleme kolay yapılabildiği  $q(x)$  önem yoğunluk dağılımı kullanılmaktadır. Eşitlik (1.24)'te  $f(x)$  fonksiyonunun beklendiği değerinin, N sayıda örnek kullanarak yaklaşık olarak elde edilmesi gösterilmektedir.

$$\begin{aligned}
x^i &\sim p(x) \quad i=1,\dots,N \\
E[f(x)] &= \int f(x)p(x)dx \\
&\simeq \frac{1}{N} \sum_{i=1}^N f(x^i)
\end{aligned} \tag{1.24}$$

$x^i$  örneklerinin  $p(x)$  dağılımı yerine,  $x^i \sim q(x)$  olacak şekilde bir  $q(x)$  dağılımından üretilmesi durumunda hesaplanan tahmini beklendik değer Eşitlik (1.25)'te verilmektedir.

$$\begin{aligned}
x^i &\sim q(x) \quad i=1,\dots,N \\
E[f(x)] &= \int f(x) \frac{p(x)}{q(x)} q(x) dx \\
&\simeq \frac{1}{N} \sum_{i=1}^N \frac{p(x^i)}{q(x^i)} f(x^i) \\
&\simeq \frac{1}{N} \sum_{i=1}^N w^i f(x^i)
\end{aligned} \tag{1.25}$$

$w^i = \frac{p(x^i)}{q(x^i)}$ , IS'de ağırlık parametresidir.  $p(x)$  dağılımı,  $w^i$  ağırlığına bağlı olarak

yaklaşık olarak Eşitlik (1.26)'da verildiği gibi ifade edilmektedir.

$$p(x) \approx \sum_{i=1}^N w^i \delta(x - x^i) \tag{1.26}$$

$w^i$  ağırlığını, zamana bağlı olarak özimizelemeli bir şekilde ifade etmek mümkündür. Bu bağlamda, IS'yi, SIS ile ifade etmek mümkündür. SIS, ardışık Monte Carlo (Sequential Monte Carlo- SMC) süzgeçlerin kestirim ve güncelleme aşamalarında kullanılmaktadır [13]. Literatürde süzgecin temel yapısı bozulmadan SMC temelli farklı yaklaşımlar bulunmaktadır. Ön yükleyici süzgeçleme [14], yoğunlaştırma algoritması [15] ve parçacık süzgeci [16] bilinen SMC yaklaşımlarıdır.

Parçacık süzgeci (PS), doğrusal olmayan dinamik sistemlerde kullanılan bir durum kestirim yaklaşımıdır. PS'de gürültüler, Gauss formunda olmak zorunda değildir. PS, sınırlı sayıda parçacık (örnek) ve bu parçacıklara ait ağırlıkları kullanarak sonsal PDF'e yinelemeli bir yaklaşımla, yakınsamaya çalışmaktadır. PS, parçacık sayısının

sonsuz gitmesi durumunda en uygun Bayes kestirimine karşılık gelmektedir. Sonsal PDF,  $p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})$  dağılımından oluşturulan  $\mathbf{x}_{0:k}^i$  örneklerini ve bu örneklere karşılık gelen  $w_k^i$  ağırlıklılıklarını kullanarak Eşitlik (1.26)'ya benzer şekilde Eşitlik (1.27)'deki gibi tanımlanabilmektedir.

$$p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0:k} - \mathbf{x}_{0:k}^i) \quad (1.27)$$

Aslında  $w_k^i$ ,  $k$  anında tanımlı IS ağırlık parametresidir. Bu bağlamda  $w_k^i$ , Eşitlik

$$(1.25)'ten yola çıkarak  $w_k^i = \frac{p(\mathbf{x}_{0:k}^i | \mathbf{z}_{1:k})}{q(\mathbf{x}_{0:k}^i | \mathbf{z}_{1:k})}$  formunda yazılabilmektedir.  $q(\mathbf{x}_{0:k}^i | \mathbf{z}_{1:k})$$$

önem yoğunluk dağılımını belirtmektedir.  $w_k^i$  ağırlığını,  $w_{k-1}^i$  ile Bayes kestirim teoremi sayesinde özyinelemeli olarak ifade etmek mümkündür. Buna göre,  $w_k^i$  ile  $w_{k-1}^i$  arasındaki ilişki Eşitlik (1.28)'de verilmektedir.

$$w_k^i = w_{k-1}^i \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k})} \quad (1.28)$$

$q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k})$  önem yoğunluk dağılımına karşılık gelmektedir.  $w_k^i$  ağırlıkları Eşitlik (1.28) ile hesaplandıktan sonra toplamları 1 olacak şekilde güncellenmektedir. Önem yoğunluk dağılımı,  $k$  anındaki durumun sadece en son duruma ve en son gözleme bağlı olması koşuluyla,  $q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k}) = q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)$  eşitliği ile yazılabilmektedir. Bu durumda elde edilen özyinelemeli ilişki Eşitlik (1.29)'da gösterilmektedir.

$$w_k^i = w_{k-1}^i \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)} \quad (1.29)$$

Sonsal durum kestirimi, Eşitlik (1.29) ile elde edilen  $w_k^i$  ağırlıklarını ve  $\mathbf{x}_k^i \sim q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)$  örneklerini kullanarak Eşitlik (1.30)'da gösterildiği gibi hesaplanmaktadır.

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (1.30)$$

SIS temelli PS'de, birkaç iterasyon sonrasında bir parçacık dışında tüm parçacıklar ihmal edilebilir ağırlıkta olmaktadır [16]. Bu durum PS'de yozlaşma olayı olarak adlandırılmaktadır. Eşitlik (1.31)'de, yozlaşma olayının tespiti için kullanılan tahmini efektif örnek sayısı ( $\widehat{Neff}$ ) tanımlanmaktadır [17].

$$\widehat{Neff} = 1 / \sum_{i=1}^N (w_k^i)^2 \quad (1.31)$$

$w_k^i$  normalize edilmiş ağırlıkları göstermektedir. Düşük  $Neff$  değerleri çok sayıda yozlaşma belirtisi olduğunu göstermektedir. Yozlaşma olayını kaldırmak için tercih edilen yöntemlerden biri yeniden örnekleme (YÖ) yaklaşımlarıdır.

YÖ algoritmaları, PS'nin önemli bir bölümünü oluşturmaktadır. En uygun YÖ'nün seçimi, PS'nin hesapsal karmaşıklığını azaltmakla birlikte, PS'nin verimliliğini arttırmaktadır. YÖ algoritmalarında düşük öneme sahip parçacıklar yok edilirken, yüksek öneme sahip parçacıklar çoğaltılmaktadır. YÖ işlemi sonrasında elde edilen ağırlıklar,  $w_k^i = 1/N$  eşitliğiyle güncellenmektedir. Eşitlik 1.26'da verilen  $p(x)$  dağılımı, YÖ işlemi sonrasında Eşitlik 1.32'de verilen forma dönüşmektedir.

$$\hat{p}(x) \approx \sum_{i=1}^N \frac{1}{N} \delta(x - \hat{x}^i) = \sum_{i=1}^N \frac{c_i}{N} \delta(x - x^i) \quad (1.32)$$

$c_i$ , YÖ işlemi sonrası elde edilen yeni parçacıklarda,  $i$ . parçacıktan kaç tane olduğunu göstermektedir. En sık kullanılan YÖ yaklaşımları, çokterimli YÖ (Multinomial resampling- MR), katmanlı YÖ (Stratified resampling- STR), sistematik YÖ (Systematic resampling- SR) ve artık YÖ'dür (Residual resampling- RR). YÖ yaklaşımlarında parçacıklar, genellikle Eşitlik 1.33'te gösterildiği gibi ters birikimsel dağılım fonksiyonu (Inverse cumulative distribution function- ICDF) kullanılarak elde edilmektedir.

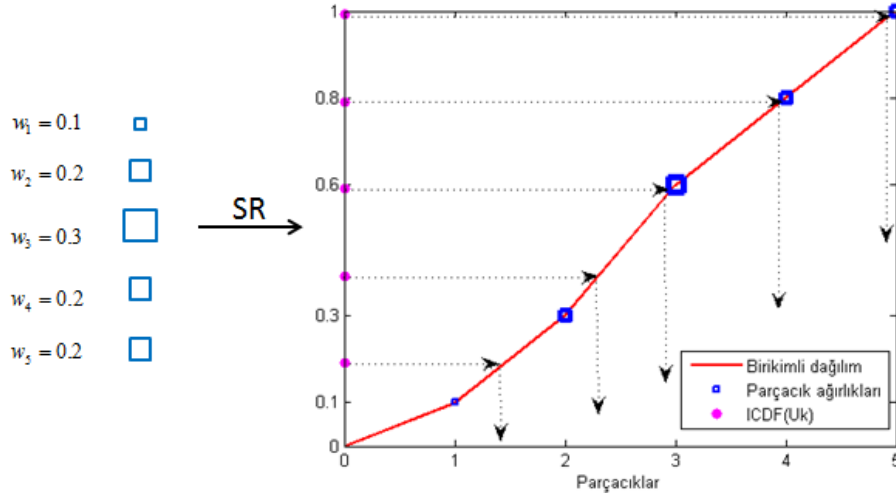
$$\hat{x}^i = x(\text{ICDF}(u_k)) \quad (1.33)$$

$u_k$ , YÖ yaklaşımlarına göre  $[0,1)$  aralığında üretilen değerlerdir. YÖ yaklaşımları arasında SR, en düşük hesapsal yüke sahiptir. Eşitlik 1.34'te, SR ile örneklerin üretilmesi ve bu örneklere göre yeni parçacıkların elde edilmesi gösterilmektedir.

$$u_k = \frac{(k-1) + u_r}{N} \quad (1.34)$$

$$\hat{x}^i = x(\text{ICDF}(u_k))$$

$u_r \sim U[0,1)$  düzgün dağılımlı rasgele bir sayıdır.  $u_k$ ,  $[0,1)$  arasında  $N$  düzgün aralığa bölünüp  $u_r/N$  değeri eklenerek hesaplanmaktadır. SR yaklaşımının şematik olarak gösterimi Şekil 1.4'te verilmiştir.



Şekil 1.4. SR yaklaşımı ile parçacıkların güncellenmesi

SMC yaklaşımlarından bir diğeri de örnekleme önem yeniden örnekleme (Sampling Importance resampling- SIR) yaklaşımıdır. SIR yaklaşımında, önem yoğunluk dağılımında  $q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_k)$  yerine, durum geçiş dağılımı  $p(\mathbf{x}_k | \mathbf{x}_{k-1}^i)$  kullanılmaktadır. Bu durumda, parçacıklar ve bunlara bağlı ağırlıklar Eşitlik (1.35)'te verilmektedir.

$$\mathbf{x}_k^i \sim p(\mathbf{x}_k | \mathbf{x}_{k-1}^i)$$

$$w_k^i = w_{k-1}^i p(\mathbf{z}_k | \mathbf{x}_k^i) \quad (1.35)$$

SIR yaklaşımında her iterasyonda yeniden örnekleme işlemi yapılmaktadır. Her YÖ işleminden sonra tüm ağırlıklar  $w_{k-1}^i = 1/N$  eşitliğindeki gibi aynı değerlere sahiptir. Dolayısıyla, parçacıklara ait ağırlıklar  $w_k^i = p(\mathbf{z}_k | \mathbf{x}_k^i)$  sadece k anındaki gözlem olabilirliğine bağlı olmaktadır.

SIR yaklaşımında, her iterasyon sonrası YÖ işleminin yapılması bir başka problemi ortaya çıkartmaktadır. Örnek fakirleşmesi olarak bilinen bu problemde, parçacıklar süreç gürültüsünün çok küçük olması durumunda, bir süre sonra tek bir merkezde toplanacaktır. Literatürde bu problemin önüne geçebilmek için kullanılan yaklaşımlardan biri de, Düzenlenmiş Parçacık Süzgeci'dir (DPS) [18].

DPS, Eşitlik (1.30)'da verilen ayrık zamanlı sonsal durum kestirimi yerine sürekli zamanda sonsal durum kestirim yaklaşımını kullanmaktadır. DPS'de kullanılan sonsal durum kestirimi Eşitlik (1.36)'da gösterilmektedir.

$$\hat{p}(\mathbf{x}_k | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N w_k^i K(\mathbf{x}_k - \mathbf{x}_k^i) \quad (1.36)$$

$K(\mathbf{x}_k - \mathbf{x}_k^i)$  çekirdek fonksiyona karşılık gelip Eşitlik (1.37)'deki gibi tanımlanmaktadır.


$$K(\mathbf{x}_k - \mathbf{x}_k^i) = \frac{1}{h^d} K\left(\frac{\mathbf{x}_k - \mathbf{x}_k^i}{h}\right) \quad (1.37)$$

Burada  $d$ , durum vektörün boyutunu,  $h > 0$  çekirdeğin bant genişliğini göstermektedir Çekirdek fonksiyonu, ortalama tümlev karesel hatayı (OTKH) minimum yapacak şekilde seçilmektedir. OTKH hesabı, Eşitlik (1.38)'de verilmektedir.

$$\text{OTKH}(\hat{p}) = E\left[\int (\hat{p}(\mathbf{x}_k | \mathbf{z}_{1:k}) - p(\mathbf{x}_k | \mathbf{z}_{1:k}))^2 dx_k\right] \quad (1.38)$$

DPS'nin PS'ye göre görsel hedef takip başarımı "seq\_sb" görüntü dizisinde karşılaştırılmıştır. Toplam 500 görüntü çerçevesi içeren ve  $128 \times 96$  piksel çözünürlüğünde olan bu görüntü dizisi, hareketli kamera kayıtları ve karmaşık arka plan sahneleri içermektedir. Görünüm modeli olarak renk histogramlarının

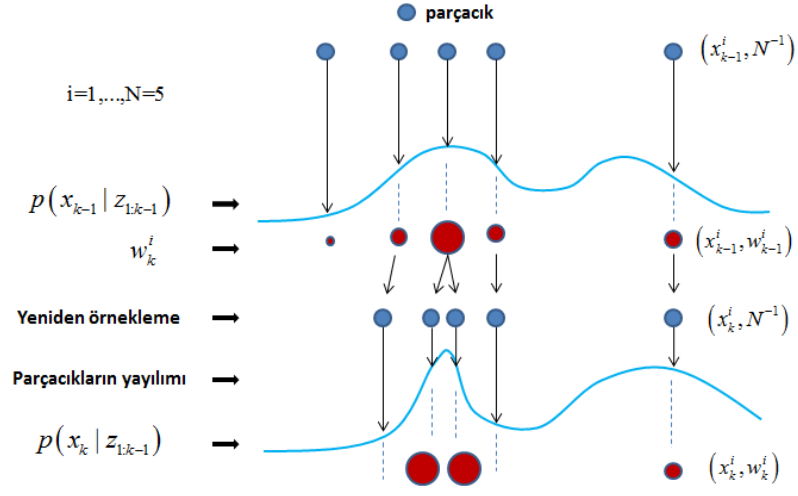
kullanıldığı bu görüntü dizisinin 37. ve 43. çerçeveleri için DPS ve PS ile elde edilen görsel hedef takip başarımları Şekil 1.5'te gösterilmektedir. Şekil 1.5'te görüldüğü gibi DPS ile hedef takibi PS'ye göre daha başarılı bir performans sergilemektedir. PS'de parçacık sayısı, 37. çerçevede örnek fakirleşmesinden dolayı azalmakta, buna bağlı olarak 43. çerçevede hedefin olduğu bölgede parçacık bulunmamaktadır. Hedefin olduğu bölgede parçacıkların olmamasından dolayı hedef kaybedilmektedir. DPS'de ise, örnek fakirleşmesinin önüne geçilmesinden dolayı hedef takibi başarılı bir şekilde devam etmektedir.



Şekil 1.5. (a) DPS (37. çerçeve), (b) PS (37. çerçeve), (c) DPS (43. çerçeve), (d) PS (43. çerçeve)

Sonsal PDF'nin ardışık bir şekilde kestirimine dayanan PS'nin genel yapısı Şekil 1.6'da gösterilmektedir. Şekil 1.6'da,  $N = 5$  adet eşit ağırlıklı parçacığın,  $p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1})$  dağılımına göre olabilirliği hesaplanmakta, buna bağlı olarak  $(k-1)$  anında ağırlıkları belirlenmektedir. Sonrasında, ağırlığı düşük olan ilk parçacık ihmal edilmekte, diğer parçacıklar ağırlıklarına göre yeniden örneklenmektedir. Bir sonraki süreçte, süreç fonksiyonu ve gürültüler parçacıklara etki etmektedir. Bu durumda oluşan parçacıkların yayılımı,  $p(\mathbf{x}_k | \mathbf{z}_{1:k-1})$  dağılımına göre yeniden olabilirlik hesabına girmektedir. Diğer bir ifadeyle  $k$  anında ağırlıkları hesaplanmaktadır. Şekil 1.6'da resmedilen PS, sonraki  $k$  anları için özyineli bir şekilde devam etmektedir.

Tez kapsamında gerçekleştirilen PS temelli hedef takibinde, DPS yaklaşımı kullanılmıştır.



Şekil 1.6. Parçacık süzgecin genel yapısı



## **2. HEDEF TESPİTİ VE HEDEF TAKİBİ**

Bu bölümde hedef tespit ve hedef takip yaklaşımları anlatılmıştır. Bununla birlikte, tez kapsamında önerilen hedef takip temelli özgün yaklaşımlarda kullanılan görsel veri setlerine ve performans ölçütlerine yer verilmiştir.

### **2.1. Hedef Tespiti**

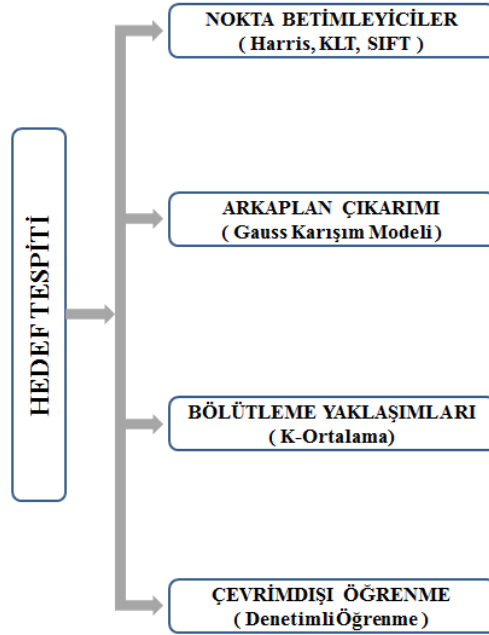
Bilgisayar görü ve imge işlemenin temel konularından biri olan hedef tespiti, hedef takip uygulamalarının en temel parçası olarak bilinmektedir. Günümüzde, kameralar vasıtasıyla alınan görüntülerde bulunan yaya, yüz, araç ve plaka gibi nesnelerin, gerçek zamanlı ve doğru bir şekilde tespiti hedef takip performansını doğrudan etkilemektedir. Hemen hemen tüm hedef takip yaklaşımlarında, nesnelere ya ilk çerçevede ya da her bir çerçevede tespit edilmektedir. Hedef takibi çalışmalarında, hedef tespiti ilk çerçevede genellikle kullanıcı tarafından yapılmaktadır.

Literatürde hedef tespit konusunda yapılan çalışmaları, kendi aralarında farklı kategorilere ayırmak mümkündür. Hedef tespit yaklaşımları için örnek bir kategori Şekil 2.1’de gösterilmiştir.

Bir hedef tespit yaklaşımı olan nokta betimleyiciler (tanımlayıcılar), imgelerde önemli noktaları tespit etmektedir. Önemli noktalar, hedefe ait karakteristik özellikleri temsil edebilmelidir. Literatürde var olan önemli nokta tanımlayıcıları, Harris algılayıcı [19], KLT algılayıcı [20] ve SIFT algılayıcı [21]. Şekil 2.2’de “Jogging” videosunun örnek bir çerçeve imgesi için Harris nokta tanımlayıcı ile bulunan noktalar gösterilmektedir.

Hareketli nesnelere, arka plan çıkarımı yaklaşımlarıyla da tespit edilebilmektedir [22]. Kısmen sabit arka planlı videolarda, referans arka plan imgesi ile o anki imge arasındaki fark, basit bir arka plan çıkarımı yaklaşımıdır. Bununla birlikte, ardışık çerçeveler arasındaki piksel farklılıklarından yararlanılarak hareketli bölgeleri

çıkartmak da mümkündür [23]. Nitekim bu yaklaşımlar, ışıklılık değişimlerinin olduğu ortamlarda daha kararlı bir performans sergilemektedir.



Şekil 2.1. Hedef tespit yaklaşımları

Gauss karışım modeli [24, 25] gibi arka plan modellemeleri daha gelişmiş arka plan çıkarım yaklaşımları olup hareketli arka plan çıkarımlarında kullanılmaktadır. İmgedeki her bir pikselin veya piksel kümelerinin istatistiksel özelliklerini kullanarak arka plan çıkarımı yapmak mümkündür. [26]'da arka plan modeli için, piksellerin ortalama, standart sapma ve parlaklık değişimi gibi istatistiksel özellikleri kullanılmaktadır.



Şekil 2.2. Harris nokta tanımlayıcısı ile bulunan noktalar

Diğer bir hedef tespit yaklaşımı ise, bölütleme (kümeleme) temelli yaklaşımlardır. Bölütleme yaklaşımlarında imge, benzer özellik gösteren bölgelere (öbeklere) ayrılmakta ve bu bölgeler ayrı ayrı etiketlenmektedir. Ortalama Kayma ve K-Ortalama yaygın olarak kullanılan bölütleme yaklaşımlarıdır. K-ortalama yaklaşımında imge, K adet kümeye ayrılmaktadır. Bu yaklaşımda öncelikle, imge içinde K adet merkez nokta belirlenmekte, imgede her bir pikselin seçilen merkez noktaya göre uzaklığı hesaplanmaktadır. Uzaklık hesabına göre, pikseller en yakın oldukları sınıflara atanmaktadır. K adet kümede bulunan piksellerin ortalaması alınarak, yeni merkez noktalar belirlenmektedir. İmgede her piksel için güncellenen merkez noktalara göre uzaklığı yeniden hesaplanmaktadır. Uzaklık hesabına göre pikseller, yeniden kümelere ayrılmakta, her bir kümede bulunan piksellerin ortalaması yeniden hesaplanmaktadır. Bu özyinelemeli işlemler, K adet merkez nokta değeri değişmeye kadar devam etmektedir.

Çevrim dışı öğrenme yaklaşımlarından olan denetimli öğrenme ile hedefe ait farklı görünüşler birarada değerlendirilerek hedef tespiti hakkında çıkarım yapılabilmektedir. Genellikle eğitim aşaması olarak bilinen bu öğrenme yöntemlerinde, hedeflerin iyi bir şekilde karakterize edilmesi, hedef tespitinin performansını arttırmaktadır.

Tespit edilen hedeflerin veritabanında bulunan sınıflara göre etiketlenmesi, hedeflerin sınıflandırılması işlemidir [27,28]. Örneğin yayaları takip etmek, aktivitelerini gözlemlemek için, yayaların diğer nesnelere ayırt edilmesi gerekmektedir. Nesnelere şekil temelli veya hareket temelli olarak sınıflandırmak da mümkündür. Şekil temelli yöntem, nesnelere çevriti, alanı gibi iki boyutlu bilgilerden yararlanırken, hareket temelli yöntemler, nesnelere zamansal olarak değişen özelliklerinden faydalanmaktadır.

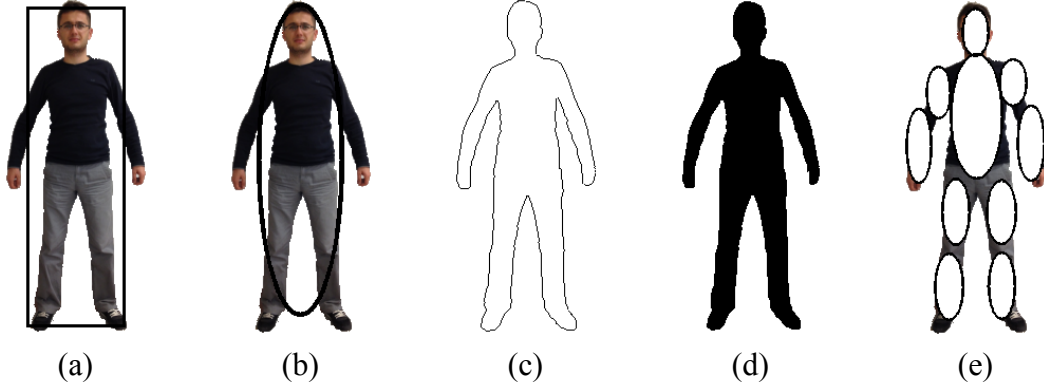
## **2.2. Hedef Takibi**

Bilgisayar görü alanında yaygın olarak kullanılan hedef takibinin önemi, gelişen teknolojiye paralel olarak artmaktadır. Hedef takibine, görsel gözetleme sistemlerinde, video indekslemede, bilgisayar-insan etkileşiminde, araç takibi gibi konularda ihtiyaç duyulmaktadır. Hedef takibinin amacı, nesnelere pozisyon, hız ve yön gibi zamansal bilgilerini çıkartmak için ardışık video çerçevelerini kullanarak

nesneler arasında benzerlik ilişkisi kurmaktır. Bu sayede, nesnelerin pozisyon bilgileri, videonun her bir çerçevesinde zamana göre bir yörünge oluşturmaktadır. Hedef takibi, her bir çerçevede hedef tespiti yapıлып hedefler arasında ilişki kurularak da gerçekleştirilebilmektedir.

Nesneler, zamana göre ani hareket gösterebilmektedir. Nesne, zamana göre düzgün bir hareket değişimi gösterse bile farklı yönlere gidebilmektedir. Bununla birlikte, hedef nesne görünümü zamanla değişime uğramaktadır. Bu değişim, hedefin şeklinde olabileceği gibi, boyutsal bir değişim de söz konusu olabilmektedir. Hedef görünüm modelinin güncellenmemesi durumunda, hedef başarılı bir şekilde takip edilemeyecektir. Diğer yandan, hedef takibinde ışıklılık değişimi, gürültü faktörü, kamera hareketi, kameranın görüş açısı, hedef nesnenin bir başka nesne ile yarı/tam örtüşme durumu, karmaşık arka plan gibi etkenler, hedef takibini zorlaştırmaktadır.

Nesnelerin farklı şekillere ve farklı karakteristik özelliklere sahip olması hedef takibinde kolaylık sağlamaktadır. Takipte sıklıkla kullanılan şekil gösterimlerinden bazıları Şekil 2.3'te verilmektedir.

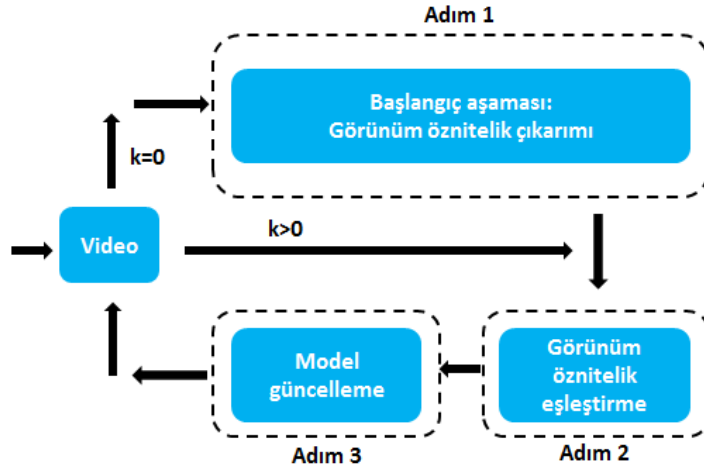


Şekil 2.3. (a) Dikdörtgensel gösterim, (b) eliptik gösterim, (c) çevrit gösterim, (d) silüet gösterim, (e) eklemliler gösterim

Şekil 2.3'te gösterilen hedef nesne, dikdörtgen veya elips ile temsil edilebilmektedir. Bu gösterim, özellikle esnek olmayan nesneler için daha uygundur. Nesnenin sınırlarını belirten çevrit ile nesnenin iç bölgesini gösteren silüet [29], şekil gösterimlerinden olup karmaşık nesnelerin gösterilmesinde daha uygun bir tercihtir. Eklemliler gösterim, daha çok esnek nesneler için tercih edilmektedir.

Başarımı yüksek, verimli bir hedef takibinden söz edebilmek için bazı gereksinimlere ihtiyaç duyulmaktadır. Bu gereksinimlerden biri gürbüzlüktür. Gürbüz bir hedef takip sistemi, takip performansını düşürecek bozucu etkenlere karşı dayanıklı olmalıdır. Bir diğer gereksinim ise uyarlanabilirliktir. Hedef takibinde kullanılan hedef görünüm modeli, zamana göre değişime uğrayan hedef görünümüne paralel bir uyum sağlamalıdır. Gürbüz, uyarlanabilir bir hedef takip sistemi, düşük hesapsal yüke sahip olmalıdır. Diğer bir ifadeyle, takip sisteminin gerçek zamana yakın bir performans sergilemesi gerekmektedir.

Genel bir hedef takip sisteminin yapısı, Şekil 2.4'te gösterildiği gibi 3 aşamada incelenebilmektedir. İlk aşamada takip edilecek nesneye ait görünüm özellik çıkarımı yapılmaktadır. Takip edilecek nesnelere, arka plan çıkarım yaklaşımları gibi yöntemlerle otomatik olarak belirleneceği gibi, el yardımıyla da seçilebilmektedir. Daha sonra hedef nesneye ait görünüm modeli oluşturulmaktadır. İkinci aşamada ise, hedef nesneye ait görünüm modeli, aday hedef görünüm bölgeleri ile eşleştirilerek en uygun aday hedef görünümü tespit edilmektedir. Son aşamada ise, hedef nesnenin görünüm modeli, zamana bağlı olarak kestirilen en uygun aday hedefin görünümüne bağlı olarak güncellenmektedir.



Şekil 2.4. Hedef takip sistemin genel yapısı.

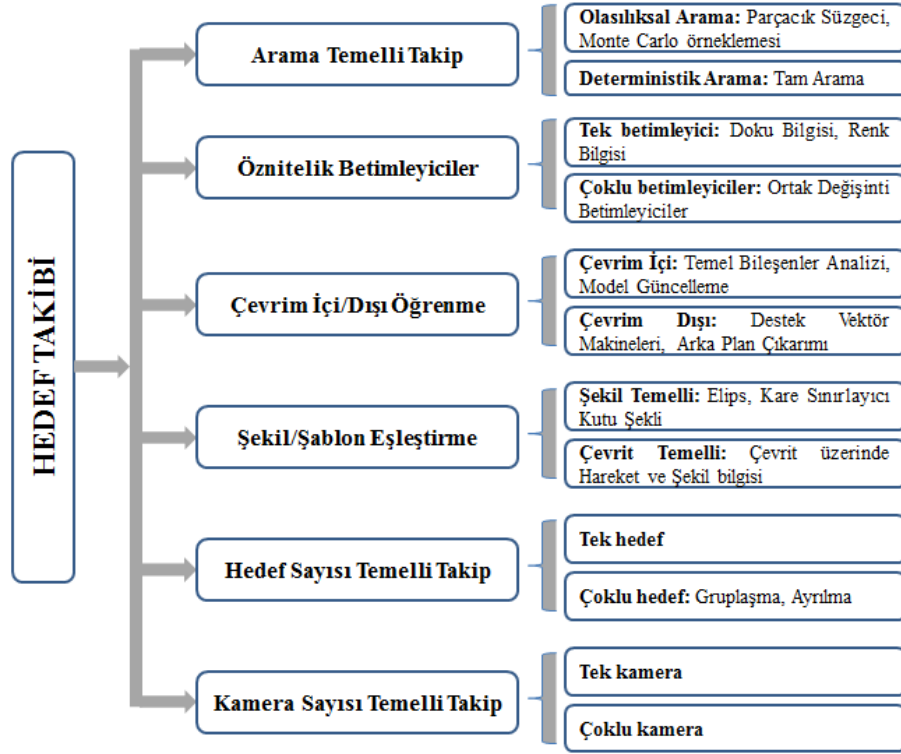
Hedeflere ait karakteristik özelliklerin belirlenmesi, görsel hedef takibin başarımına doğrudan etki etmektedir. Takip edilecek hedefe ait öznelik çıkartımı, o nesneye ait özellik betimleyicisi olmaktadır. Hedefin gradyan bilgilerini kullanarak hedefe ait öznelik çıkartımı yapmak mümkündür. [30]'da gradyanların yönlü histogramı kullanılarak hedef tespiti gerçekleştirilmiştir. Gradyan bilgisi kullanılarak

gerçekleştirilen başarılı bir hedef tespiti, beraberinde başarılı bir hedef takibine olanak sağlamaktadır. [31]'de yayalar için gradyen temelli çevrit çıkarımı önerilmektedir. Renk bilgisi, nesne için bir başka özellik betimleyicisidir. Hedefe ait RGB veya HSV renk bilgileri, nesnenin genel bir karakteristiğini ortaya koymada yardımcı olmaktadır. Örneğin, renk histogramlarıyla nesnelerin gerçek zamanlı takibi yapılabilmektedir [32]. [33]'te, hem renk özüne bağlı histogram bilgisi hem de SIFT betimleyicisi birarada kaynaştırılarak etkin bir renk betimleyicisi oluşturulmuştur. Doku bilgisi, takip edilecek hedefi, diğer hedeflerden ayırt edecek bilgiler içermektedir. Örneğin [34]'te, çoklu ortam veri tabanlarından içerik odaklı bilgi çıkartımında, doku özellikleri için Gabor dalgacık özellikleri kullanılmıştır. Doku özelliklerini etkin kullanan bir başka yaklaşım ise yerel ikili örüntülerdir [35].

Literatürde hedef takibi, farklı kategoriler altında değerlendirilmekle birlikte, hedef takip yaklaşımlarının genel bir şeması Şekil 2.5'te gösterilmiştir. Hedefin hangi yöntemle aranacağı, hedefin hangi karakteristik özelliklerinin betimleneceği, takip edilen hedef sayısı, hedef nesnelere gözlemleyen kamera sayısı, takipte çevrim içi/dışı öğrenme teknikleri, hedef takip yaklaşımlarının başlıca çalışma konularını oluşturmaktadır.

Literatürde hedef tespiti ve takibi ile ilgili farklı kriterlerde birçok çalışma yapılmıştır. Tek bir kamera veya çoklu kamera ile kameraların aktif ya da pasif olmasına göre farklı hedef takip çalışmaları bulunmaktadır. Aktif kameralar, sağa sola, yukarı aşağı ve yaklaşma özelliğine sahiptir. Aktif kameralar ile hedef takibinde [36,37], hedef takip başarımının artırılması amaçlanmıştır. Diğer yandan, aktif kameralar yerine pasif kameraların tercih edildiği hedef takip sistemleri [38,39] daha yaygın bir kullanım alanına sahiptir.

Çoklu kameralar ile hedef tespiti ve takibinde, kameraların ortak görüş alanları (overlapping field of view) veya farklı görüş alanları (non-overlapping field of view) olması hedef takip başarımını etkilemektedir. [40]'da ortak görüş alanı olmayan çoklu kameralar ile hedef takibi önerilmiştir. Önerilen yöntemin temel amacı, hedef nesnenin belirli bir süre her iki kamera tarafından da görülmediği durumlarda hedef takip işlemini gerçekleştirmektir. [41]'de ortak ve farklı görüş alanları için çoklu kameralar ile KS ve PS kullanılarak çoklu hedef takibi önerilmiştir.



Şekil 2.5. Hedef takip yaklaşımları

Hedef takip performansını etkileyen diğer önemli bir unsur örtüşmedir. Örneğin, takip edilen yaya, bir başka yaya tarafından gizlenmişse veya sabit bir nesnenin arkasından geçiyorsa, hedef takibi zorlaşmakta hatta örtüşme süresine bağlı olarak hedef kaybedilebilmektedir. Örtüşme durumlarını hafifletmek için kullanılan yöntemlerden birisi, kameraların hedef nesnelere yukarıdan görece şekilde konumlandırılmasıdır [42]. Diğer bir yaklaşım, Eş-grafik (Homografi) yöntemiyle çoklu kameralardan alınan görüntüler üzerinde ilişki kurarak, bir görüntü üzerinde yer alan herhangi bir noktanın, diğer görüntü üzerinde hangi noktaya karşılık geleceğini hesaplamaktır [43,44].

KS, GKS, KKS, PS gibi doğrusal ve doğrusal olmayan durum kestirim yaklaşımları, hedef takibinde sıklıkla kullanılmaktadır. Bu yaklaşımlarda, takip edilecek nesnenin veya nesnelerin konum bilgileri ve şekil boyutları kullanılarak başlangıç durum vektörü oluşturulup, durum vektörü güncellenerek hedef takibi yapılmaktadır. [45]'te KS ve GKS'nin kablosuz algılayıcı ağlarındaki hedef takip performansları değerlendirilmiştir. [46]'da KKS, ortak görüş alanına sahip kameralar ile gerçekleştirilen hedef takibinde kullanılmıştır. Hedef takibinde, hedefin olası yeri

hakkında birden fazla tahmin yapma yeteneğine sahip PS, literatürde yaygın bir şekilde tercih edilmektedir [47-50].

Hedef tespit ve takibinde, tek bir kamera veya çoklu kamera kullanımının yanı sıra tüm-yönlü (omni directional) kameralar da kullanılmaktadır [51,52]. Tüm yönlü kameralar kullanarak daha verimli bir hedef takip uygulaması gerçekleştirmek mümkündür.

[53,54]'te hedef tespiti ve takibi ile ilgili genel kavramlar verilmiş, literatürde konuyla ilgili yapılan çalışmalar gözden geçirilmiştir.

### **2.3. Tez Kapsamında Kullanılan Veri Setleri**

Tez kapsamında önerilen özgün yaklaşımların nesnel ve görsel başarımlarını değerlendirmek için, görsel veri setleri kullanılmıştır. Kullanılan veri setleri, CAVIAR [55] veritabanından alınan veri kümelerinden ve literatürde görsel takip ile ilgili yapılan çalışmalarda kullanılan veri setlerinden oluşmaktadır.

Takip edilecek hedefin zamana göre gerçek konumsal ve boyutsal özelliklerinin tutulduğu kesin referans (ground truth) bilgileri, CAVIAR veri setleri için, .xml uzantılı dosyaların bulunduğu CAVIAR veritabanından alınmıştır. Tez kapsamında, benzetim çalışmalarında kullanılan diğer veri setlerine ait kesin referans bilgileri de el yardımıyla oluşturulmuştur. Bu veri setleri sıkıştırılmış jpeg formatında olup sıkıştırma etkisinden kaynaklanan veri kayıpları, görüntüler üzerinde bir miktar gürültü oluşturmaktadır. Görüntülerin gürültü içermesi, hedef takip çalışmalarında karşılaşılan olağan bir problemdir.

Tez kapsamında kullanılan görsel veri setlerine ait özellikler aşağıda açıklanmaktadır. Takip edilen hedefler kırmızı renk ile belirtilmiştir.

OneLeaveShopReenter1front: CAVIAR veri tabanından alınan bu veri seti, iç mekanda sabit bir kamera ile  $384 \times 288$  piksel çözünürlüğünde kayıt yapılmış görüntü dizisi içermektedir. Benzetim çalışmalarında kullanılan toplam çerçeve sayısı 239'dur. Bu görüntü dizisinin ilk zamanlarında tek bir hedef varken, daha sonra hedef sayısı ikiye çıkmaktadır. Görüntü dizisinin hiçbir çerçevesinde ışıklılık değişimi yoktur. Takip edilen hedef Şekil 2.6'da gösterilmiştir.





Şekil 2.6. OneLeaveShop Reenter1front görüntü dizisinde hedef nesne


Bu görüntü dizisinde hedef nesne, zamanla düzgün, boyutsal bir değişim göstermektedir. Nesne belirli bir ana kadar kameraya yaklaştığından nesnenin boyutunda artış gözlemlenmektedir. Daha sonra ise hedef nesne kameradan uzaklaştığından boyutunda azalma gözlemlenmektedir. Bunlarla beraber, nesnenin görünümü zamanla değişmektedir. Hedef, zamana göre düzgün bir harekete sahiptir.

EnterExitCrossingPaths1cor: CAVIAR veri tabanına ait, sabit arka plan içeren bu görüntü dizisinde, değişken sayıda nesne bulunmaktadır.  $384 \times 288$  piksel çözünürlüğüne sahip, ışıklılık değişiminin olmadığı bu görüntü dizisinde, hedef nesne Şekil 2.7’de gösterilmiştir. Görüntü dizisinden toplam 195 çerçeve değerlendirmeye alınmıştır. Hedef nesne, zamana göre düzgün bir harekete sahiptir. Bununla birlikte, hedef nesnenin görünümünde hemen hemen bir değişiklik olmamaktadır. Nesnenin boyutunda ise zamanla düzgün bir artış söz konusudur. Kırmızı renk ile sınırlanmış nesnenin üst bölgesi ile arka planın zemini, birbirine yakın renk tonları içermektedir.



Şekil 2.7. EnterExitCrossing Paths1cor görüntü dizisinde hedef nesne

Jogging: Toplam 306 çerçeveden oluşan ve  $352 \times 288$  piksel çözünürlüğünde olan bu görüntü dizisinde kayıtlar, hareketli kamera ile oluşturulmuştur. Dolayısıyla arka plan zamanla değişmektedir. Takip edilen nesnelerin boyutları yavaş yavaş artmaktadır. Bu nesnelerin görünüşleri ise hemen hemen korunmaktadır. Bu görüntü dizisi, belirli bir zaman aralığında tam örtüşme içermektedir. Takip edilen hedefler, Şekil 2.8’de gösterilmiştir.



Şekil 2.8. (a) Hedef nesne (Jogging1), (b) hedef nesne (Jogging2)

Şekil 2.8 (a) ve Şekil 2.8 (b)’de Jogging dizisinden işaretlenmiş nesnelerin nesne takip başarımları birbirinden bağımsız değerlendirilmiştir.

Race: Tez kapsamında kullanılan bu görüntü dizisi toplam 319 çerçeveden oluşmakta ve  $320 \times 240$  piksel çözünürlüğüne sahiptir. Arka planı sabit olmayan bu dizide, birden fazla nesne bulunmaktadır. Hedef nesne, kısmen ani bir hareket değişimi göstermektedir. Bunun yanında, hedefin boyutu zamanla büyümekte ve küçülmektedir. Işıklılık değişiminin olmadığı bu dizide, hedefin görünümü zaman zaman değiştirmektedir. Bu dizide takip edilen hedef Şekil 2.9’da gösterilmiştir.



Şekil 2.9. Race görüntü dizisinde hedef nesne.

Subway: 180 çerçeveden oluşan bu görüntü dizisi,  $352 \times 288$  piksel çözünürlüğünde olup görüntüler, sabit bir kamera ile çekilmiştir. Çok sayıda nesnenin bulunduğu bu görüntü dizisinde, hedef nesne zaman zaman kısmi örtüşmelere maruz kalmaktadır. Şekil 2.10'da gösterilen hedef nesnenin boyutu ve görünümü ise örtüşme durumları hariç takip süresince değişmemektedir.



Şekil 2.10. Subway görüntü dizisinde hedef nesne

Crowd: Sabit kameradan alınan bu görüntü dizisi  $440 \times 360$  piksel çözünürlüğünde olup çok sayıda nesne içermektedir. Hedef nesnenin takip başarımı, 250 çerçeve için değerlendirilmiştir. Hedefin boyutu ve görünümü hemen hemen aynı kalmaktadır. Takip süresince ışıklılık değişimi yoktur. Şekil 2.11'de Crowd dizisinden örnek bir kare gösterilmiştir.




Şekil 2.11. Crowd görüntü dizisinde hedef nesne

Couple: Toplam 139 çerçeve içeren bu görüntü dizisi,  $320 \times 240$  piksel çözünürlüğündedir. Bu görüntü dizisinde hedef nesne, bir insan grubunu oluşturmaktadır. Hedef nesnenin görünümü ve boyutu, takip süresince değişime uğramaktadır. El kamerasından çekilen bu görüntülerde, arka plan zamanla değişmekte, bununla birlikte hedef nesne ani bir değişim göstermektedir. Hedef nesne Şekil 2.12'de gösterilmiştir.



Şekil 2.12. Couple görüntü dizisinde takip edilen nesne

Woman:  $352 \times 288$  piksel çözünürlüğünde, hareketli kamera ile çekilmiş bu görüntü dizisinde arka plan zamanla değişmektedir. Hedef takibi, toplam 542 çerçeve için gerçekleştirilmiştir. Nesnenin görünümünde ve boyutunda sık sık değişimler görülmektedir. Bununla birlikte, takip işleminin başlangıç anlarında ışıklılık değişimi gözlemlenmektedir. Bu görüntü dizisinde hedef nesne, sık sık kısmi örtüşmelere maruz kalmaktadır. Şekil 2.13'te, hedef nesne gösterilmiştir.



Şekil 2.13. Woman görüntü dizisinde takip edilen nesne

## 2.4. Tez Kapsamında Kullanılan Performans Ölçütleri

Bu bölümde, tez kapsamında kullanılan performans ölçütlerinden bahsedilmektedir. Performans ölçütleri, hedef takip başarımını değerlendirmede kullanılmaktadır.

### 2.4.1. Öklid uzaklığı

Öklid uzaklığı, hedef kestirim bölgesinin merkezinin, takip edilen hedef bölgenin (kesin referans) merkezine olan uzaklığını hesaplamak için kullanılmaktadır. Öklid uzaklığı, Eşitlik (2.1)'de gösterilmektedir.

$$d_E(\mathbf{k}_b, \mathbf{k}_r) = \sqrt{((x_{kb} - x_{kr})^2 + (y_{kb} - y_{kr})^2)} \quad (2.1)$$

$\mathbf{k}_b = (x_{kb}, y_{kb})$  ve  $\mathbf{k}_r = (x_{kr}, y_{kr})$  sırasıyla kestirim bölgesinin ve kesin referansın merkez noktalarına karşılık gelmektedir.

Şekil 2.14'te, kesin referans ile kestirim bölgesi arasında hesaplanan Öklid uzaklığı gösterilmektedir. Uzaklığın düşük olması, hedefin göreceli olarak başarılı bir şekilde izlendiği anlamına gelmektedir.

Tez kapsamında önerilen özgün yöntemlerde hedef takip başarımını ölçmek için, Öklid uzaklığı kullanılmıştır.



Şekil 2.14. Öklid uzaklığına göre performans ölçütü

#### 2.4.2. F-ölçütü

Tez kapsamında kullanılan bir diğer performans ölçütü ise F-ölçütüdür. Sınıflandırma modellerinin başarımında da kullanılan F-ölçütü, doğruluk (precision) ve anma (recall) ölçütlerinin harmonik ortalaması olup Eşitlik (2.2) ile ifade edilmektedir.


$$F\_ölçütü = \frac{2 \times \text{Doğruluk} \times \text{Anma}}{\text{Doğruluk} + \text{Anma}} \quad (2.2)$$

Doğruluk ölçütü, doğru sınıflandırılmış (tespit edilmiş) pozitif örnek sayısının pozitif olarak sınıflandırılmış örneklerin sayısına oranıdır. Anma ölçütü ise doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranıdır. Doğruluk, kestirim yapılan hedef bölgesinin ne kadarının kesin referans bölgesini

kapsadığını göstermektedir. Anma ise, kesin referans bölgesinin ne kadarının kestirim yapılan bölge tarafından kapsandığını göstermektedir. Doğruluk ve anma ölçütleri, Eşitlik (2.3)'te gösterilmektedir.

$$\text{Doğruluk} = \frac{TP}{TP + FP} \quad (2.3)$$
$$\text{Anma} = \frac{TP}{TP + FN}$$

F-ölçütü, [0-1] aralığında değişmektedir. Kestirilen hedef bölgesi ile gerçek (kesin referans) hedef bölgesinin çakışması durumunda 1 değerini almaktadır. Şekil 2.15'te örnek bir görüntü dizisinde doğruluk ve anma ölçütlerinin farklı durumları gösterilmiştir.



Şekil 2.15. (a) Doğruluk/Anma: Yüksek/Düşük, (b) Doğruluk/Anma: Düşük/Yüksek, (c) Doğruluk/Anma: Yüksek/Yüksek.

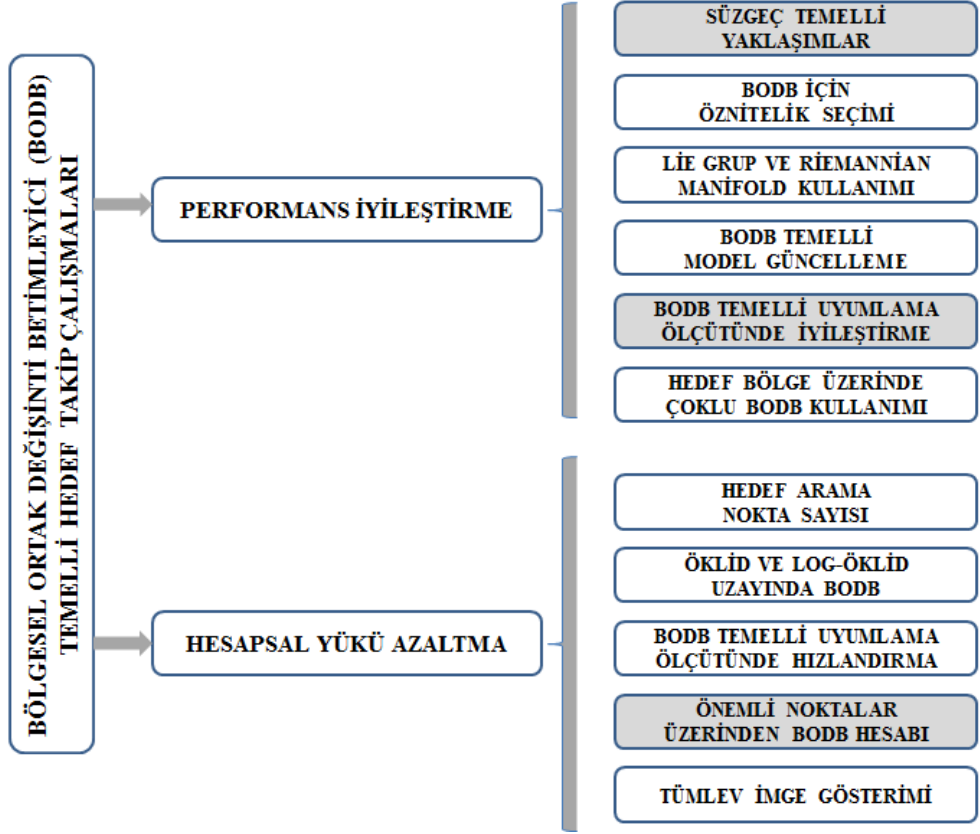
### 3. ORTAK DEĞİŞİNTİ BETİMLEYİCİLER İLE HEDEF TAKİBİ

Görsel hedef tespiti ve takibinde, takip edilecek nesnenin doğru bir şekilde betimlenmesi, hedef takip performansını doğrudan etkilemektedir. İyi bir nesne betimlemesi (hedef gösterimi), nesneye ait karakteristik özellikleri taşımali ve çevresel koşullara karşı dayanıklı olmalıdır.

Renk temelli histogram yaklaşımları, nesnelere sadece tek bir öznitelik vektörüyle temsil etmektedir [56]. Bu yaklaşımlarda kullanılan öznitelik vektörü nesnelere renk bilgilerine karşılık gelmektedir. Bununla birlikte nesnelere, karakteristik özellikleri bakımından birden fazla öznitelik vektörleriyle de temsil edilebilmektedir [57,58]. [57]'de öznitelik vektörü olarak, renk bilgileri ve gradyan-temelli yön bilgileri kullanılmıştır. [58]'de öznitelik vektörleri, görsel takipte karşılaşılan örtüşme, dönme ve ölçekleme problemlerinin üstesinden gelmek için RGB renk bilgilerinden ve yerel ikili örüntülerden oluşmaktadır. Hedef gösteriminde kullanılan öznitelik sayısı, hedef takip performansına olumlu, hesapsal yüke ise olumsuz yönde etkileyebilmektedir.

Yakın bir zamanda, nesnelere karakteristik özelliklerinin daha verimli kullanıldığı bölgesel ortak değişinti betimleyici (BODB) temelli görünüm modeli önerilmiştir [59]. Nesnelere, BODB temelli görünüm modelinde birden fazla öznitelik vektörüyle temsil edilmektedir.

Literatürde kullanılan BODB temelli hedef takip çalışmaları, Şekil 3.1'de özetlenmiştir. Bu çalışmalar genel olarak, performans iyileştirmeye ve hesapsal yükü azaltmaya yönelik olmaktadır. Örneğin, hesapsal yükü azaltmak için BODB'yi hızlı bir şekilde oluşturmak ya da BODB temelli istatistiksel işlemleri hızlı bir şekilde hesaplamak gerekmektedir. Benzer şekilde, Şekil 3.1'de gösterildiği gibi BODB temelli hedef takibinde performansı arttırmaya yönelik farklı yaklaşımlar kullanılmaktadır. Tez kapsamında önerilen özgün yaklaşımlar, hesapsal yükü azaltma ve performans iyileştirmesine yönelik olup Şekil 3.1'de koyu bölgelerle gösterilmiştir.



Şekil 3.1. Ortak değişinti betimleyici temelli hedef takip çalışmalarına genel bir bakış


Bu bölümde, sırasıyla, BODB temelli hedef görünüm modelinin oluşturulması, hedef tespit/takip uygulamalarında BODB temelli benzemezlik ölçütü ve model güncellemesi ve tümlev imge gösterim yöntemleriyle BODB'nin hızlı bir şekilde hesaplanması konuları irdelenmiştir. Son olarak, literatürde gerçekleştirilmiş BODB temelli hedef takip çalışmaları incelenmiştir.

### 3.1. Ortak Değişinti Betimleyiciler

Ortak değişinti, iki raslantı değişkeni arasındaki doğrusal ilişkiyi gösteren istatistiksel bir ölçüt olup bilgisayar görü uygulamalarında yaygın bir şekilde kullanılmaktadır. Raslantı değişkenlerin her ikisinin de aynı yönde bir değişim göstermesi, aralarında pozitif bir ilişki olduğunu ve ortak değişintinin pozitif işaretli olduğunu göstermektedir. Ortak değişintinin negatif işaretli olması, raslantı değişkenleri arasında negatif bir ilişki bulunduğunu göstermektedir. Bununla birlikte, raslantı değişkenleri arasında doğrusal bir ilişki yoksa ortak değişinti sıfıra yakın olmaktadır. Sıfır ortalamalı iki raslantı değişkeni dağılımı arasındaki ilişki durumları Şekil 3.2'de



gösterilmektedir. İki ya da daha fazla raslantı değişkeni arasındaki ilişki durumları ortak değişinti matrisiyle tanımlanabilmektedir. Ortak değişinti matrisinin köşegen ve köşegen dışındaki değerleri, raslantı değişkenlerinin sırasıyla değişinti ve ortak değişinti değerlerine karşılık gelmektedir.



Şekil 3.2. (a) İlişkisiz, (b) pozitif-ilişki, (c) negatif-ilişki

### 3.1.1. Ortak değişinti betimleyicilerin oluşturulması

İmgenin her bir pikseli ışıklılık, renk, doku gibi farklı özelliklere sahiptir. Piksellere ait her bir özelliğin öznitelik olarak değerlendirilmesi ve her bir pikselin birer gözlem olarak tanımlanması durumunda, çok değişkenli bir yapı oluşturmak mümkündür. Sütunların gözlemleri, satırların ise öznitelikleri temsil ettiği çok değişkenli yapı Eşitlik (3.1)'de verilmiştir.

$$\mathbf{M} = [\mathbf{f}_1 \quad \dots \quad \mathbf{f}_i \quad \dots \quad \mathbf{f}_n]_{d \times n} \quad (3.1)$$

$\{\mathbf{f}_i\}_{i=1}^n$   $d$ -boyutlu öznitelik sütun vektörünü,  $i$  ilgili piksel indisini,  $n$  ise imgedeki toplam piksel sayısını göstermektedir. Çok değişkenli yapının ortak değişinti matrisi, değişkenlerin dağılımları hakkında bilgi vermektedir.


Nesnelere ait karakteristik özelliklerin seçimi hedef tespit ve sınıflandırma performansında önemli bir rol oynamaktadır. [59]'da, imgede herhangi bir bölgenin ayırt edici özelliğini ortaya çıkartmak için bölgesel ortak değişinti betimleyici (BODB) önerilmiştir. Eşitlik (3.1)'de verilen çok değişkenli yapı, imgenin herhangi bir bölgesi için de tanımlanabilmektedir. Bu bağlamda BODB, imgede tespit veya takip edilecek hedef nesnenin görünüm betimleyicisi olan bir  $R$  bölgesi için bölgesel ortak değişinti matrisine karşılık gelmektedir. BODB'nin, diğer bir ifadeyle bölgesel ortak değişinti matrisinin gösterimi Eşitlik (3.2)'de verilmiştir.

$$\mathbf{C}_R = \frac{1}{n_R - 1} \sum_{i=1}^{n_R} (\mathbf{f}_i - \boldsymbol{\mu}_R)(\mathbf{f}_i - \boldsymbol{\mu}_R)^T \quad (3.2)$$

$\mathbf{C}_R$ ,  $d \times d$  boyutunda simetrik pozitif tanımlı bir matrisi,  $\boldsymbol{\mu}_R$  ilgili öznitelik vektörlerinin ortalamasını,  $n_R$  ise  $R$  bölgesi içindeki toplam piksel sayısını göstermektedir.  $R$  bölgesine ait, uzamsal özellikleri ve görünüm temelli özellikleri içeren örnek  $\mathbf{f}_i$  öznitelik vektörü Eşitlik (3.3)'te gösterilmiştir.

$$\mathbf{f}_i = [x \quad y \quad I(x, y) \quad I_x(x, y) \quad \dots]^T \quad (3.3)$$

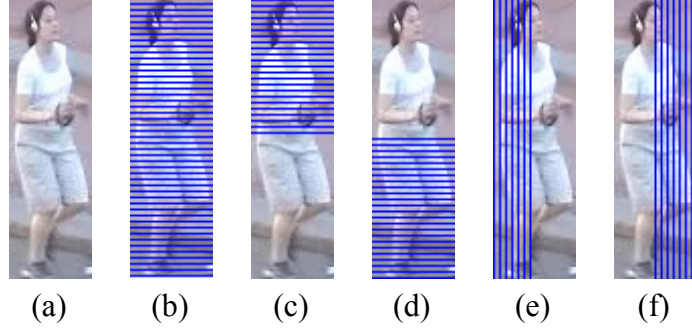
$x, y$  imgenin piksel koordinatlarını göstermektedir.  $I(x, y)$  ve  $I_x(x, y)$  ise sırasıyla imgenin ilgili piksel koordinatlarındaki renk ve  $x$  yönündeki gradyen bilgilerine karşılık gelmektedir.  $\mathbf{f}_i$  öznitelik vektörüne, imgenin ikinci veya daha yüksek dereceden gradyen bilgilerini, gradyen açılarını ve ön-plan/arka-plan bilgileri gibi detaylı özelliklerini ilave ederek genişletmek mümkündür. Şekil 3.3'te örnek bir hedef nesne üzerinden alınan bloğa ait her bir piksel için oluşturulan öznitelik vektörleri gösterilmiştir.



Şekil 3.3. Her bir piksel için öznitelik vektörlerinin elde edilmesi

$d$  boyutlu rasgele değişken ile oluşturulmuş ortak değışinti matrisi, yarı-pozitif tanımlı iken BODB'ler pozitif tanımlı bir matristir. Bunun nedeni, BODB'de tüm pikseller için oluşturulan öznitelik vektörleri arasında doğrusal bir ilişki olmadığı varsayımıyla hareket edilmesidir. Pozitif tanımlı BODB'lerin tüm öz değerleri pozitifdir.

Nesnelerin karakteristik özelliklerini çıkartmak için tek bir BODB yeterli olmakla birlikte, çoklu BODB kullanmak da mümkündür. Özellikle hedef takip uygulamalarında görülen yarı-örtüşme anlarında tek bir BODB yerine, çoklu BODB kullanmak nesnenin daha iyi tespit edilmesini sağlamaktadır. Şekil 3.4'te örnek bir hedefte farklı bölgeler için tanımlanan BODB'ler gösterilmektedir.



Şekil 3.4. (a) Hedef imge  $C_R$ , (b) tüm bölge  $C_R^1$ , (c) üst bölge  $C_R^2$ , (d) alt bölge  $C_R^3$ , (e) sol bölge  $C_R^4$ , (f) sağ bölge  $C_R^5$

Ortak değişinti matrislerini bölgesel betimleyici olarak kullanmak, hedef tespit ve takip uygulamalarında birçok avantaj sağlamaktadır. Farklı özniteliklerin bir arada kullanılmasıyla kompakt bir gösterim olan BODB'ler, özniteliklerin değişinti ve ilinti değerleri hakkında bilgi vermektedir. Ortak değişinti matrisinin hesaplanmasında ortalama süzgecin kullanılmasından dolayı, gürültülü veriler büyük oranda süzgeçlenmektedir. İmgede farklı boyuttaki bölgeler için oluşturulan ortak değişinti matrislerin aynı boyutta olması, bölge boyutundan bağımsız bir matris karşılaştırması sağlamaktadır. Bununla birlikte, BODB'ler içerdikleri özniteliklere bağlı olarak farklı boyuttaki bölgeler için ölçekte değişmezlik özelliğine sahiptir. BODB'ler sıfır ortalamalı bir dağılıma sahip olmalarından dolayı, hedef tespit ve takip uygulamalarında ışıklılık değişimine karşı gürbüz bir yapıya sahiptirler.

BODB'lerin diğer önemli bir avantajı, düşük işlem yüküne sahip olmalarıdır. Bölgesel  $d \times d$  boyutlu,  $C_R$  ortak değişinti matrisi simetrik bir yapıda olduğundan dolayı sadece  $(d^2 + d)/2$  adedinde farklı değer içermektedir. Halbuki aynı bölge,  $n_R$  toplam gözlem sayısı olmak üzere,  $d \times n_R$  boyutunda veri içermektedir.

### 3.1.2. Ortak deęişinti betimleyicilerde benzemezlik ölçütü ve model güncellemesi

Tez kapsamında önerilen özgün yöntemlerde, ortak deęişinti matrislerini karşılaştırmak için Forstner benzemezlik ölçütünden faydalanılmıştır. Hedef takibi için gerekli olan model güncelleme yaklaşımında ise Lie cebir/Lie grup temelli yaklaşım kullanılmıştır.

#### 3.1.2.1. Forstner benzemezlik ölçütü

Hedef takibinde referans nesneye en çok benzeyen aday nesnelerin bulunması için referans hedef bölgesine ait ortak deęişinti matrisi ile aday hedef bölgelerine ait ortak deęişinti matrisleri arasında benzerlik hesabı yapılmaktadır.

$d \times d$  boyutlarında tekil olmayan simetrik pozitif tanımlı ortak deęişinti matrisler ( $Sym_d^+$ ) arasındaki benzerlik hesabında, Forstner benzemezlik ölçütü kullanılmaktadır [60]. İki ortak deęişinti matris arasındaki benzemezlik ölçütü Eşitlik (3.4) ile ifade edilmektedir.

$$\text{dist}(\mathbf{C}_1, \mathbf{C}_2) = \sqrt{\sum_{i=1}^d \log^2 \lambda_i(\mathbf{C}_1, \mathbf{C}_2)} \quad (3.4)$$

$\lambda_i(\mathbf{C}_1, \mathbf{C}_2)$ ,  $\mathbf{C}_1$  ve  $\mathbf{C}_2$  ortak deęişinti matrislerinin genelleştirilmiş özdeęerlerini göstermektedir.  $\lambda_i(\mathbf{C}_1, \mathbf{C}_2)$  ile  $\mathbf{C}_1$  ve  $\mathbf{C}_2$  matrisleri arasındaki baęıntı Eşitlik (3.5)'te gösterilmiştir.

$$\mathbf{C}_1 \mathbf{X} = \mathbf{C}_2 \mathbf{X} \boldsymbol{\lambda} \quad (3.5)$$

$\mathbf{X}$ , genelleştirilmiş özvektör matrisine karşılık gelmektedir. Forstner benzemezlik ölçütü aşağıda belirtildięi gibi metrik aksiyomlarını sağlamaktadır.

- i)  $\text{dist}(\mathbf{C}_1, \mathbf{C}_2) \geq 0$
- ii)  $\text{dist}(\mathbf{C}_1, \mathbf{C}_2) = 0 \quad \mathbf{C}_1 = \mathbf{C}_2$
- iii)  $\text{dist}(\mathbf{C}_1, \mathbf{C}_2) = \text{dist}(\mathbf{C}_2, \mathbf{C}_1)$
- iv)  $\text{dist}(\mathbf{C}_1, \mathbf{C}_2) + \text{dist}(\mathbf{C}_1, \mathbf{C}_3) \geq \text{dist}(\mathbf{C}_2, \mathbf{C}_3)$

Eşitlik (3.5)'te verilen eşitliğin her iki tarafı  $C_2^{-1}$  ile çarpıldığında,  $C_2^{-1}C_2 = I$  birim matris ( $I$ - identity matrix) elde edildiğinden, genelleştirilmiş özdeğer-özvektör problemi, Eşitlik (3.6)'da ifade edildiği gibi standart özdeğer-özvektör problemine dönüşmektedir.

$$\begin{aligned} C_2^{-1}C_1\mathbf{X} &= C_2^{-1}C_2\mathbf{X}\lambda \\ (C_2^{-1}C_1)\mathbf{X} &= I\mathbf{X}\lambda \end{aligned} \quad (3.6)$$

Eşitlik (3.5)'te, eşitliğin her iki tarafı  $\mathbf{X}^T$  özvektör matrisinin devriği ile çarpıldığında,  $\mathbf{X}$  özvektör matrisi,  $\mathbf{X}^T C_2 \mathbf{X} = I$  olacak şekilde normalize edilirse,  $\mathbf{X}^T C_1 \mathbf{X} = \lambda$  eşitliği elde edilecektir. Dolayısıyla  $\lambda$  özdeğer matrisi, birim matrisine dönüştürülen  $C_2$  matrisine göre hesaplanan özvektör matrisine bağlıdır. Bununla beraber, aynı özdeğer matrisi  $\mathbf{X}^T C_1 \mathbf{X} = I$  olacak şekilde normalize edilen özdeğer matrisini kullanarak  $\mathbf{X}^T C_2 \mathbf{X} = \lambda$  eşitliğiyle de hesaplanabilmektedir.

Nesne gösterimi için çoklu BODB'ler kullanılması durumunda, her bir BODB için referans bölge ile hedef bölge arasında Forstner benzeme ölçütü hesaplanmalıdır. Şekil 3.4'te referans bölge için tanımlanan 5 farklı bölgeye ait ortak değişinti matrisleri, aday bölgelerin ortak değişinti matrisleri ile karşılaştırılmalıdır. Dolayısıyla, çoklu BODB durumları için iki bölge arasındaki benzeme ölçütü olarak Eşitlik (3.4) yerine Eşitlik (3.7) kullanılmaktadır.

$$\text{total\_dist}(C_R^i, C_T^i) = \sum_{i=1}^5 \text{dist}(C_R^i, C_T^i) \quad (3.7)$$

$C_R^i$  ve  $C_T^i$  sırasıyla referans ve aday bölgelere ait ortak değişinti matrislerine karşılık gelmektedir.

### 3.1.2.2. Model güncelleme yaklaşımı

BOBD temelli hedef takip uygulamalarında, referans bölgesel betimleyicilerin tanımlanması kadar zamana göre güncellenmesi de önemli olmaktadır. Takip edilen hedef görünümünün zamanla değişmesi, hedefe ait karakteristik özellikleri de değiştirmektedir. Karakteristik özellikleri betimleyen ortak değişinti matrislerin

zamana göre doğru bir şekilde güncellenmesi, hedef takip performansını arttırmaktadır. Takip edilen hedefin, görünümünde değişme olmadığı durumlarda, ortak değişinti betimleyicilerin zamana göre güncellenmesine gerek duyulmamaktadır. Buna rağmen, zaman içerisinde hedefin görünümünde değişim olması kaçınılmazdır.

$k = 1, \dots, K$  zamanlarında tespit edilen hedef nesneye ait  $R_k$  nesne bölgelerinde tanımlı olan  $\mathbf{f}_i^k \in R_k$  öznitelik vektörlerini kullanarak, Eşitlik (3.8)'de gösterildiği gibi ortalama ortak değişinti betimleyicisi hesaplanabilmektedir.

$$\tilde{\mathbf{C}} = \frac{1}{(n_R - 1)K} \sum_{k=1}^K \sum_{i=1}^{n_R} (\mathbf{f}_i^k - \boldsymbol{\mu}_{R_m})(\mathbf{f}_i^k - \boldsymbol{\mu}_{R_m})^T \quad (3.8)$$

$$\boldsymbol{\mu}_{R_m} = \frac{1}{K} \sum_{k=1}^K \boldsymbol{\mu}_{R_k}$$

Burada  $\tilde{\mathbf{C}}$ , ortalama BODB'yi göstermektedir.  $\boldsymbol{\mu}_{R_m}$  ise tüm  $R_k$  bölgelerinde bulunan öznitelik vektörlerin ortalama öznitelik vektörüne karşılık gelmektedir. Eşitlik (3.8)'de gösterilen ortalama BODB hesabında,  $R_k$  bölgelerinin aynı boyutta olduğu varsayılmıştır. Bununla birlikte,  $\mathbf{f}_i^k \in R_k$  öznitelik vektörleri, ortalama BODB hesabında eşit ağırlığa sahiptir. Eşitlik (3.8)'de gösterilen ortalama BODB hesabının işlem yükü,  $k$ 'ya bağlı olarak artmaktadır. Buna paralel olarak, uzun süreli hedef takip işlemlerinde yüksek işlem yükü ortaya çıkmakta ve çok büyük miktarda hafızaya gereksinim duyulmaktadır.

Ortalama BODB hesabında öznitelik vektörlerine farklı ağırlıklar verebilmek hedef takip performansını etkilemektedir. Bununla birlikte, ortalama BODB hesabında sabit sayıda BODB kullanmak, hafıza gereksinimini azaltmaktadır. Bu doğrultuda, daha verimli bir BODB temelli model güncelleme işlemini farklı bir uzayda gerçekleştirmek mümkündür.[61].

$Sym_d^+$  ortak değişinti matrisler için model güncelleme işlemi, Riemannian geometrisi sayesinde hesaplanabilmektedir. Bu doğrultuda, ortak değişinti matrisler Lie grup yapısına sahiptir. Lie grubu, grup özelliklerini sağlamakta aynı zamanda pürüzsüz

birçok katlıdır (smooth manifold). Grubun pürüzsüz çok katlı olması, sonsuz türevlenebilir bir yapıda olduğunu ifade etmektedir.

Bir Lie cebri ile Lie grubu arasındaki geometrik bağlantı, Lie cebrinin, Lie grubunun birim elemanı ( $\mathbf{e}$ ) üzerinde yer alan tanjant uzayına karşılık gelmesi ile kurulabilmektedir. Bu bağlamda, Lie grubun birim elemanı üzerindeki tanjant uzayı, Lie cebrine karşılık gelmektedir. Lie cebri diğer bir ifadeyle, Lie grubunun birim elemanı yakınında doğrusallaştırılmasıdır.

Tanjant uzayından Lie grubuna üssel bir dönüşüm bulunmaktadır (exponential map). Benzer şekilde, Lie grubundan Lie cebrine logaritmik (logarithmic map) bir dönüşüm vardır. Bu dönüşümler, Eşitlik (3.9)'da gösterilmiştir.

$$\begin{aligned} \exp(\mathbf{c}) &= \mathbf{I} + \sum_{n=1}^{\infty} \left( \frac{1}{n!} \mathbf{c}^n \right) \\ \log(\mathbf{C}) &= \sum_{n=1}^{\infty} \frac{(-1)^{n-1}}{n} (\mathbf{C} - \mathbf{e})^n \end{aligned} \quad (3.9)$$


$\mathbf{c}$  ve  $\mathbf{C}$  sırasıyla Lie cebri ve Lie grubu elemanlarına karşılık gelmektedir. Simetrik bir matris, özvektör ve özdeğerlerine ayrıştırılabilmektedir. Buna göre, Lie cebrinde bir noktaya karşılık gelen  $\mathbf{c}$  matrisinin matris üssel ve matris ters üssel dönüşümleri, özvektör ve özdeğer matrisi ile Eşitlik (3.10)'da gösterildiği gibi daha kolay bir şekilde hesaplanabilmektedir.

$$\begin{aligned} \mathbf{c} &= \mathbf{O} \mathbf{D} \mathbf{O}^T = \mathbf{O} \mathbf{D} \mathbf{O}^{-1} \\ \exp(\mathbf{c}) &= \mathbf{O} \exp(\mathbf{D}) \mathbf{O}^T = \mathbf{O} \exp(\mathbf{D}) \mathbf{O}^{-1} \end{aligned} \quad (3.10)$$

$\mathbf{O}$  ve  $\mathbf{D}$  sırasıyla özvektör ve özdeğer matrisine karşılık gelmektedir. Lie cebri ve Lie grubu elemanları arasındaki geometrik ilişki, Şekil 3.5'te gösterilmiştir

Lie grubunda bulunan noktaların (elemanların) ortalama değeri, Lie cebri ile hesaplanabilmektedir. BODB'ler, diğer bir ifadeyle ortak değişinti matrisleri, Lie grup yapısında bulunduğundan, ortak değişinti matrislerin ortalama değeri, Lie cebri/ Lie grup yapısında gerçekleştirilebilmektedir.

Çok katlı topolojik uzay üzerinde bulunan noktalar arasındaki uzaklıklar, en kısa uzunluğa sahip eğriler ile tanımlanmaktadır. En kısa uzunluğa sahip eğri, “jeodezik eğri” olarak isimlendirilmektedir. Bu eğrinin uzunluğu, gerçek uzaklığa (intrinsic distance) karşılık gelmektedir.



Şekil 3.5. Lie cebri ve Lie grubu elemanları arasındaki geometrik ilişki

Lie grubunda bulunan bir  $C$  noktasının birim elemana gerçek uzaklığı,  $\|\log(C)\|$ 'dir.

$C$  noktası, tersiyle ( $C^{-1}$ ) çarpılması durumunda,  $e$  birim elemana eşleşmektedir. Bu durumda  $C$  noktası, Lie cebirinde tanjant uzayına karşılık gelmektedir. Lie grup üzerinde,  $\{C_k\}_{k=1,\dots,K}$  noktalarının Lie cebirindeki ifadesi, Eşitlik (3.11)'de verilmiştir.

Lie cebri, vektör uzayına karşılık geldiği için,  $c_k$  noktalarının ortalamasını hesaplamak mümkündür.

$$c_k = \log(C^{-1}C_k) \quad (3.11)$$

Bu bilgiler ışığında, hedef takibinde, ortak değişinti matrislerin Lie grubunda tanımlı olmasından dolayı, Lie cebir/Lie grup temelli bir model güncelleme işlemi gerçekleştirmek mümkündür. Model güncelleme işleminde, her bir ortak değişinti matrisi,  $C_k$  noktasına karşılık gelmektedir.




Tez kapsamında önerilen tüm özgün yaklaşımlarda, [61]'de önerilen Lie cebir/Lie grup temelli model güncelleme yaklaşımı kullanılmıştır. Bununla birlikte, yine [61]'de önerilen yaklaşıma paralel olarak model güncelleme işleminde, daha iyi bir hedef takip performansı için, ortak değişinti matrislerin uzaklık ölçütlerine bağlı bir iyileştirme yapılmıştır.

### 3.1.3. Tümlev imge gösterim yaklaşımı ile ortak değişinti betimleyicilerin elde edilmesi

İmge işleme uygulamalarında ortalama süzgeçleme işleminin işlem yükü, blok boyutuna bağlı olarak değişmektedir. Ancak tümlev imge gösteriminden faydalanılarak blok boyutundan bağımsız bir ortalama süzgeçleme işlemini gerçekleştirmek mümkündür. Bu sayede işlemin hesapsal karmaşıklığı azaltılmaktadır.

Herhangi bir imgenin tümlev imge gösterimi önceden hesaplanarak, imge içinde herhangi bir dikdörtgen bölgenin alanı veya ortalaması birkaç aritmetik işlemle hesaplanabilmektedir. Tümlev imge gösterimi, gerçek zamanlı yüz tespitinde [62] ve hızlı histogram hesaplamalarında [63] kullanılmaktadır.

Tümlev imgede  $(x,y)$  noktasındaki değer, orijinal imgenin  $(x,y)$  noktasının sol üst kısmında bulunan piksel değerlerinin toplamına eşittir.



Şekil 3.6. Tümlev imge oluşturma


Şekil 3.6'da gösterilen tümlev imge, Eşitlik (3.12)'deki formül ile elde edilmektedir.

$$I^J(x,y) = \sum_{x' \leq x, y' \leq y} I(x',y') \quad (3.12)$$

$I(x', y')$  orijinal imgeyi,  $I^J(x, y)$  ise tümlev imgeyi göstermektedir. Tümlev imge gösterimi, aynı zamanda yinelemeli bir şekilde de oluşturulabilmektedir. Yinelemeli gösterim Eşitlik (3.13)'te gösterilmiştir.

$$I^J(x, y) = I(x, y) + I^J(x-1, y) + I^J(x, y-1) - I^J(x-1, y-1) \quad (3.13)$$

Tümlev imge yapısının, yinelemeli gösteriminde başlangıç koşulları olarak  $I(-1, 0) = I(0, -1) = I(-1, -1) = 0$  alınmalıdır. Tümlev imge oluşturulduktan sonra, Şekil 3.7'de gösterilen boyuttan bağımsız bir  $R$  bölgesi için piksel değerlerinin toplamı Eşitlik (3.14)'te gösterilmiştir.



Şekil 3.7. Herhangi bir  $R$  bölgesinin alanının hesaplanmasında tümlev imge kullanımı

$$\sum_{(x,y) \in R} I(x, y) = I^J(x_2, y_2) - I^J(x_1, y_2) - I^J(x_2, y_1) + I^J(x_1, y_1) \quad (3.14)$$

BODB'ler, tümlev imge gösterim tekniğinden faydalanarak, hızlı bir şekilde hesaplanabilmektedir [64]. Bu sayede, BODB temelli hedef tespiti ve özellikle hedef takibi uygulamalarında hesapsal yük azaltılmaktadır. Eşitlik (3.2)'de gösterilen ortak değişinti matrisi, daha açık bir ifadeyle Eşitlik (3.15)'te tanımlanmıştır.

$$C_R(i, j) = \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} (\mathbf{f}_k(i) - \boldsymbol{\mu}(i)) (\mathbf{f}_k(j) - \boldsymbol{\mu}(j)) \right] \quad (3.15)$$

Burada  $(i, j)$  ortak deęişinti matrisinin sırasıyla satır sütun koordinatlarını göstermektedir. Ortak deęişinti matrisinin tümlev imge yapısına uygun olması için Eşitlik (3.16)'da ifade edildięi gibi yeniden düzenlenmiştir.

$$\begin{aligned}
C_R(i, j) &= \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} \mathbf{f}_k(i) \mathbf{f}_k(j) - \mathbf{f}_k(i) \boldsymbol{\mu}(j) - \mathbf{f}_k(j) \boldsymbol{\mu}(i) - \boldsymbol{\mu}(i) \boldsymbol{\mu}(j) \right] \\
&= \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} \mathbf{f}_k(i) \mathbf{f}_k(j) - \sum_{k=1}^{n_R} \mathbf{f}_k(i) \boldsymbol{\mu}(j) - \sum_{k=1}^{n_R} \mathbf{f}_k(j) \boldsymbol{\mu}(i) + n_R \boldsymbol{\mu}(i) \boldsymbol{\mu}(j) \right] \\
&= \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} \mathbf{f}_k(i) \mathbf{f}_k(j) - n_R \boldsymbol{\mu}(i) \boldsymbol{\mu}(j) - n_R \boldsymbol{\mu}(j) \boldsymbol{\mu}(i) + n_R \boldsymbol{\mu}(i) \boldsymbol{\mu}(j) \right] \quad (3.16) \\
&= \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} \mathbf{f}_k(i) \mathbf{f}_k(j) - n_R \boldsymbol{\mu}(i) \boldsymbol{\mu}(j) \right] \\
&= \frac{1}{n_R - 1} \left[ \sum_{k=1}^{n_R} \mathbf{f}_k(i) \mathbf{f}_k(j) - \frac{1}{n_R} \sum_{k=1}^{n_R} \mathbf{f}_k(i) \sum_{k=1}^{n_R} \mathbf{f}_k(j) \right]
\end{aligned}$$

Eşitlik (3.16) incelendięinde, ortak deęişinti matrisin hesaplanabilmesi için her bir öznitelik vektör toplamının ve herhangi iki öznitelik vektör çarpım toplamının bilinmesi gerekmektedir. Bu bağlamda, öznitelik vektörlerine baęlı olarak hesaplanan toplamsal işlemler, tümlev imge gösterim teknięiyle hızlı bir şekilde hesaplanabilmektedir.

[64]'te kullanılan notasyonlara baęlı kalarak  $F$ , renk, gradyan gibi farklı özellikler için hesaplanan  $W \times H$  boyutlu  $I$  imgesinden elde edilmiş,  $W \times H \times d$  boyutunda bir özellik imgesi olsun. Bu durumda, BODB'ler için tanımlanan tümlev imge yapıları Eşitlik (3.17) ve Eşitlik (3.18)'de gösterilmiştir.  $W$  ve  $H$  imgenin sırasıyla genişlik ve yüksekliğini göstermektedir.

$$P^{\int} (x, y, i) = \sum_{x' \leq x, y' \leq y} F(x', y', i) \quad (3.17)$$

$$Q^{\int} (x, y, i, j) = \sum_{x' \leq x, y' \leq y} F(x', y', i) F(x', y', j) \quad (3.18)$$

$P^{\int}$  ve  $Q^{\int}$  sırasıyla  $W \times H \times d$  ve  $W \times H \times d \times d$  boyutlarında tümlev imgeleri göstermektedir. Bu tümlev imgeler üzerinden herhangi bir  $(x, y)$  koordinatı için

Eşitlik (3.19)'da gösterildiği gibi  $d$  boyutlu bir  $\mathbf{p}_{x,y}$  vektörü ve  $d \times d$  boyutlu bir  $\mathbf{Q}_{x,y}$  matrisi oluşturmak mümkündür.

$$\mathbf{p}_{x,y} = \left[ P^J(x,y,1) \quad \dots \quad P^J(x,y,d) \right]^T$$

$$\mathbf{Q}_{x,y} = \begin{pmatrix} Q^J(x,y,1,1) & \dots & Q^J(x,y,1,d) \\ & \dots & \\ Q^J(x,y,d,1) & \dots & Q^J(x,y,d,d) \end{pmatrix} \quad (3.19)$$

Nihai olarak, imgenin herhangi bir  $R$  bölgesi için BODB, Eşitlik (3.13) yardımıyla Eşitlik (3.20)'deki gibi hesaplanmaktadır.

$$\mathbf{p}_R = \left( \mathbf{p}_{x_2,y_2} + \mathbf{p}_{x_1,y_1} - \mathbf{p}_{x_2,y_1} - \mathbf{p}_{x_1,y_2} \right) \left( \mathbf{p}_{x_2,y_2} + \mathbf{p}_{x_1,y_1} - \mathbf{p}_{x_2,y_1} - \mathbf{p}_{x_1,y_2} \right)^T$$

$$\mathbf{C}_{R(x_1,y_1;x_2,y_2)} = \frac{1}{n_R - 1} \left[ \left( \mathbf{Q}_{x_2,y_2} + \mathbf{Q}_{x_1,y_1} - \mathbf{Q}_{x_2,y_1} - \mathbf{Q}_{x_1,y_2} \right) - \frac{1}{n_R} \mathbf{p}_R \right] \quad (3.20)$$

$\mathbf{Q}_{x,y}$  matrisinin simetrik yapıda olmasından dolayı,  $\mathbf{Q}_{x,y}$  için  $(d^2 \times d) / 2$  sayıda tümlev imgesi yeterli olmaktadır.

Bu tez kapsamında önerilen BODB temelli yöntemlerde BODB'ler, aksi belirtilmediği sürece tümlev imge gösterim yöntemiyle hesaplanmıştır.

### 3.2. Ortak Değişinti Betimleyici Temelli Hedef Tespit ve Takip Çalışmalarına Genel Bakış

Literatürde, BODB'ler ilk defa [59]'da tanımlanmış, hedeflerin tespiti ve sınıflandırmasında kullanılmıştır. Hedef tespiti için, 9 farklı öznitelik vektörü kullanarak  $9 \times 9$  boyutlu BODB'ler oluşturulmuştur. BODB'ler, farklı ölçeklerde hedef boyutları dikkate alınarak, tam arama yaklaşımıyla hedef imgede aranmaktadır. [59]'dan yola çıkarak önerilen ortak değişinti betimleyici (ODB) temelli yaklaşımlar hedef tanıma, hedef tespiti ve takibi, sınıflandırma, bölütleme gibi farklı bilgisayar görü uygulamalarında yaygın bir şekilde kullanılmaktadır.

[64]'de ODB'lerin hızlı bir şekilde hesaplanabilmesi için tümlev imge gösterim yöntemi kullanılmıştır. Önerilen bu yöntem sayesinde, imgede herhangi bir

dikdörtgen bölge için hesaplanan ODB'nin hesapsal gereksinimi, [59]'daki yaklaşıma göre oldukça azalmaktadır. Bununla birlikte ODB, tümlev imge gösterim sayesinde, bölge boyutundan bağımsız, sabit bir sürede hesaplanabilmektedir.

[61]'de ODB temelli hedef takip yaklaşımı önerilmiştir. Bu yaklaşımda, takip edilecek nesneye benzer, en uygun hedef nesnenin bulunmasında Forstner uzaklık metriği kullanılmıştır. Nesne görünümünü temsil eden ortak değişinti betimleyicinin güncellenmesinde Lie cebir/ Lie grup yapısı kullanılmıştır. Önerilen yaklaşımın başarımı, hareketli ve durağan kamera kayıtları ile kızılötesi görüntülerde test edilmiştir. Hareketli kamera kayıtlarında kullanılan öznitelik vektörü; x-y koordinat değerini, imgenin ışıklılık değerini, x ve y yönlerindeki gradyen bilgilerini içermektedir. Bununla birlikte, sabit arka plan içeren görüntü dizileri için ayrıca çerçeve fark bilgisi eklenmiştir. Hedef takip başlangıcı, el yardımıyla yapılmıştır. Hedef nesnelerin en uygun yerinin bulunmasında tam arama yaklaşımı kullanılmıştır.

[61]'de önerilen ODB temelli nesne takibine benzer bir çalışma [65]'de önerilmiştir. Takip edilecek referans ODB ile aday ODB'ler arasındaki benzerlik hesabı Forstner uzaklık metriği ile hesaplanmaktadır. Referans ODB'nin güncellenmesi ise Riemannian uzayında gerçekleştirilmektedir [66]. ODB'lerin simetrik pozitif tanımlı matrisler olmasından dolayı, Riemannian manifoldları üzerinde bulunan noktalar arasında en kısa uzunlukta eğri, jeodezik olarak isimlendirilmektedir. Riemannian manifoldunda her bir ODB, bir noktaya karşılık gelmektedir. Riemannian manifoldu, bölgesel olarak Öklid uzayında olup manifold üzerindeki her bir nokta, tanjant uzayına sahiptir. Manifold üzerindeki noktalar ile tanjant uzayındaki vektörler arasındaki ilişki, üssel dönüşüm ve logaritmik dönüşümler ile ifade edilmektedir.

[67]'de ODB temelli araç plaka tespiti gerçekleştirilmiştir. Bu yaklaşımda araç plakaları, ODB'ler kullanılarak sinir ağları ile çevrim dışı eğitim aşamasından geçirilmektedir. Sinir ağını eğitmek için, plaka içeren ve içermeyen imgeler kullanılmıştır. Plaka tespit aşamasında ise, aday imgeler sinir ağında değerlendirilip, sinir ağından imgenin plaka içerip içermediği bilgisi alınmaktadır. Bu yaklaşımda, ODB'ye ait öznitelik vektörlerinden x-y kartezyen koordinat veya kutupsal koordinat değerlerinden farklı olarak, koordinat değerlerine bağlı frekans dönüşüm fonksiyonu kullanılmıştır. Frekans dönüşüm fonksiyonu sayesinde ODB, imgenin olası rotasyon

durumlarına karşılık kararlı bir yapıya sahip olmasının yanı sıra, imgede meydana gelen bozunumlara karşı kararlı yapısını korumaktadır.

İnsan görünümününin ODB ile temsil edilmesi ve Riemannian manifoldları üzerinde bulunan bu ODB'lerin sınıflandırılması, insan tespiti için mümkün kılmaktadır. [68]'de, Riemannian manifoldlarından Tanjant vektör uzayına geçilmekte, ODB temelli sınıflandırma işlemi ise LogitBoost algoritmasından yararlanılarak bu vektör uzayında yapılmaktadır. Bununla birlikte imge içinde, 200 farklı alt bölge seçilip, bu bölgeler için ODB oluşturulmaktadır. Zayıf sınıflandırıcı gösteriminde öğrenme işlemi, bu alt bölgelere ait ODB'ler kullanılarak elde edilen Tanjant vektör uzayı üzerinden yapılmaktadır.

[69]'da videolarda insan tespiti için önerilen yaklaşım, temelde [68]'de önerilen yaklaşıma benzer bir yol izlemektedir. Önerilen yaklaşım, [68]'e göre daha düşük bir hesapsal yüke sahip olup hedefi daha yüksek bir başarıyla tespit etmektedir. Bu yaklaşımda, ODB oluşturulurken hesaplanan ortalama öznitelik vektörleri aynı zamanda eğitim ve tespit aşamasında kullanılmıştır. Bununla birlikte, ODB'yi oluşturan öznitelik vektörlerine, ön plan olasılık bilgisi dahil edilmiştir.

[70]'de BODB temelli çoklu hedef takibi önerilmiştir. Hedef takibinde süreç ve ölçüm modeli olarak PS kullanılmıştır. Süreç modelinde, uyarlamalı hız modeli tercih edilmiştir. PS'de ağırlıkların belirlenmesinde, referans ODB ile aday ODB'ler arasında hesaplanan uzaklık değerleri kullanılmaktadır. Referans hedefin görünümü, birden fazla ODB ile temsil edilmektedir. Hedef takibinde referans hedefe ait ODB'nin zamanla güncellenmesi, Riemannian manifoldunda gerçekleşmektedir. Güncelleme işleminde,  $k$  anında geçerli olan referans ODB ile  $k+1$  anında bulunan en uygun aday ODB arasında ortalama alma işlemi yapılmaktadır. Bu işlem, hedef takip süresince devam etmektedir. Bu çalışmada ayrıca, çoklu hedef takibinde görülen hedeflerin birleşmesi, ayrılması gibi farklı senaryolar için de başarımlar değerlendirilmiştir.

[71]'de ODB temelli olasılıksal hedef takip yaklaşımı önerilmiştir. Hedef takibinde, ODB temelli uzaklık hesabı, görünüm güncelleme gibi işlemler Riemannian uzayında gerçekleştirilmiştir. Takip edilecek hedefe ait durum vektörlerinin zamana göre dağılımı, PS ile yapılmaktadır. PS'de, her bir durum vektörüne ait ağırlık

değerleri, durum vektörüyle ilişkili olabilirlik değeriyle orantılıdır. Bu yaklaşımda, takip sistemine ait durum-geçiş fonksiyonu olarak özbağımlı (autoregressive AR) model kullanmak yerine daha basit bir model tercih edilmiştir. Bu modelde,  $k$  anındaki parçacıkların konumu hesaplanırken, rasgele sayı üretimine göre ya  $k-1$  anındaki parçacıkların konumu kullanılmakta ya da  $k-1$  anındaki parçacıkların konumuna ek olarak parçacıkların  $k-1$  anındaki hızı kullanılmaktadır. Ayrıca bu çalışmada, ODB'nin hızlı bir biçimde hesaplanması için kullanılan tümlev imge gösteriminde farklı bir yol izlenmiştir. Tümlev imge hesabında, imgenin tüm alanını kullanmak yerine, durum vektörlerine ait parçacıkların kapladığı alan kullanılmaktadır. Bu sayede, hesapsal yükte bir iyileştirme sağlanmıştır.

[72]'de görüntü dizilerinde dinamik arka plan çıkarımı için ODB'ler kullanılmıştır. Arka plan çıkarımında, her bir piksel için birden fazla Gauss karışım modeli kullanmak yerine, birden fazla ortak değişinti matrisi kullanılmıştır. Gauss karışım modeline benzer şekilde, her bir ortak değişinti matrisi belirli bir ağırlığa sahiptir. İmgedeki ilgili pikselin ön plana mı yoksa arka plana mı ait olduğunu tespit etmek için, ilgili piksele ait ortak değişinti matrisi ile arka planı temsil eden ortak değişinti matrisleri karşılaştırılmaktadır.

[73]'te Gabor temelli ortak değişinti matrisleri yüz tanımada kullanılmıştır. Bu yaklaşımda, ODB'nin hesaplanmasında yaygın bir şekilde kullanılan birinci ve ikinci dereceden gradyen bilgileri yerine Gabor katsayıları tercih edilmiştir. 8 farklı yönde ve 5 farklı ölçekte tanımlanmış Gabor kernelleri ile yüz imgesinin evrişimi sonrasında elde edilen 40 farklı Gabor özelliği, yüz imgesinin her bir pikseline ait Gabor öznitelik vektörüne karşılık gelmektedir.

Farklı öznitelik vektörleriyle oluşturulmuş ODB'lerin, hedef tespit işlemi üzerindeki performansı ilk kez [74]'te ele alınmıştır. Bu çalışmada, sabit bir kamera ve hareketli bir kameranın ortak çalışmasıyla hedef tespiti ve hedef doğrulaması gerçekleştirilmiştir. Sabit kamera ile tespit edilen hedef, hareketli kamera ile farklı açılardan aynı sahne ortamında aranmaktadır. Önerilen yöntemin başarımı, farklı öznitelik vektörlerine sahip ODB ve yönlü histogram betimleyicileri kullanılarak sınanmıştır.

[75]'te ODB temelli olasılıksal hedef takip sistemi önerilmiştir. Hedefe ait durum vektörlerinin zamana göre olasılıksal dağılımı PS ile gerçekleştirilmektedir. Süreç modeli olarak birinci dereceden dinamik model seçilmiştir. Referans hedefe ait ODB ile aday hedeflere ait ODB'ler arasında hesaplanan uzaklık değerlerinin dağılımı Gauss formunda olduğu kabul edilmiştir. Bu uzaklık değerleri de, aday hedeflerin olabilirliğini gösterecek şekilde olasılıksal olarak ifade edilmektedir.

[76]'da ODB temelli gürbüz bir görsel hedef takip sistemi önerilmiştir. Bu yaklaşımda, takip edilen hedefin görünüm modelini temsil eden ODB'nin güncellenmesi, artımsal (incremental) olarak yapılmaktadır. Diğer bir ifadeyle, k anındaki referans ODB'nin güncellenmesinde, k-1 anındaki referans ODB ile k anında arama sonrasında bulunan en uygun aday ODB kullanılmaktadır. Güncelleme işlemi Öklid uzayında yapılmaktadır. Bununla birlikte, ODB'nin güncellenmesinde uyarlamalı ağırlık faktörü kullanılarak, eski gözlemlere verilecek önem ile yeni gözlemlere verilecek önem ayarlanabilmektedir.

[77]'de ortak değişinti matrislerin tanımlı olduğu Riemannian manifoldunda bayır iniş algoritması (gradient descent algorithm) kullanılarak hedef takip yaklaşımı önerilmiştir. Diğer bir ifadeyle, Öklid vektör uzayında tanımlı bayır iniş en iyileme algoritması, Riemannian uzayında gerçekleştirilmiştir. Referans ODB ile aday ODB'ler arasında hesaplanan uzaklık ölçütünün, x ve y konumlarına bağlı bir fonksiyonla gösterilmesi durumunda, bu fonksiyonun x-y konumlarına göre minimizasyonu amaçlanmıştır. Bununla birlikte, hedef takibinde en uygun aday hedefin konumunu bulmak için, kapsamlı bir arama yapmak yerine, yerel bir arama yapılmaktadır. Bu sayede hedef takip işleminin hesapsal yükü, kapsamlı bir aramayla gerçekleştirilen takip işlemine göre daha az olmaktadır.

[79]'da önerilen görsel hedef takibinde, simetrik pozitif tanımlı matris temelli istatistiksel işlemler, Riemannian uzayı yerine Log-Öklid uzayında [78] yapılmıştır. Log-Öklid uzayı, standart Riemannian uzayına göre daha basit bir yapıda olup ODB'ler arasında uzaklık hesabı ve ortalama ODB hesabı gibi işlemler bu uzayda gerçekleştirilebilmektedir. Bu çalışmada, takip edilen nesne için birden fazla ODB kullanılmış ve her bir ODB'nin zamanla güncellenmesi artımsal olarak uyarlamalı bir şekilde gerçekleştirilmiştir. Güncelleme aşamasında, düşük seviyeli Log-Öklid öz



uzay gösterim yaklaşımı kullanılmıştır. Hedefin durum-geçiş dağılımı, Gauss dağılımı ile modellenmiş, hedef takibinde PS kullanılmıştır.

[80]'de önerilen görsel hedef takibinde, referans ODB ile aday ODB'ler arasındaki uzaklık hesabı, Öklid uzayında gerçekleştirilmiştir. Ortak değişinti matrisler, kokusuz dönüşümde [10] önerilen yaklaşımdan yola çıkılarak, özel noktalar ile tanımlanmıştır. Özel noktalar ile oluşturulan referans ODB'ye ait vektör ile aday ODB'ye ait vektörler, Öklid uzayında karşılaştırılmaktadır. Takip edilen hedef görünümünün zamanla güncellenmesi, artımsal temel bileşen analizi yaklaşımıyla sağlanmıştır.

[81]'de önerilen yaklaşımda, hedef takibine ait sistem dinamik modelleri Riemannian manifoldunda tanımlanmıştır. Bu çalışmada, hedefe ait deformasyon ve konum değişim bilgilerini içeren ilgin dönüşüm parametreleri, durum vektörü olarak alınmıştır. Riemannian manifoldunda ardışık iki durum vektörü arasındaki fark, bu durum vektörlerini birbirine bağlayan eğriye ait Tanjant vektörüyle ilişkilendirilmiştir. Diğer bir ifadeyle, durum vektörleri Lie grubunda, durum vektörlerine ait hareket (hız) bilgisi de Lie cebirinde tanımlanmıştır. Bu yaklaşımda, Riemannian manifoldunda gerçekleştirilen PS temelli hedef takibinin başarımı, standart vektör uzayında gerçekleştirilen PS temelli hedef takibi ile karşılaştırılmıştır.

[82]'de ortak değişinti betimleyici matrislerin oluşturulmasında farklı bir yaklaşım önerilmiştir. ODB'lerin oluşturulmasında hesapsal yük çok fazla olmamakla birlikte, farklı ölçekler ve farklı konum değerleri için işlemsel yük artmaktadır. Bu yaklaşımda, işlemsel yükü azaltmak için ortak değişinti matris hesabında çarpma operatörü yerine toplam operatörü kullanılmıştır.

[83]'te farklı öznitelik vektörleri ile oluşturulan ODB'lerin, hedef tespitindeki başarımı irdelenmiştir. 9 farklı ortak değişinti matrisi oluşturularak, her bir ortak değişinti matrisinin, insan ve yüz tespitindeki başarımı değerlendirilmiştir.

[84]'te ODB'lerin karşılaştırılmasında kullanılan Forstner metriği yerine, Mahalanobis uzaklık metriği kullanılmıştır. Bununla birlikte, referans hedefe ait pozisyon ve görünüm bilgilerinin güncellenmesinde bir takım kısıtlamalar getirilmiştir. Örneğin, referans ODB'ye en çok benzeyen aday ODB etrafında

hesaplanan diğ er aday ODB'lerin öz deđ iş intisi küçük olmak zorundadır. Bu yaklaşımda, kısıtlamaların herhangi birisi sağ lanamı yorsa, referans hedefe ait pozsiyon ve görünüm bilgisi güncellenmemektedir.

ODB'ler arasında uzaklık hesabını ve takip edilen hedefe ait referans ODB'nin zamanla güncellemesini Öklid uzayında gerçekleştirmek mümkündür. [85]'te ortak deđ iş intisi matrisleri bir takım özel nokta adı verilen vektörlerle temsil edilmektedir. Bu çalışmada, uzaklık metriđ i olarak en küçük karesel hata yaklaşı mını kullanılmış tır. Hedefe ait görünüm modelinin güncellenmesinde ise zamanla hafızada tutulan en uygun aday görünümlere ait özel noktaların ortalaması alınmış tır.

[86]'da PS temelli hedef takip yaklaşı mını önerilmiş tir. Bu yaklaşımda nesne görünümleri ODB'ler ile modellenmiş tir. Önceki çalışmalara benzer şekilde PS'de kullanılan olabilirlik fonksiyonu, referans ODB ile aday ODB'ler arasında hesaplanan uzaklık metriđ ine bađ lı Gauss PDF formunda tanımlanmış tır. Bu çalışmanın katkısı, hedef nesneye ait görünüm modelinin güncellenmesinin uyarlamalı bir şekilde gerçekleştirilmesidir. Sahnede takip edilen hedefin örtüşmeye maruz kalması durumunda görünüm modelinin güncelleme iş lemi, örtüşmeye maruz kalmadan önceki görünüm modeline bađ lı olarak gerçekleştirilmektedir.

[87]'de önerilen ODB temelli hedef takibinde, PS yerine Monte Carlo yaklaşı mını kullanılmış tır. Bu yaklaşımda takip edilen hedef hareketinin, 2 boyutlu Gauss formunda olduđu varsayılmış tır. Gauss dağılımının ortalama deđ eri, takip edilen hedefin bir önceki çerçevedeki konumuna, ortak deđ iş intisi ise hedefin hızına karşılık gelmektedir. Hedefin konumunu kestirmek için kullanılan Gauss dağılı mını, benzer şekilde hedefin boyutu için de tanımlanmış tır. Bununla birlikte, model güncelleme iş lemi, referans ODB ile aday ODB'ler arasında hesaplanan uzaklıđ a bađ lı olarak yapılmaktadır.

[88]'de çevrit temelli hedef takip yaklaşı mını önerilmiş tir. Referans ve aday görünüm modelleri olarak ODB'lerin kullanıldıđ ı bu yaklaşımda, uzaklık metriđ i olarak Log-Öklid yaklaşı mını tercih edilmiş tir. En küçük enerji fonksiyonuna sahip çevriti bulmak için ODB'ler kullanılmış tır.

[89]'da hedef betimleyicisi olarak ODB kullanılmış ve kademeli LogitBoost algoritması kullanılarak hızlı bir şekilde insan tespiti önerilmiştir. Bu çalışmanın [68]'de önerilen yaklaşıma göre katkısı, hedef nesnenin görünüm özelliklerinin yanında, nesnenin ön plan bilgisinin de LogitBoost sınıflandırmasına dahil edilmesidir. Bununla birlikte, ODB'ye ait ortalama öznitelik vektörü, zayıf sınıflandırıcının girişine ilaveten uygulanmıştır.

[90]'da farklı öznitelik vektör seçenekleriyle oluşturulan ODB'lerin, hedef tespiti üzerindeki başarımı değerlendirilmiştir. Bu çalışmada, SIFT betimleyicisi ve Fourier dönüşümü sonrası elde edilen genlik ve faz bilgileri, öznitelik vektörü olarak ODB'ye dahil edilmiştir. Hedef takibinde en uygun aday bölgenin belirlenmesi, en kısa uzaklık değerine sahip aday bölgenin seçilmesi yerine, belirli ölçütler altında yeniden hesaplanmaktadır.

[91]'de ODB kullanılarak önemli nokta haritası (saliency point map) oluşturulmuştur. Bu haritadaki her bir değer, imgedeki ilgili piksel etrafında hesaplanan ortak değişinti matrisine bağlı olarak hesaplanmıştır. Diğer bir ifadeyle, önemli noktalara ait değerler, merkez piksel etrafında elde edilen bilgi miktarıyla doğru orantılı olarak değişmektedir. Elde edilen bilgi miktarına bağlı olarak, aday bölge ile bu bölge etrafındaki bilgi miktarı arasındaki farkların en büyüğünü bulacak arama algoritması gerçekleştirilmiştir.

[92]'de hedefe ait görünüm modeli için tek bir ODB kullanmak yerine çok ölçekli ODB'nin kullanılması önerilmiştir. Çok ölçekli ODB için dörtlü ağaç yapısı tercih edilmiştir. Dörtlü ağaç yapısı, çok seviyeli bir yapı olup farklı ölçeklerde imge özelliklerinin çıkartılmasında kullanılmıştır.

[93]'te PS temelli olasılıksal hedef takibi önerilmiştir. Hedefe ait görünüm modelinin ODB ile temsil edildiği bu yaklaşımda, görünüm modelinin güncellenmesi Riemannian manifoldu yerine Öklid uzayında gerçekleştirilmiştir. Görünüm modelinin güncellenmesi artımsal olarak yapılmakta, bu sayede gerçek zamanlı bir görsel takip mümkün olmaktadır.

[94]'te önerilen yaklaşımda, [79]'da gerçekleştirilen artımsal Log-Öklid Riemannian alt-uzay öğrenme algoritmasına ek olarak, tekli ve çoklu hedef takip yaklaşımı

önerilmiştir. Hedef görünüm bölgesi, birçok alt bölgeye ayrılmış ve her bir alt bölge için Log-Öklid Riemannian alt uzay modeli, çevrim içi öğrenme yapısına sahiptir.

[95]'te, özellikle büyük boyutlu nesnelere için hesaplanan bölgesel ODB'lerin daha hızlı bir şekilde oluşturulması için farklı bir yaklaşım önerilmiştir. ODB hesabında öznitelik vektörleri, hedef nesne bölgesindeki tüm pikseller yerine önemli noktalara karşılık gelen pikseller üzerinden seçilmiştir. Önemli noktaların bulunmasında, Hessian matrisinin özdeğerleri incelenmektedir.

[96]'de seyrek gösterim temelli görsel takip yaklaşımı önerilmiştir. Hedef bölge, birbirleriyle örtüşmeyen alt bölgelere ayrılarak, her bir alt bölge için ortak değişinti matrisi oluşturulmuştur. Ortak değişinti matrisleri, Log-Öklid uzayında vektörel bir biçimde ifade edilerek seyrek gösterim yaklaşımı kullanılmıştır. Bununla birlikte, hedef görünümünün zamanla güncellenmesi için 3 farklı yaklaşım belirlenmiş, güncelleme esnasında hangi yaklaşımın seçileceği uyarlamalı bir şekilde tespit edilmiştir.

Ortak değişinti betimleyicilerinde kullanılan öznitelik sayısı ve türü, görsel hedef takibin performansını ve hesapsal yükünü etkilemektedir. [97]'de, genetik algoritma yaklaşımıyla hedef nesnenin karakteristik özelliklerinin en az sayıda öznitelik kullanarak belirlenmesi amaçlanmıştır.

## 4.ORTAK DEĞİŞİNTİ BETİMLEYİCİLERİ İÇİN İYİLEŞTİRİLMİŞ BENZEMEZLİK ÖLÇÜTÜ

### 4.1. Giriş

Standart BODB temelli hedef takibinde (SBODB) [61], takip edilen hedefe benzeyen en uygun hedef nesnenin bulunmasında Forstner uzaklık metriği kullanılmıştır. Hedef görünümünü temsil eden ortak değişinti betimleyicinin güncellenmesinde ise Lie cebir/ Lie grup yapısı kullanılmıştır. BODB'lerin takip edilen hedefi diğer hedeflerden ayırt edecek bir yapıda olması, hedef takip performansını doğrudan etkilemektedir.

BODB'lerde, diğer bir ifadeyle ortak değişinti matrisinde, her bir öznitelik vektörünün değişintisi ve öznitelik vektörleri arasındaki ilintiyi, sıfır ortalamalı bir dağılımla ifade edilmektedir. Sıfır ortalamalı dağılıma sahip bir BODB, takip ortamında meydana gelebilecek ışıklılık değişimine karşı hedef takip performansı açısından dayanıklı bir yapıya sahiptir.

Hedefe ait görünüm modeline karşılık gelen BODB, yapısında bulundurduğu öznitelik vektörlerinin, ortalamalarından ne kadar bir sapma gösterdiği ve öznitelik vektörleri arasındaki ilişkilerle ilgilenmektedir. BODB, kompakt bir yapıda olmasına rağmen, içerisinde öznitelik vektörlerinin ortalamasına ait bir bilgi bulunmamaktadır. Dolayısıyla, hedef takibinde Forstner benzemezlik ölçütüne göre referans BODB ile aday BODB'ler arasında uzaklık hesabı yapılırken, öznitelik vektör ortalamalarının karşılaştırılması göz ardı edilmektedir. Diğer yandan, BODB'ler için uzaklık hesabının Öklid uzayında gerçekleştirildiği durumlarda, Öklid uzayında kullanılan benzemezlik ölçütüne ortalama öznitelik vektörlerinin de dahil edildiği yaklaşımlar mevcuttur [80,85].

Tez kapsamında önerilen özgün yaklaşımlardan ilki, Forstner benzemezlik ölçütünün iyileştirilmesidir. Buna göre, iyileştirilmiş uzaklık ölçütüne, öznitelik vektörlerinin dağılımlarının yanı sıra ortalama değerleri de dahil edilmiştir.

## 4.2. Forstner Benzemezlik Ölçütünün İyileştirilmesi

SBODB yaklaşımında referans bölgeye ait öznelik vektörlerinin dağılımına benzer birden fazla aday bölge olması durumunda hedef takibinin başarımlı azalabilmektedir. Bunun nedeni, BODB'ler arasında benzemezlik ölçütü olarak kullanılan Forstner metriğinin, sadece öznelik vektörlerinin dağılımını dikkate almasıdır.

Şekil 4.1'de görsel veri setlerinden "Crowd" dizisinden alınan bir imge için, Eşitlik (4.1)'de verilen Forstner benzemezlik ölçütü kullanılarak elde edilen olabilirlik haritası gösterilmektedir.

$$\text{dist}(\mathbf{C}_{ref}, \mathbf{C}_{aday}) = \sqrt{\sum_{i=1}^d \log^2 \lambda_i(\mathbf{C}_{ref}, \mathbf{C}_{aday})} \quad (4.1)$$

$\mathbf{C}_{ref}$  ve  $\mathbf{C}_{aday}$  sırasıyla referans ve aday bölgelere ait ortak değışinti matrisine karşılık gelmektedir. Olabilirlik haritası, piksel temellidir. Her bir pikselin olabilirlik değeri, bu piksellere karşılık gelen aday ODB'ler ile imge üzerinde referans bir bölgeyi temsil eden ODB arasında hesaplanmaktadır. Olabilirlik haritasındaki uzaklık değeri, Forstner benzemezlik ölçütünden gelen uzaklık değeriyle ters orantılı olacak şekilde belirlenmiştir. Bunun nedeni, Forstner uzaklık hesabının aynı ODB'ler için 0 değeri vermesidir.



Şekil 4.1. (a) "Crowd" imgesi ve imge üzerinden alınan bir bölge, (b) Forstner uzaklık hesabına göre oluşturulan olabilirlik haritası

Şekil 4.1 (b)'de gösterilen olabilirlik haritasında, referans bölgeye karşılık gelen hedef bölge, diğer bölgelere nazaran daha yüksek genliğe sahiptir. Buna rağmen,

imgede bulunan diğer aday hedeflerin olduğu bölgeler de genellikle düz bir tona sahiptir. Ortalama öznitelik vektöründen bağımsız, Forstner benzemezlik ölçütü ile elde edilen olabilirlik haritasında aday hedef bölgeler de nispeten yüksek genliğe sahiptir.

Tez kapsamında, öznitelik vektörlerinin dağılımları yanında, ortalama değerlerinin de dikkate alındığı iyileştirilmiş bir benzemezlik ölçütü tanımlanmıştır. Bu bağlamda  $\mathbf{C}_{ref}$  ve  $\mathbf{C}_{aday}$  ortak değişinti matrislerine ait  $\boldsymbol{\mu}_{ref}$  ve  $\boldsymbol{\mu}_{aday}$  ortalama öznitelik vektörlerini kullanarak,  $d$  boyutlu karesel Öklid normu Eşitlik (4.2)'de tanımlanmıştır.


$$\text{dist}(\boldsymbol{\mu}_{ref}, \boldsymbol{\mu}_{aday}) = \|\boldsymbol{\mu}_{ref} - \boldsymbol{\mu}_{aday}\|_2^2 = \sum_{i=1}^d (\mu_{ref,i} - \mu_{aday,i})^2 \quad (4.2)$$

$d$ , öznitelik vektörünün boyutunu göstermektedir. Eşitlik (4.2)'de verilen uzaklık hesabı, Eşitlik (4.1)'de verilen uzaklık hesabıyla birarada kullanılarak, gürbüz hedef tespiti ve takibi için Eşitlik (4.3)'te gösterildiği gibi iyileştirilmiş Forstner benzemezlik ölçütü elde edilmiştir.

$$\text{dist}^*(\mathbf{C}_{ref}, \mathbf{C}_{aday}) = \alpha \times \text{dist}(\mathbf{C}_{ref}, \mathbf{C}_{aday}) + (1 - \alpha) \times \frac{\text{dist}(\boldsymbol{\mu}_{ref}, \boldsymbol{\mu}_{aday})}{\beta} \quad (4.3)$$

Eşitlik (4.3)'te gösterilen iyileştirilmiş benzemezlik ölçütünde, Forstner benzemezlik ölçütü ve ortalama öznitelik vektörüne bağlı benzemezlik ölçütü, sırasıyla  $\alpha$  ve  $1 - \alpha$  değerleriyle ağırlıklandırılmıştır. Forstner benzemezlik ölçütünde kullanılan ortak değişinti matrisleri, hedef takip esnasında sahnede meydana gelebilecek ışıklılık değişimlerine karşı gürbüz bir yapıya sahiptir. İyileştirilmiş Forstner benzemezlik ölçütünde, hedef takip performansının ışıklılık değişimlerine karşı olumsuz etkilenmemesi için, ortalama öznitelik vektörlerine bağlı benzemezlik ölçütüne, Forstner benzemezlik ölçütüne göre daha az ağırlık verilmiştir. Diğer yandan,  $\beta$  parametresi düzgeleme (normalization) sabiti olup her iki benzemezlik ölçütünün birbirine yakın dinamik ağırlıklarda olmasını sağlamaktadır.  $\alpha$  ve  $\beta$  parametreleri deneysel olarak sırasıyla 0.9 ve 200 olarak belirlenmiştir.

Şekil 4.2’de “Crowd” imgesi için, Forstner benzemezlik ölçütü ve Eşitlik (4.3)’te verilen iyileştirilmiş Forstner benzemezlik ölçütü kullanarak elde edilen olabilirlik haritaları gösterilmektedir. Şekil 4.2 (a)’da sadece ortak değişinti matrisler kullanılarak elde edilen hedef bölge ve aday bölgelerin olabilirlik haritası gösterilmiştir. Şekil 4.2 (b)’de ise, ortak değişinti matrislerine ek olarak, ortalama öznitelik vektörleri kullanılarak elde edilen hedef bölge ve aday bölgelerin olabilirlik haritası gösterilmiştir. Şekil 4.2 (b) incelendiğinde, hedef bölgeye ait olabilirlik değerlerinin, diğer ön plan olabilirlik değerlerine göre daha yüksek genlikte olduğu açıkça görülmektedir. Oysa ki Şekil 4.2 (a)’da aynı ön plan olabilirlik değerleri, Şekil 4.2 (b)’dekine göre daha yüksek genliğe sahiptir. Bununla birlikte, kısmen yüksek genliğe sahip arka plan olabilirlik değerlerini, arka plan çıkarım yaklaşımlarıyla etkisiz hale getirmek mümkündür. Uygulanabilecek diğer bir farklı yaklaşım ise, piksel temelli öznitelik vektör bilgisine, arka plan/ön plan bilgisinin eklenmesidir.



Şekil 4.2. (a) Forstner benzemezlik ölçütüne göre oluşturulan olabilirlik haritası, (b) önerilen yaklaşıma göre oluşturulan olabilirlik haritası

İyileştirilmiş Forstner benzemezlik ölçütünün başarımını değerlendirmek için görüntü dizilerinde hedef takibi yapılmıştır. Elde edilen başarımlar, SBODB temelli hedef takibiyle elde edilen başarımla karşılaştırılmıştır.

Hedef takibinde hedef, deterministik ve olasılıksal yöntemlerle ayrı ayrı aranmaktadır. Deterministik yöntemde hedef, tam arama yaklaşımıyla bir önceki görüntü çerçevesinde kestirilen hedefin  $\pm 100$  piksel etrafında aranmaktadır. En uygun aday bölge, referans BODB ile aday BODB’ler arasında en kısa uzaklığa sahip bölge olarak belirlenmektedir. Bununla birlikte, en uygun hedef bölge aranırken, hedefte olabilecek ölçek değişikliği de göz önünde bulundurulmuştur. Bu



doğrultuda, hedef mevcut boyutuyla birlikte daha küçük ve daha büyük bölge boyutlarında aranmaktadır. Olasılıksal yöntemde ise PS kullanılmıştır. PS temelli hedef takibinde parçacık sayısı 500'dür. Takip işleminin başlangıç aşamasında ve takip esnasında YÖ işlemi ile güncellenen her bir parçacığa ait ağırlık, eşit olasılıkla dağıtılmıştır.

Parçacıkların üretilmesinde gerekli olan IS yoğunluk fonksiyonu  $q(\mathbf{x}_k^i | \mathbf{x}_{0:k-1}^i, \mathbf{z}_{1:k})$ , durum geçiş olasılığıyla  $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)$  değerlendirilmiştir. Süreç modelinin durum geçiş olasılığıyla ilişkilendirildiği hedef takibinde, süreç modeli olarak doğrusal sabit hızlı hareket modeli kullanılmıştır. Hareket modeline Gauss tipinde gürültü eklenerek aday hedef bölgelerin konumlarını ve boyutlarını temsil eden parçacıkların zenginleştirilmesi sağlanmıştır. Parçacıklar için kullanılan süreç modeli, Eşitlik (4.4)'teki gibidir.

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{q}_{k-1} \quad (4.4)$$

$\mathbf{A}$  matrisi, süreç modelinde kullanılan durum geçiş matrisidir.  $\mathbf{q}_{k-1}$ , süreç modeline eklenen Gauss gürültüsüne karşılık gelmektedir.  $\mathbf{x}_k$  ise durum vektörüne karşılık gelmekte olup Eşitlik (4.5)'te ifade edilmiştir.

$$\mathbf{x}_k = \begin{bmatrix} v_x & \dot{v}_x & v_y & \dot{v}_y & s_x & s_y \end{bmatrix} \quad (4.5)$$

$v_x, \dot{v}_x$  sırasıyla hedef nesnenin x-yönündeki pozisyon ve hız bilgisine,  $v_y, \dot{v}_y$  ise sırasıyla y-yönündeki pozisyon ve hız bilgisine karşılık gelmektedir. Hedefe ait yatay ve düşey boyutlar  $s_x$  ve  $s_y$  değerleriyle ölçeklendirilmektedir. Süreç modelinde kullanılan sıfır ortalamalı Gauss gürültüsünün elde edilmesi ve gürültüye ait ortak değişinti matrisi Eşitlik (4.6)'da gösterilmiştir.

$$\mathbf{q}_{k-1} \sim N(0, \mathbf{Q})$$

$$\mathbf{Q} = \begin{bmatrix} 10^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 4^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 10^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1^2 \end{bmatrix} \quad (4.6)$$

$\mathbf{Q}$  ortak deęişinti matrisinin köşegen bileşenleri, durum vektörünün bileşenleriyle bire bir ilişkilidir. PS'de ölçüm modeli olarak iyileştirilmiş Forstner benzemezlik ölçütü kullanılmıştır. Bu ölçüte baęlı olabilirlik model, Eşitlik (4.7)'de verilmiştir.

$$p(\mathbf{z}_k | \mathbf{x}_k) = \exp\left(-\frac{\text{dist}^*(\mathbf{C}_{ref}, \mathbf{C}_{aday})^2}{2\sigma^2}\right) \quad (4.7)$$

Uzaklık deęerleri daęılımının şiddetini gösteren standart sapma deęeri  $\sigma = 0.5$  'tir.  $\mathbf{C}_{ref}$  ve  $\mathbf{C}_{aday}$  ortak deęişinti matrisleri, sırasıyla referans hedefe ait durum vektörüne karşılık gelen bölge ve aday durum vektörlerine karşılık gelen bölgeler için hesaplanmaktadır.

Önerilen yaklaşımda, SBODB temelli nesne takip yöntemine paralel olarak hareketli kamera görüntüleri için  $x$ ,  $y$  piksel koordinatları, R, G, B renk kanalları ve 1. dereceden yatay ve dikey gradyanları içeren 7 boyutlu öznitelik vektörleri kullanılmıştır. SBODB yöntemine paralel olarak, öznitelik vektörlerine duraęan kamera görüntüleri için ayrıca çerçeve fark bilgisi eklenmiştir.

Takip edilen hedefe ait ortak deęişinti matrisinin zamanla güncellenmesinde, SBODB temelli yöntemde olduęu gibi hafızada tutulan ve takip esnasında gemiş çerçevelerde kestirilen en uygun adaya ait ortak deęişinti matrisleri kullanılmıştır. Model güncelleme işlemleri, Lie cebir/ Lie grup temellidir. Hafızada tutulan ortak deęişinti matris sayısı 40'dır.

Önerilen yaklaşımda, hedefe ait bölgesel ortak deęişinti betimleyicilerin hızlı bir şekilde hesaplanabilmesi için tümlev imge gösterim yöntemi kullanılmıştır. Takip edilen hedefler, takip işleminin başlangıç aşamasında el yardımıyla belirlenmiştir.

### 4.3. Önerilen Yöntemin Nesnel Başarımı

Önerilen yöntemin nesnel başarımını değerlendirmek için sabit ve hareketli arka plan içeren görüntü dizileri kullanılmıştır. Başarım karşılaştırmasında [61]'de önerilen yöntem (SBODB) referans olarak alınmıştır.

Tablo 4.1'de farklı görüntü dizileri için referans yöntem ile önerilen yöntemle ait hedef takip hatalarının ortalama ve standart sapma değerleri verilmiştir. Tabloda belirtilen değerler, tam arama yaklaşımı kullanarak elde edilmiştir. Hedef takip hata değerleri Öklid uzaklığı kullanarak hesaplanmıştır. Tablo 4.1'e göre önerilen yöntem, referans yöntemle göre genellikle daha yüksek bir hedef takip performansına sahiptir. Bununla birlikte, önerilen yöntem ile referans yöntem "Crowd" ve "Subway" dizilerinde benzer hedef takip performansı sergilemektedir.

Tablo 4.1. Farklı görüntü dizileri için tam arama yaklaşımına göre referans yöntem ile önerilen yöntemle ait hedef takip hatalarının ortalama ve standart sapma değerleri

Görüntü Dizileri	Referans Yöntem		Önerilen Yöntem	
	Ortalama Hata	Standart Sapma	Ortalama Hata	Standart Sapma
Jogging1	8.57	12.40	6.41	4.61
Jogging2	6.86	12.36	8.08	7.80
Race1	11.50	6.57	5.33	3.36
Reenter1 front	7.94	6.90	5.90	3.78
Crowd	2.56	1.41	3.72	1.71
Subway	5.06	3.85	5.09	3.79
Couple	20.26	39.95	17.52	26.32

Tablo 4.2'de, hedefe ait dinamik sistem modelinin PS ile belirlendiği, referans ve önerilen yöntem ile elde edilen hedef takip sonuçları verilmiştir. Tablo 4.2'de verildiği gibi önerilen yöntem ile elde edilen hedef takip sonuçları genel olarak referans yöntemle göre daha düşüktür. "Crowd" dizisinde, referans hedef bölgesine benzer karakteristik özellik gösteren aday bölge sayısı düşüktür. Karmaşık bir arka plan içermeyen bu görüntü dizisinde, önerilen yöntemin hedef takip başarımı referans yöntemle bir üstünlük sağlamamasına karşın, benzer başarımlar elde edilmektedir.

Tablo 4.2. Farklı görüntü dizileri için olasılıksal arama yaklaşımına göre referans yöntem ile önerilen yönteme ait hedef takip hatalarının ortalama ve standart sapma değerleri

Görüntü Dizileri	Referans Yöntem		Önerilen Yöntem	
	Ortalama Hata	Standart Sapma	Ortalama Hata	Standart Sapma
Jogging1	6.00	5.50	6.50	4.16
Jogging2	12.20	30.55	6.70	7.63
Race1	9.79	6.52	6.95	3.85
Reenter1 front	11.54	6.61	10.80	7.83
Crowd	1.92	1.10	2.83	1.39
Subway	5.52	4.81	4.64	3.49
Couple	18.78	17.96	16.79	17.76

Önerilen yöntemin nesnel başarımını değerlendirmek için Öklid uzaklığının yanısıra F-ölçütü de kullanılmıştır. Tablo 4.3'te, farklı görüntü dizileri için tam arama yaklaşımına göre referans yöntemle önerilen yönteme ait ortalama F-ölçüt değerleri verilmiştir. Ortalama F-ölçüt değeri, her bir görüntü dizisinin tüm çerçevelerinden elde edilen F-ölçüt değerlerinin ortalamasına karşılık gelmektedir. Tablo 4.3'te belirtildiği gibi, önerilen yöntem genel olarak referans yönteme göre daha yüksek başarımlıdır. Referans yöntem ile önerilen yöntemin F-ölçütüne göre başarımı, tüm görüntü dizilerinde yer yer tam örtüşme ve yarı örtüşme anlarının olması ve takip edilen hedefte ölçek değişikliğinin görülmesinden dolayı çok yüksek olmamaktadır. Bu doğrultuda, önerilen yöntem ile referans yöntemde tüm görüntü dizileri için ortalama F-ölçüt değeri 0.75 civarındadır.

Tablo 4.4'te ise farklı görüntü dizileri için olasılıksal arama yaklaşımına göre referans yöntemle önerilen yönteme ait ortalama F-ölçüt değerleri verilmiştir. Olasılıksal arama yaklaşımında da önerilen yöntem, referans yönteme göre genel olarak daha yüksek hedef takip başarımı sergilemektedir. Bununla birlikte "Couple" dizisi gibi ani hareketin görüldüğü görüntü dizilerinde ortalama F-ölçüt değeri, her iki yöntemde de düşük çıkabilmektedir. Bunun nedeni, PS yaklaşımında kullanılan örnek sayısının az olması ya da örneklerinin dağılımından dolayı parçacıkların hedef bölgeyi karşılayamamasıdır.

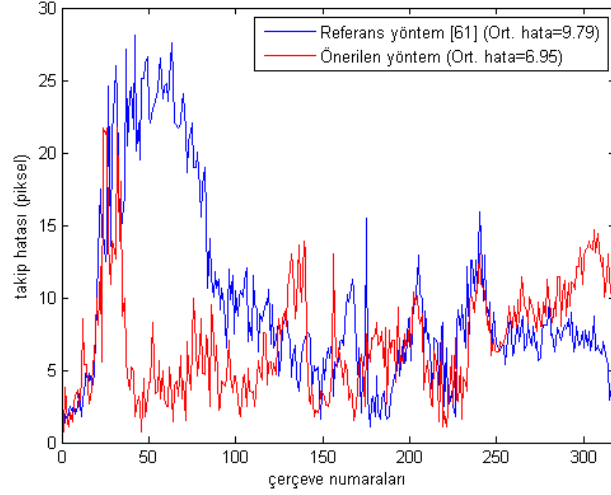
Tablo 4.3. Farklı görüntü dizileri için tam arama yaklaşımına göre referans yöntem ile önerilen yönteme ait ortalama F-ölçüt değerleri

Görüntü Dizileri	Referans Yöntem	Önerilen Yöntem
Jogging1	0.8235	0.8119
Jogging2	0.8398	0.8427
Race1	0.6758	0.7599
Reenter1 front	0.6699	0.6912
Crowd	0.8228	0.7718
Subway	0.7626	0.7849
Couple	0.6833	0.6969

Tablo 4.4. Farklı görüntü dizileri için olasılıksal arama yaklaşımına göre referans yöntem ile önerilen yönteme ait ortalama F-ölçüt değerleri

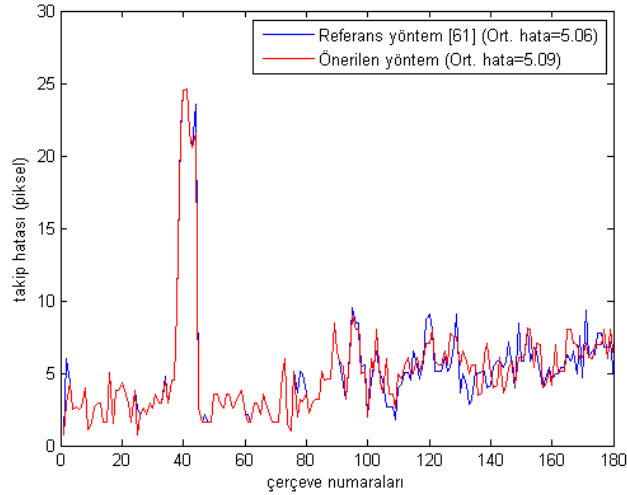
Görüntü Dizileri	Referans Yöntem	Önerilen Yöntem
Jogging1	0.8361	0.8124
Jogging2	0.7925	0.8299
Race1	0.6722	0.7464
Reenter1 front	0.6337	0.6777
Crowd	0.8358	0.8214
Subway	0.7606	0.7719
Couple	0.5349	0.5816

Şekil 4.3'te "Race1" dizisi için önerilen yaklaşıma ait PS temelli hedef takibi ile referans yönteme göre elde edilen hedef takibinin başarımları karşılaştırılmıştır. Görüntü dizisinin büyük bir bölümünde önerilen yaklaşım ile hedef nesne daha iyi takip edilmiştir. Önerilen yaklaşım, görüntü dizisinin son bölümlerinde referans yönteme göre daha düşük bir performans sergilemektedir. Bu durum, hedef görünümünün modellenmesinde kullanılan ortak değişinti matrislerin, kameradan uzaklaşan hedefte oluşan ölçek değişiminden dolayı hedefi iyi modelleyememesinden kaynaklanmaktadır. Hedefin giderek küçülmesi sonrasında kestirilen hedef bölgesi, gerçek hedef bölgesine nazaran daha geniş bir alanı kaplamakta, dolayısıyla arka plan bilgisi içermektedir. Arka plan bilgisi, ortalama öznitelik vektörlerin karşılaştırılmasında kullanılan uzaklık hesabına olumsuz yönde etki etmektedir.



Şekil 4.3. “Race1” dizisi için PS temelli nesne takibinde referans yöntem ile önerilen yöntemde elde edilen hedef takip hata performansları


Şekil 4.4’te “Subway” dizisi için elde edilen tam arama temelli hedef takip performansı gösterilmiştir. Her iki yöntemde, hedef takip hata değerleri tüm çerçeve boyunca birbirine yakın değerlerdedir. Görüntü dizisinin 40. çerçeve anlarında, hedef nesne kısmi örtüşmeye maruz kalmaktadır. Her iki yöntem de, kısa bir süre sonra bu örtüşmeyi atlatarak, hedefi takip etmeye devam etmektedir.



Şekil 4.4. “Subway” dizisi için tam arama temelli nesne takibinde referans yöntem ile önerilen yöntemde elde edilen hedef takip hata performansları


Şekil 4.5 (a) ve (b)’de “Crowd” dizisi için sırasıyla önerilen yöntem ile SBODB yöntemin tam arama ve PS temelli hedef takip performansı gösterilmiştir. Görüntü

dizisinde takip edilen hedef düzgün bir harekete sahip olup, sahnede hedefe benzer düşük sayıda aday bölge bulunmaktadır. Gerek tam arama temelli gerekse PS temelli hedef takibinde, önerilen yöntem ile SBODB yöntemin başarımları tüm çerçeve boyunca birbirine yakındır.



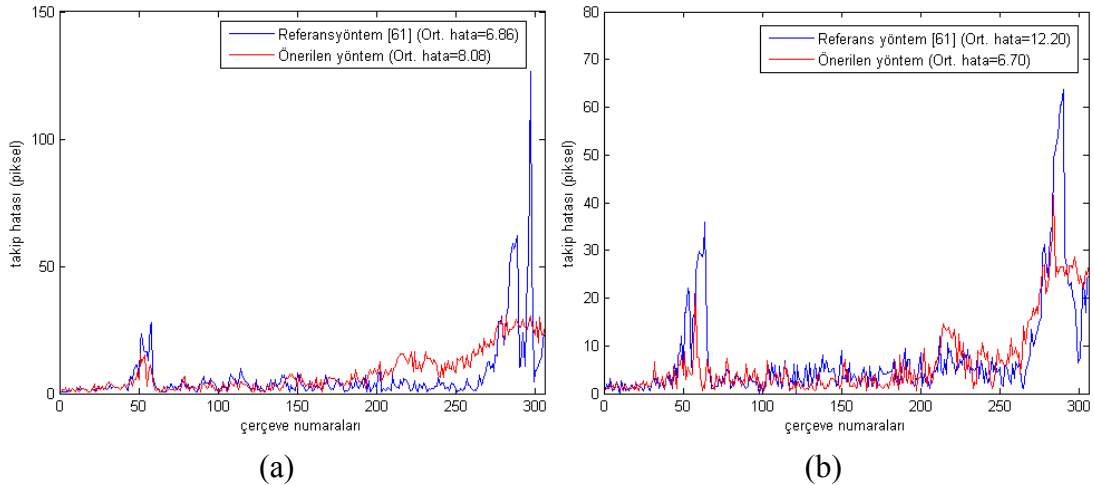
Şekil 4.5. “Crowd” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma

Şekil 4.6 (a) ve (b)’de “Jogging1” dizisi için sırasıyla önerilen yöntem ile SBODB yöntemin tam arama ve PS temelli hedef takip başarımları verilmiştir. Dizinin yaklaşık 75. çerçevesinden sonra görülen kısa süreli tam örtüşme durumundan dolayı, her iki yöntemin tam arama veya PS temelli arama yaklaşımlarında düşük performans görülmektedir. Buna rağmen her iki yöntem de, hedefi örtüşme sonrasında takip etmeye devam etmektedir. Şekil 4.6 (a)’da dizinin sonlarına doğru, önerilen yöntemin başarımlarını SBODB yöntemine göre nispeten düşük olsa da, önerilen yöntem genel olarak SBODB yöntemine göre daha iyi bir performans sergilemektedir. Şekil 4.6 (b)’de PS temelli karşılaştırmada ise, her iki yöntem genel olarak benzer hedef takip performansları göstermektedir. Dizinin sonlarında, sınırlı sayıda olan parçacıkların temsil ettiği konum ve boyut bilgileri için hesaplanan olabilirlik modeli, önerilen yöntemde SBODB yöntemine göre daha yüksektir. Bu nedenle, önerilen yöntem sayesinde hedef, daha düşük bir hedef takip hatasıyla takip edilmektedir.



Şekil 4.6. “Jogging1” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma

Şekil 4.7 (a) ve (b)’de “Jogging2” dizisi için sırasıyla önerilen yöntem ile SBODB yöntemin tam arama ve PS temelli hedef takip başarımları verilmiştir. Şekil 4.7 (a)’da verilen tam arama temelli karşılaştırmada, önerilen yöntem özellikle dizinin sonlarına doğru SBODB yöntemine göre daha üstün performans sergilemektedir. Önerilen yöntem sayesinde dizinin sonlarında görülen hedefe benzer aday bölgeler başarıyla elenmekte ve hedef başarıyla takip edilmektedir. Benzer durum, Şekil 4.7 (b)’de gösterilen PS temelli karşılaştırma için de geçerlidir. Şekil 4.7 (b)’de önerilen yöntemin başarımları açıkça görülmektedir.




Şekil 4.7. “Jogging2” dizisi için önerilen yöntem ile SBODB yöntemin nesne takip performansı (a) tam arama temelli karşılaştırma, (b) PS temelli karşılaştırma

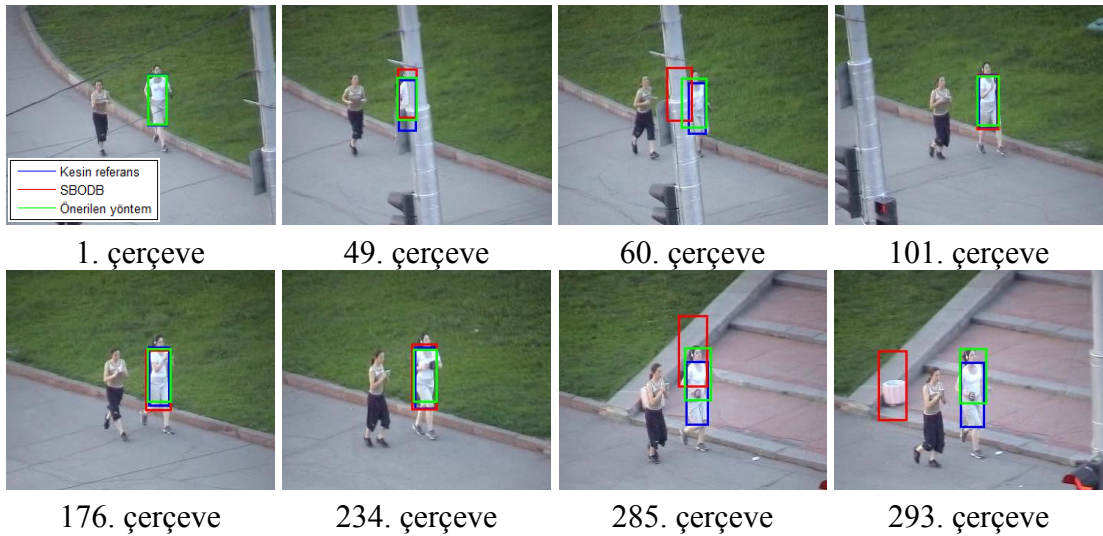




performansında, önerilen yöntemin SBODB yöntemine göre üstünlüğü açıkça görülmektedir. Önerilen yöntem sayesinde, tam örtüşme olayının bittiği 60. çerçeve civarında daha iyi bir hedef eşleştirme yapılmıştır. Bununla birlikte görüntü dizisinin sonlarında, takip edilen hedef bölgeye benzer bölgelerin olduğu sahnede, önerilen yöntem SBODB yöntemine göre daha yüksek başarı sağlamaktadır.



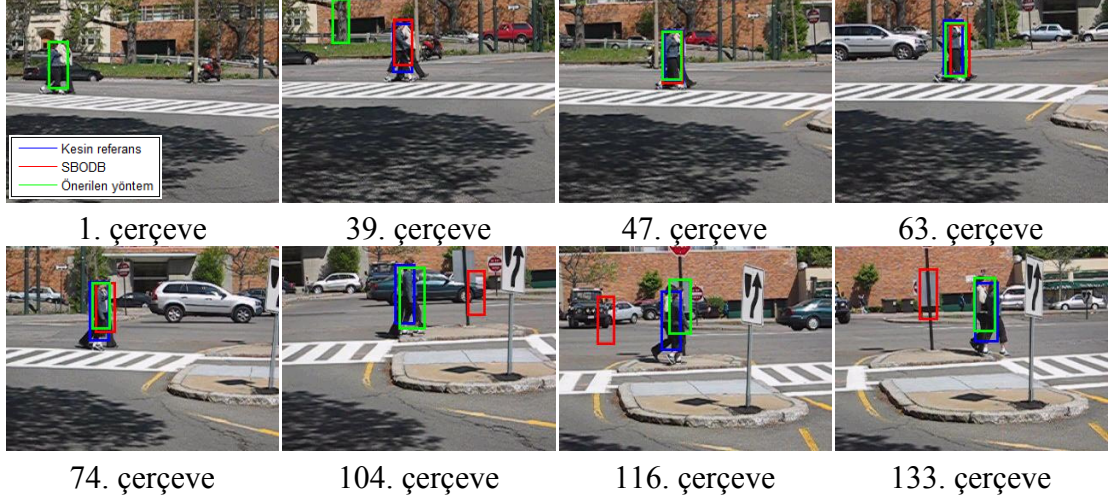
Şekil 4.9. “Jogging1” dizisi için SBODB yöntem ile önerilen yöntemin PS kullanarak elde edilen görsel takip performansları



Şekil 4.10. “Jogging2” dizisi için SBODB yöntem ile önerilen yöntemin PS kullanarak elde edilen görsel takip performansları

Şekil 4.11’de, “Couple” dizisi için önerilen yöntem ile SBODB yönteminin görsel takip performansı verilmiştir. Ani kamera hareketlerinin olduğu bu görüntü dizisinde, önerilen yöntem sayesinde hedef, SBODB yöntemine göre daha başarılı bir şekilde

takip edilmiştir. Bununla birlikte, bazı görüntü sahnelerinde (örneğin 39. çerçeve) önerilen yaklaşım hatalı hedef tespiti yapmıştır. İyileştirilmiş benzemezlik ölçütünde, parametrelerin deneysel yolla seçilmesi, bu görüntü dizisinde olduğu gibi yer yer hatalı tespitlere neden olabilmektedir.



Şekil 4.11. “Couple” dizisi için SBODB yöntem ile önerilen yöntemin tam arama yaklaşımı kullanarak elde edilen görsel takip performansları

#### 4.5. Sonuç

Tez kapsamında önerilen bu yöntemde, ortak değişinti matrislerin karşılaştırılmasında iyileştirilmiş benzemezlik ölçütü önerilmiştir. Hedef nesnelere ait öznitelik vektör dağılımlarının dikkate alındığı Forstner benzemezlik ölçütüne, öznitelik vektörlerin ortalamalarını dikkate alan benzemezlik ölçütü ilave edilerek, hedefler daha gürbüz bir şekilde takip edilebilmektedir. Önerilen yaklaşım, özellikle hedef nesneye benzer karakteristik özellik gösteren sahnelerde, SBODB yöntemine göre daha başarılı bir performans sergilemektedir.

SBODB yönteminde, ortak değişinti matrisinin oluşturulması esnasında, öznitelik vektörlerinin ortalama değerleri de kullanılmaktadır. Bu nedenle, önerilen yöntemin gerçekleştirilmesi için ortalama öznitelik vektörlerinin yeniden hesaplanmasına gerek yoktur. Dolayısıyla önerilen yöntemin hesapsal yükü, SBODB yöntemine kıyasla kayda değer bir artış göstermemektedir.

Ortak değişinti matrisler için önerilen iyileştirilmiş benzemezlik ölçütünde, parametre seçimi deneysel yolla yapıldığından, görüntü dizilerinin bazı

çerçevelerinde hatalı hedef tespiti yapılabilmektedir. En uygun parametre seçimini, uyarlamalı bir şekilde gerçekleştirerek, daha başarılı bir hedef takip algoritması gerçekleştirmek mümkündür.

## **5. GAUSS AĞIRLIKLANDIRMA VE KALMAN SÜZGEÇİ İLE ORTAK DEĞİŞİNTİ TEMELLİ GÜRBÜZ HEDEF TAKİBİ**

### **5.1. Giriş**

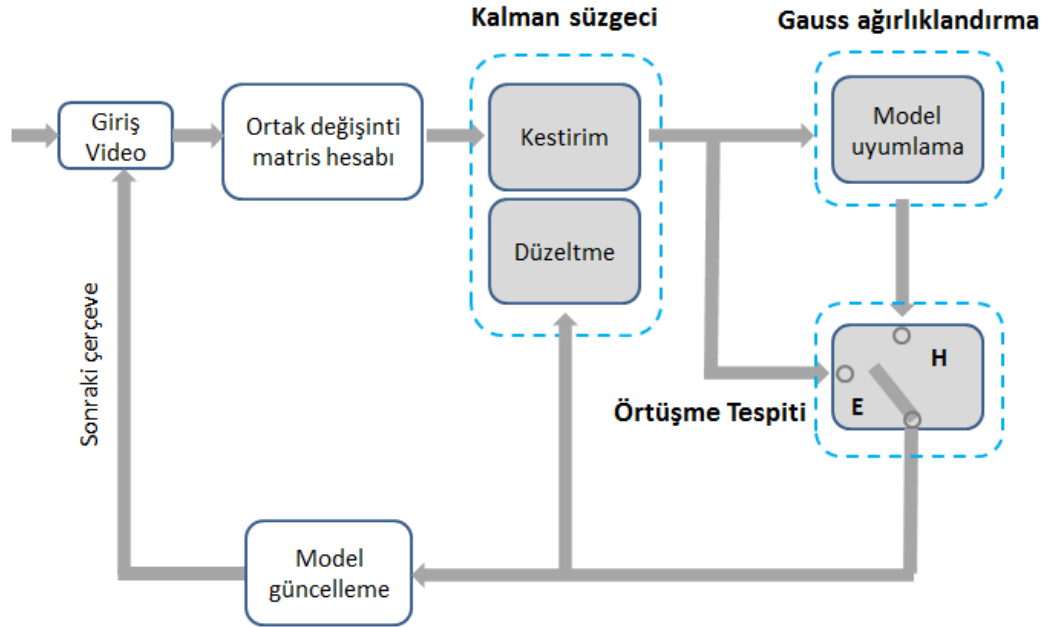
Literatürde, ortak değişinti temelli görsel hedef takibine yönelik birçok çalışma bulunmaktadır. Bu çalışmaların ortak amacı, genel olarak hedef takip performansını arttırmaya ya da görsel hedef takip işleminin gerçek zamanlı çalışabilmesine yönelik yaklaşımlar önermektir.

Bu bölümde tez kapsamında, ortak değişinti temelli gürbüz bir hedef takip yöntemi önerilmektedir. Önerilen yaklaşımın üç temel katkısı bulunmaktadır. İlk katkıda, Gauss tipi ağırlıklandırma fonksiyonu tanımlanarak, bu fonksiyon ortak değişinti matrislerin uzaklık hesabında kullanılmıştır. Diğer bir katkı ise olası hedef bölgesinin belirlenebilmesi için KS'nin hedef takip sistemine entegre edilmesidir. Son olarak da hedef takibinin başarımını arttırmak için, hedef nesneye ait ortak değişinti matrisi ile en uygun aday bölgelere ait ortak değişinti matrisleri arasında hesaplanan uzaklık değerlerine bağlı bir örtüşme tespit yaklaşımı önerilmiştir.

### **5.2. Gauss Ağırlıklandırma ve Kalman Süzgeci ile Hedef Takibi**

BODB temelli yöntemler hedefi, karmaşık arkaplan içeren sahnelerde, örtüşmelerin sık sık yaşandığı durumlarda ve hedef görünümünün ani değişiklik gösterdiği durumlarda, her zaman başarılı bir şekilde takip edemeyebilmektedir. Hatalı bir hedef tespiti veya doğru bir model güncelleme işleminin yapılamaması, hedef takibinde performans kaybına neden olabilmektedir. Referans alınan hedef için oluşturulan BODB, hedef takibinde kendisine ait dağılıma benzer bir dağılıma sahip birden fazla aday hedef bölgesi ile karşılaşabilmektedir. Bu durumda, referans alınan hedefe benzer aday bölgelerin olması, diğer bir ifadeyle en kısa uzaklığa yakın uzaklıkların bulunması durumunda, en uygun BODB'nin tespit edilmesi zor olabilmektedir.

Örtüşme, hedef takip problemlerinde sıklıkla karşılaşılan bir durumdur. Takip esnasında, tam örtüşme ya da yarı örtüşme anlarının görülmesi durumunda ortak değişinti temelli hedef takip yaklaşımları düşük performans sergileyebilmektedir. Hedef bölgenin gösterimi için genellikle çoklu ortak değişinti matrisler kullanılmaktadır. Çoklu ortak değişinti matrislerin kullanımı, takip esnasında görülen yarı örtüşme durumlarında faydalı olmaktadır. Bununla birlikte ortak değişinti temelli yöntemlerde, tam örtüşme anlarının tespiti için uyarlamalı bir kontrol mekanizması kullanılmamakta, buna bağlı olarak model güncelleme işlemi doğru bir şekilde gerçekleştirilememektedir. Ortak değişinti temelli hedef takip yöntemlerinde karşılaşılan bu eksikliklerin üstesinden gelmek için önerilen yöntemin akış şeması, Şekil 5.1’de gösterilmiştir. Önerilen her bir katkı, koyu renkle vurgulanmıştır.



Şekil 5.1. Önerilen yöntemin akış şeması

### 5.2.1. Gauss ağırlıklandırma yaklaşımı


BODB temelli hedef takibinde en uygun aday hedef bölge, referans hedef bölgesine göre en düşük uzaklık değerine sahiptir. Takip ortamında karmaşık sahneler olması durumunda, en uygun aday hedef bölge, en düşük uzaklık değerine sahip olmasına rağmen hatalı tespit edilebilmektedir.

Hedef takibinde, takip edilen hedefe ait geçmiş çerçevelerden elde edilen hareket bilgilerini hesaba katarak, hedefin olası aday bölgelerine daha fazla ağırlık vermek,

hedef takip başarımını arttırmaktadır. Bu doğrultuda, önerilen yöntemde öncelikle ortak değışinti matrisler arasında hesaplanan uzaklık değeri Gauss tipi bir fonksiyonla ağırlıklandırılmıştır. Eş yönlü ve monoton bir şekilde artan Gauss tipi fonksiyon (GTF) Eşitlik (5.1)'de gösterilmiştir.

$$GTF(x, y) = B - G_{2D}(x, y, \sigma) \times (B - S) \quad (5.1)$$

$G_{2D}(x, y, \sigma)$ , iki boyutlu birim yüksekliğe normalize edilmiş Gauss fonksiyonudur.  $S$  ve  $B$  sırasıyla Gauss tipi fonksiyonun minimum ve maksimum genliklerine karşılık gelmektedir. Minimum ve maksimum genlik değeri, tüm görüntü dizilerinde en iyi hedef takip performansı elde edilecek şekilde deneysel yolla belirlenmiştir. Önceden belirlenmiş olan  $\sigma$ , Gauss fonksiyonun standart sapmasıdır. Önerilen yöntemde kullanılan GTF, Şekil 5.2'de gösterilmiştir.



Şekil 5.2. Gauss tipi fonksiyon

Şekil 5.2'de gösterilen  $x$  ve  $y$  yönündeki  $\mu_x$  ve  $\mu_y$  değeri fonksiyon değeri, minimum olmaktadır. Önerilen yöntemde BODB'ler arasında hesaplanan uzaklık değeri,  $GTF(x, y)$  fonksiyonu ile ağırlıklandırılmakta, bu sayede hedefin olabileceği muhtemel yerlere daha fazla ağırlık verilmektedir. Bu yöntem sayesinde, uzaklık değeri kısmen yüksek muhtemel bir aday bölge, uzaklık değeri kısmen düşük fakat muhtemel aday bölge görüntüsünden uzak bölgeye tercih edilecektir.

### 5.2.2. Kalman süzgeci yaklaşımı

Takip edilen hedefe ait önceki çerçevelerden elde edilen bilgilerle, hedefin o anda en iyi ihtimalle hangi pozisyonda olabileceğinin kestirilmesinde KS kullanılmıştır. KS’de, sabit ivme hareket modeli tercih edilmiştir. Hedef takibinde en uygun aday bölge, KS ile kestirilen tahmini aday bölge etrafında hızlı arama yaklaşımıyla aranmaktadır. KS, bilindiği gibi özyineli bir yapı olup kestirim ve doğrulama aşamalarından oluşmaktadır. Önerilen BODB temelli hedef takibinde standart KS yaklaşımı kullanılmış fakat en uygun aday bölgenin aranmasında sadece kestirim aşamasından faydalanılmıştır. k-1 anında durum vektörü bilinen bir sistemin, k anında KS ile durum vektörünün kestirilmesi Eşitlik (5.2)’de verilmiştir.

$$\hat{\mathbf{x}}_k^- = \mathbf{A}_k \hat{\mathbf{x}}_{k-1} \quad (5.2)$$

$\hat{\mathbf{x}}_k^-$ , k anında durum vektörünün önsel kestirimine karşılık gelmektedir.  $\mathbf{A}_k$  ise sistemin durum geçiş matrisidir.  $\hat{\mathbf{x}}_{k-1}$ , k-1 anında, KS’de kestirim ve doğrulama aşaması sonrası elde edilen sonsal durum vektörüne karşılık gelmektedir. Sabit ivme modelinde kullanılan  $\hat{\mathbf{x}}_{k-1}$  durum vektörü Eşitlik (5.3)’te gösterilmiştir.

$$\hat{\mathbf{x}}_{k-1} = \begin{bmatrix} v_x & v_y & \dot{v}_x & \dot{v}_y & \ddot{v}_x & \ddot{v}_y \end{bmatrix}^T \quad (5.3)$$

$v_x, v_y$  sırasıyla hedef nesnenin x-y yönündeki pozisyon bilgisine,  $\dot{v}_x, \dot{v}_y$  sırasıyla x-y yönündeki hız bilgisine,  $\ddot{v}_x, \ddot{v}_y$  ise sırasıyla x-y yönlerindeki ivme bilgisine karşılık gelmektedir.

BODB temelli gürbüz hedef takibinde, hedef KS ile kestirilen konumun etrafında Gauss tipi ağırlıklandırma fonksiyonu ile aranmaktadır.

### 5.2.3. Örtüşme tespiti

BODB temelli önerilen yöntemin bir diğer katkısı ise hedef takibinde görülen örtüşme olaylarının uzaklık hesabına bağlı olarak tespit edilmesidir. Zamansal olarak referans BODB ile en uygun BODB arasında hesaplanan uzaklık değerlerinde ani bir artış görülmesi durumunda, ilgili görüntü dizisinde bulunan en uygun hedef



pozisyonu yerine KS ile kestirilen önsel hedef pozisyonu kullanılmıştır. Önsel hedef pozisyonu, hedefe ait önsel durum vektöründen elde edilmektedir. Bu doğrultuda, özellikle örtüşme anlarında görülen ani uzaklık değerlerindeki artıştan dolayı, KS'den gelen kestirim değerlerini kullanmak, hedef takip performansını arttırmaktadır. Zamana göre önceden belirlenmiş  $M$  adet çevrevede bulunan en uygun uzaklık değerlerinin hareketli ortalaması alınarak, bir eşik değeri belirlenmiştir. Belirlenen eşik değerinden büyük bir uzaklık değeri bulunması durumunda, arama sonrası bulunan pozisyon yerine, KS'den elde edilen önsel kestirime dayalı pozisyon bilgisi, güncel pozisyon bilgisi olarak alınmıştır. Örtüşme tespiti için kullanılan  $k$  anındaki eşik değeri, Eşitlik (5.4)'te ifade edilmiştir.

$$TH_k = Coeff \times \left( \frac{1}{M} \sum_{i=1}^M \text{dist}_{k-i}(Cr_{k-i}, Ct_{k-i}) \right) \quad (5.4)$$

$Coeff$ , deneysel yolla belirlenmiş bir katsayıdır.  $Cr$  ve  $Ct$  sırasıyla  $(k-i)$  anlarında referans ve en uygun aday ortak değişinti matrislerine karşılık gelmektedir.

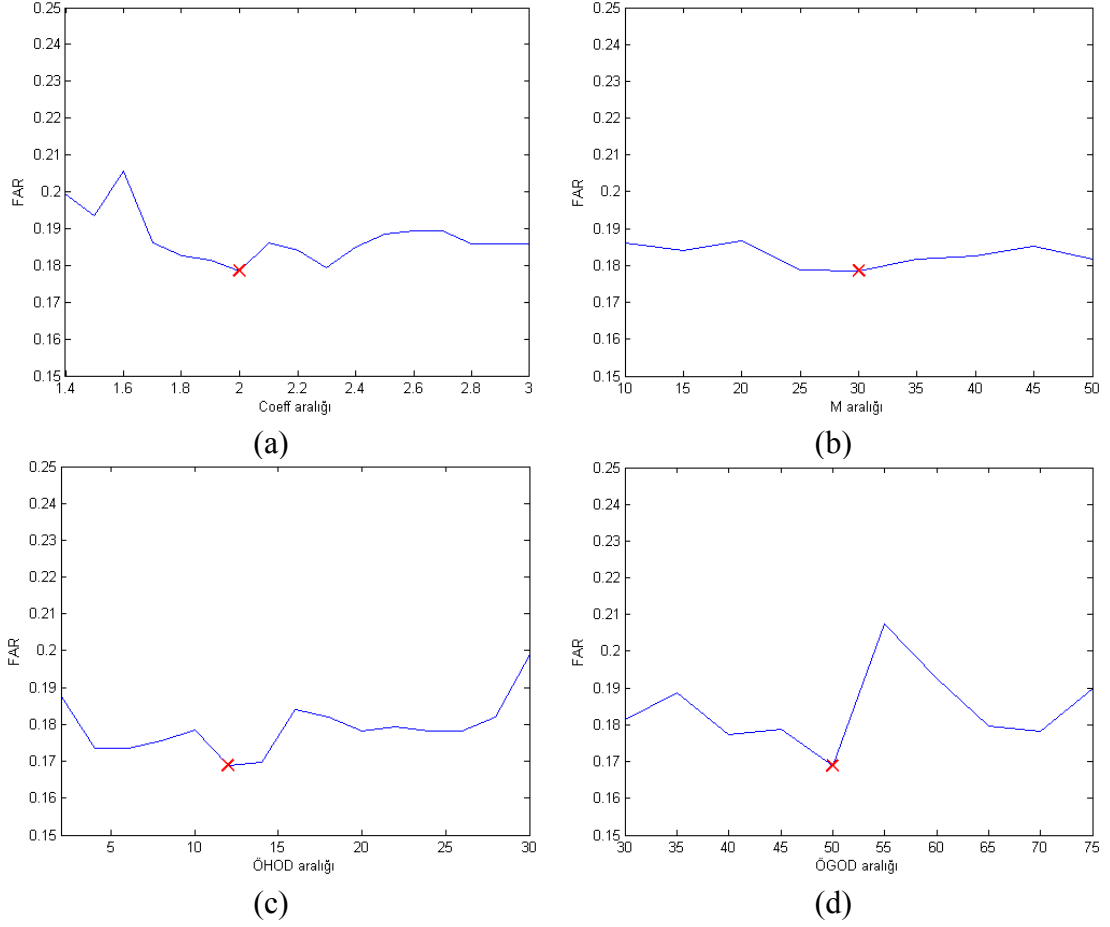
### 5.3. Önerilen Yöntemin Nesnel Başarımı

Önerilen yöntemin başarımını değerlendirmek için tez kapsamında bahsedilen görüntü dizileri kullanılmıştır. Bu yöntemin başarımı, SBODB temelli hedef takip yöntemi (Covariance- COV) [61], BODB temelli Monte Carlo (MC) [87] ve BODB temelli artımsal ortak değişinti tensör öğrenmesi (Incremental Covariance Tensor Learning- ICTL) [93] hedef takip yöntemleriyle karşılaştırılmıştır. Önerilen yöntem ile diğer yöntemlerde tek bir hedef takibi gerçekleştirilmiştir. Takip edilen hedef, başlangıç durumunda el yardımıyla belirlenmiştir.

Uzaklık değerlerinin ağırlıklandırılmasında kullanılan GTF'nin standart sapması,  $\sigma = 50$  olarak belirlenmiştir. Bununla birlikte, bu ağırlıklandırma fonksiyonun minimum ve maksimum değerleri sırasıyla 0.5 ve 1 olarak alınmıştır. Hareketli arka plan görüntüleri için BODB'lerin oluşturulmasında 7 boyutlu öznitelik vektörü kullanılmıştır. Öznitelik vektörleri sırasıyla x-y piksel koordinat değerlerinden, R, G, B renk kanallarından ve x-y yönlerindeki birince dereceden gradyen bilgilerinden oluşmaktadır. Durağan kamera kayıtlarından oluşan görüntü dizileri için, 7 boyutlu öznitelik vektörlerine ayrıca çerçeveler arası fark bilgisi eklenmiştir. En uygun aday

hedef bölge, bir önceki çerçeveden kestirilen hedef bölge etrafında aranmaktadır. Arama penceresi,  $\pm 100$  pikselle sınırlandırılmıştır. Hedef takip işleminin işlem yükünü azaltmak için, her bir piksel için aday bölge oluşturmak yerine yatay ve dikey yönde her dört pikselde bir aday bölge oluşturulmuştur. Model güncelleme işleminde, ortalama ortak değişinti matris hesabı için gerekli olan toplam ortak değişinti matris sayısı, [61]'de önerilen yöntemde olduğu gibi 40 olarak alınmıştır.

Önerilen yöntemde, KS'de ve örtüşme tespitinde kullanılan parametrelerin hedef takip performansına etkisi incelenmiştir. Bu kapsamda, öncelikle KS'de kullanılan önsel hata ortak değişinti (ÖHOD) ve ölçüm gürültü ortak değişinti (ÖGOD) matrislerinin köşegen elemanları ile örtüşme tespitinde kullanılan M çerçeve sayısı sabit bir değerde tutularak, en uygun *Coeff* değeri (önsel *Coeff*) yanlış alarm oranına (False Alarm Ration- FAR) göre belirli aralıkta incelenmektedir. FAR değeri, tüm veri setlerinde hatalı olarak tespit edilen hedef sayısının, toplam hedef sayısına oranına karşılık gelmektedir. Takip edilen hedeflerin hatalı olarak değerlendirilmesinde, kestirilen hedef konumlarının kesin referans verilerine göre Öklid uzaklıklarına bakılmıştır. Uzaklıkların 20 pikselden fazla olması durumunda, kestirilen hedefler hatalı olarak etiketlenmiştir. En uygun parametre değeri seçimi için bir sonraki aşamada M değerinin en uygun değeri, bir önceki aşamada en düşük FAR değerini veren *Coeff* değeri ile ÖHOD ve ÖGOD parametre değerlerini değiştirmeden FAR'a göre belirlenmektedir. Benzer adımlar, ÖHOD ve ÖGOD parametreleri için gerçekleştirilmiştir. Şekil 5.3'te, sırasıyla *Coeff*, M, ÖHOD ve ÖGOD parametrelerinin FAR değerine göre hedef takip performansları gösterilmiştir. Her bir parametre için kullanılan farklı değerlerde FAR değerleri büyük değişimler göstermemektedir. Bundan dolayı parametre seçiminde, en düşük FAR değerine sahip değerler kullanılmıştır. Bu doğrultuda önerilen yöntemde, *Coeff*, M, ÖHOD ve ÖGOD değerleri sırasıyla 2, 30, 12 ve 50 alınmıştır.




Şekil 5.3. FAR değerine göre parametre eniyilemesi (a) en uyguna yakın *Coeff* seçimi (b) en uyguna yakın *M* seçimi (c) en uyguna yakın *ÖHOD* seçimi (d) en uyguna yakın *ÖGOD* seçimi

En uygun *Coeff* parametresine göre belirlenen diğer parametreler sabit tutularak, *Coeff* parametresi (sonsal *Coeff*) yeniden hesaplanmıştır. Önsel ve sonsal *Coeff* değerleri arasındaki ilişki Şekil 5.4'te gösterilmiştir. FAR sonuçlarından da görüleceği gibi, önceden tanımlanmış aralıkta hesaplanan önsel ve sonsal *Coeff* değerleri birbirlerine yakındır.

Parametre kestirim sonuçlarından elde edilen FAR değerlerine göre hatalı tespit edilen hedeflerin %75'i "Woman" görüntü dizisinden kaynaklanmaktadır. Bu nedenle, Şekil 5.3 ve Şekil 5.4'te görüldüğü gibi tüm veri dizilerinde hedef takip performansı, FAR değerine göre %80 civarındadır. "Woman" dizisi hedef takibine dahil edilmediği durumda elde edilen takip performansı, %95'e çıkmaktadır. MC yönteminde FAR değerine göre elde edilen takip performansı, "Woman" dizisinin

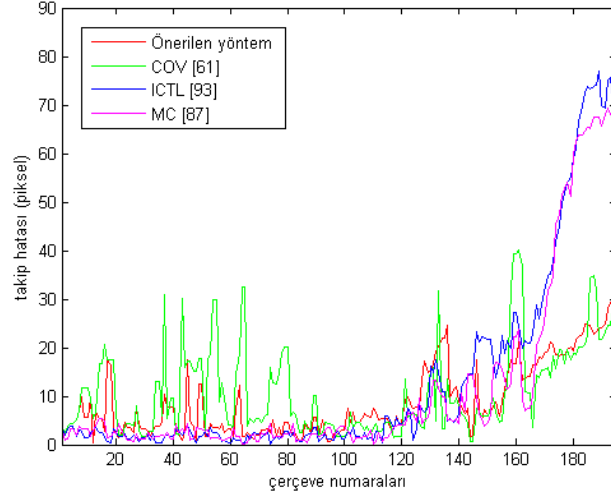
dahil edildiği durumda %77, dahil edilmediği durumda ise %81'dir. Benzer şekilde ICTL yönteminin, takip performansı sırasıyla %63 ve %75'tir.



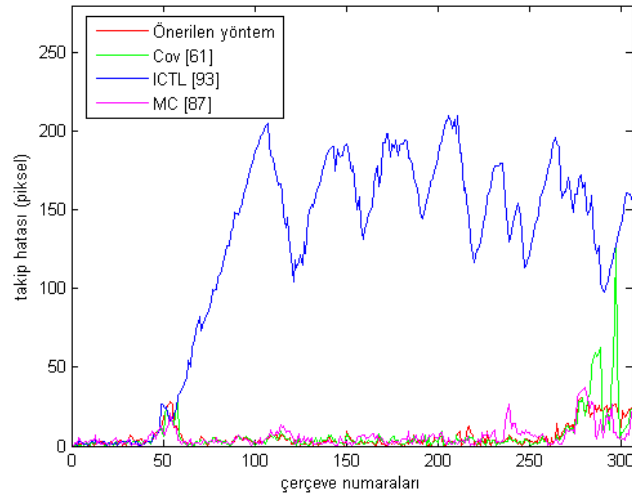
Şekil 5.4. Önsel ve sonsal *Coeff* parametre değerlerinin FAR sonucuna göre karşılaştırılması

Şekil 5.5'te, önerilen yöntem ile COV [61], MC [87] ve ICTL [93] yöntemlerinin "EnterExit1cor" dizisi için hedef takip performansları gösterilmiştir. Önerilen yöntem, KS ve Gauss ağırlıklandırması sayesinde diğer yöntemlere göre genellikle daha düşük hedef takip hatasına sahiptir. Dizinin 165.ci çerçevesine kadar, önerilen yöntem ile MC ve ICTL yaklaşımları birbirlerine yakın takip performansı sergileseler de, bu çerçeveden itibaren MC ve ICTL yaklaşımlarının performansı dramatik bir biçimde azalmıştır. Bu azalmanın nedeni, MC ve ICTL yaklaşımlarında hedef arama işleminin PS ile gerçekleştirilmesidir. PS'de örnek sayısının yetersiz olması ve zamanla gerçekleşen örnek yozlaşması nedeniyle, MC ve ICTL yaklaşımlarının performansı azalmıştır.

Şekil 5.6'da, "Jogging2" dizisi için önerilen yöntem ile diğer yöntemlerde elde edilen hedef takip hataları gösterilmiştir. ICTL yaklaşımı, hedefi örtüşme sonrasında kaybetmektedir. Buna bağlı olarak sınırlı bölgelerde tanımlı parçacıkların, hedefin gerçek yerini karşılayamamasından dolayı hedef tespiti yapılamamıştır. COV yaklaşımı, görüntü dizisinin sonlarına doğru sahnede görülen benzer nitelikteki hedef bölgelerinden dolayı, düşük performans göstermektedir. Önerilen yöntem ile MC yaklaşımı hedefi başarıyla takip etmiştir. Bununla birlikte hedef takibinde, önerilen yöntem MC yaklaşımına göre nispeten daha yüksek başarımlar sağlamıştır.

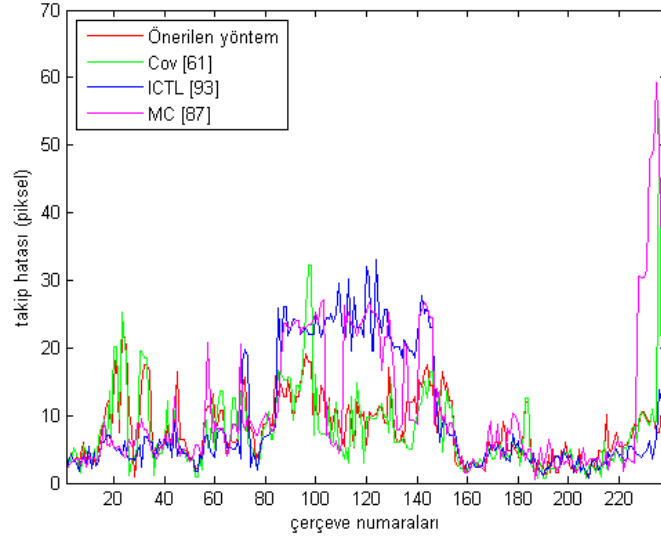


Şekil 5.5. “EnterExit1cor” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı



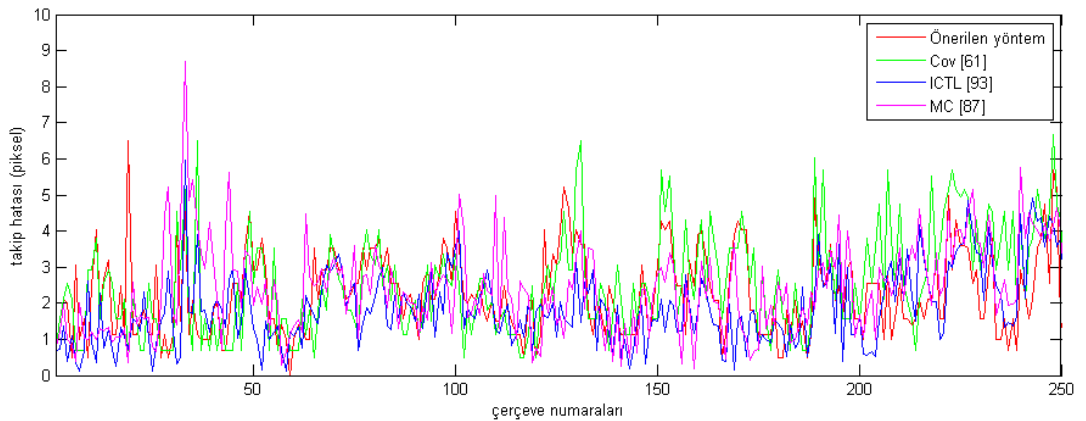
Şekil 5.6. “Jogging2” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı

“Reenter1front” dizisi için önerilen yöntem ile diğer yöntemlerin hedef takip performansları Şekil 5.7’de gösterilmiştir. Şekil 5.7’de, önerilen yöntemin diğer yöntemlere göre hedef takip başarımı, açıkça görülmektedir. Bununla birlikte önerilen yöntem, sahnede özellikle hedef görünümüne benzer nesnelerin görüldüğü durumlarda COV yöntemine göre daha düşük takip hatası vermektedir.



Şekil 5.7. “Reenter1front” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı

Şekil 5.8’de “Crowd” dizisi için önerilen yöntem ile diğer yöntemlerin hedef takip performansları verilmiştir. Tüm yöntemlerde hedef, düşük takip hatasıyla başarıyla takip edilmektedir. Bu görüntü dizisinde takip edilen hedef, takip süresince örtüşmeye maruz kalmamaktadır. Bu doğrultuda, önerilen yöntemde kullanılan örtüşme tespiti aktif olmamakta, hedefi hatalı bir şekilde izlemenin önüne geçmektedir. Benzer şekilde, önerilen yöntemde kullanılan KS ve GTF yaklaşımları hedef takibinin performansını olumsuz etkilememektedir.



Şekil 5.8. “Crowd” dizisi için önerilen yöntem ile COV, ICTL ve MC yaklaşımlarının hedef takip performansı.

Tablo 5.1 ve Tablo 5.2, sırasıyla durağan ve hareketli kamera görüntülerinde Öklid uzaklığına göre elde edilen hedef takip hata sonuçlarının ortalama (ORT) ve standart

sapma (SS) değerlerini göstermektedir. Tablo 5.1’de önerilen yöntem, hedef takibinin nispeten daha kolay yapıldığı “Subway” ve “Crowd” görüntü dizilerinde diğer yaklaşımlar ile karşılaştırıldığında benzer bir hedef takip performansı sergilemektedir. Bununla birlikte önerilen yöntem, ortalama ve standart sapma değerleri açısından diğer yaklaşımlara göre genel olarak daha iyi bir performans göstermektedir.

Tablo 5.1. Durağan kamera kayıtları içeren görüntü dizilerinde Öklid uzaklığına göre elde edilen hedef takip hatalarının ortalama ve standart sapma değerleri

	Crowd		EnterExit1cor		Subway		Renter1front	
	ORT.	SS.	ORT.	SS.	ORT.	SS.	ORT.	SS.
COV [61]	2.56	1.41	11.05	9.18	5.06	3.84	7.94	6.90
ICTL [93]	1.88	1.07	13.31	20.71	5.15	3.59	9.78	8.65
MC [87]	2.40	1.26	11.61	19.07	123.8	83.72	11.05	10.29
Önerilen Y.	2.27	1.16	8.88	7.46	3.99	4.13	8.08	4.65

Tablo 5.2’den görüldüğü gibi, önerilen yöntem, hemen hemen tüm görüntü dizilerinde daha düşük ortalama ve standart sapma hatasına sahiptir. Özellikle “Couple” ve “Woman” görüntü dizilerinde, önerilen yöntem diğer yöntemlere nazaran üstün bir hedef takip performansı sergilemektedir. Bununla birlikte, MC ve ICTL yaklaşımları, “Jogging1” ve “Jogging2” dizilerinde hedefi, tam örtüşme durumundan dolayı kaybetmektedir.

Tablo 5.2. Hareketli kamera kayıtları içeren görüntü dizilerinde Öklid uzaklığına göre elde edilen hedef takip hatalarının ortalama ve standart sapma değerleri

	Couple		Jogging1		Jogging2		Woman	
	ORT.	SS.	ORT.	SS.	ORT.	SS.	ORT.	SS.
COV [61]	20.26	39.95	8.58	12.40	6.76	12.36	62.80	46.91
ICTL [93]	14.35	16.85	8.15	5.52	124.5	66.31	32.44	26.42
MC [87]	16.46	19.82	90.10	51.82	6.02	6.39	110.6	75.24
Önerilen Y.	7.79	5.30	7.25	4.02	6.00	7.19	26.42	13.80

Tablo 5.3 ve Tablo 5.4, sırasıyla durağan/hareketli kamera görüntülerinde F-ölçütüne göre elde edilen ortalama hedef takip hata değerlerini göstermektedir. Tablo 5.3’te

gösterildiği gibi hedefler, önerilen yöntem sayesinde genel olarak daha yüksek başarımla takip edilmektedir.

Tablo 5.3. Durağan kamera kayıtları içeren görüntü dizilerinde F-ölçütüne göre elde edilen ortalama hedef takip hata değerleri

	Crowd	EnterExit1cor	Subway	Renter1front
COV [61]	0.8228	0.7716	0.7626	0.6699
ICTL [93]	0.8403	0.7320	0.7642	0.6532
MC [87]	0.7834	0.7394	0.1753	0.5769
Önerilen Y.	0.8303	0.7887	0.7735	0.7176

Tablo 5.4’te gösterildiği gibi tüm görüntü dizilerinde hedefler, önerilen yöntem sayesinde daha yüksek başarımla takip edilmektedir. “Woman” görüntü dizisinde, hedef takip başarımları tüm yöntemlerde düşük değerdedir. Bunun nedeni, bu görüntü dizisinde hedefin, takip süresince sık sık yarı örtüşmeye maruz kalmasıdır.

Önerilen yöntem, 3.4 GHz’lik bir bilgisayar üzerinde MATLAB kullanılarak her bir görüntü dizisi için yaklaşık 0.74 ms sürmektedir. Aynı platformda, ICTL ve MC yaklaşımları ise sırasıyla 0.30 ve 0.36 ms’de gerçekleştirilmektedir. Önerilen yöntemde kullanılan arama nokta sayısı, COV yaklaşımı için de geçerlidir. Bu doğrultuda, KS ve Gauss ağırlıklandırma yaklaşımlarının hedef takip işlem karmaşıklığına önemli bir etkisi yoktur.

Tablo 5.4. Hareketli kamera kayıtları içeren görüntü dizilerinde F-ölçütüne göre elde edilen ortalama hedef takip hata değerleri

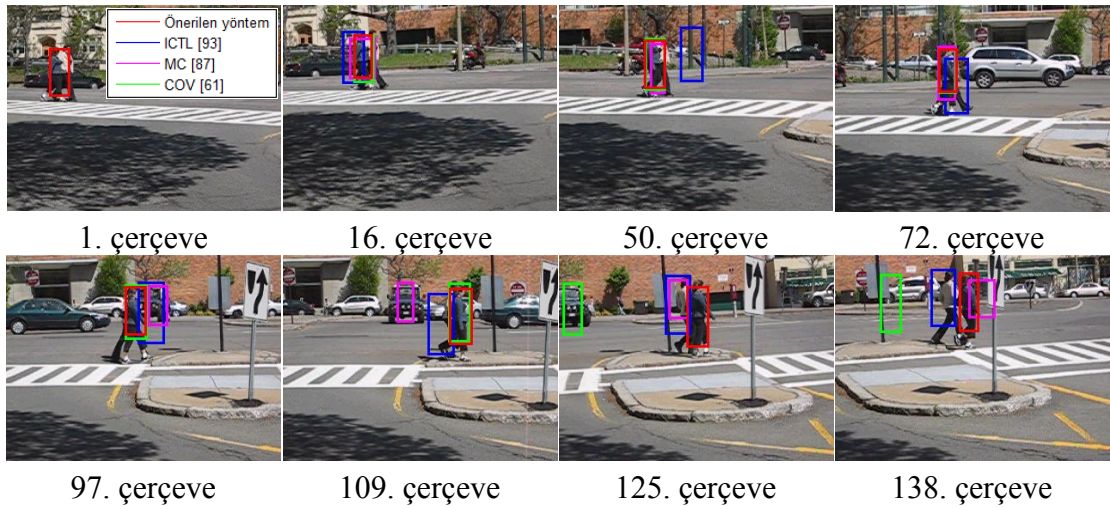
	Couple	Jogging1	Jogging2	Woman
COV [61]	0.6833	0.8235	0.8398	0.1621
ICTL [93]	0.6447	0.8250	0.1602	0.4922
MC [87]	0.6169	0.1915	0.8179	0.2022
Önerilen Y.	0.7284	0.8275	0.8482	0.5292

#### 5.4. Önerilen Yöntemin Görsel Başarımı

Şekil 5.9’da, “Couple” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları gösterilmiştir. Takip esnasında arka planda hedef nesneye benzer öznelik betimleyicilerin görüldüğü durumlarda, COV yaklaşımının takip performansı




azalmaktadır. Diğer yandan MC ve ICTL yaklaşımları, sahnede ani kamera hareketleri olmasından dolayı hedefi başarıyla takip edememektedir. Bununla birlikte, önerilen yöntemde kullanılan KS ve Gauss ağırlıklandırması sayesinde hedef, başarıyla takip edilmektedir. Hedef takip işleminin başlangıç anında, birden fazla hedef, tek bir hedef olarak algılanmaktadır. Başlangıç aşamasında iki farklı hedef bölgesi açıkça görülmekte ve 60. çerçeveye kadar başarılı bir şekilde takip edilmektedir. 60. çerçeveden sonra hedeflerden biri diğeriyle örtüşmektedir. Önerilen yöntem, bu örtüşme olayından etkilenmemekte ve hedefi başarıyla takip etmeye devam etmektedir. Dizinin sonlarına doğru önerilen yöntemin başarımında nispeten az bir düşme olmasına rağmen, karşılaştırılan diğer yaklaşımlara göre daha iyi bir hedef takip performansı sergilenmektedir. Önerilen yöntemin performans kaybının nedeni, takip edilen hedefin sahnenin sonlarına doğru iki ayrı bölgeye ayrılmasıdır. Diğer bir ifadeyle, örtüşmeye maruz kalan hedefe ait karakteristik özelliklerin bir bölümünün model güncelleme işlemi esnasında kaybedilmesidir.



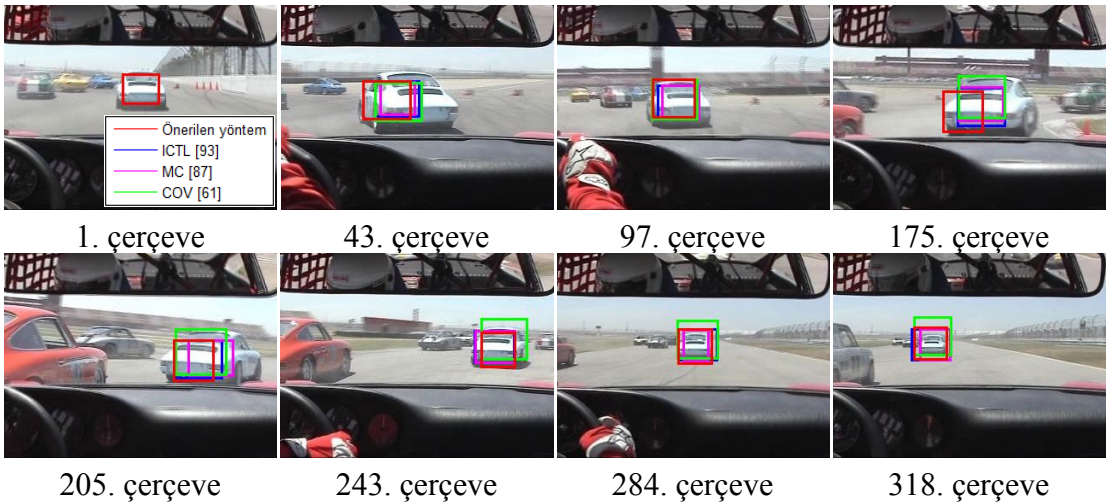
Şekil 5.9. “Couple” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları

Şekil 5.10’da “Woman” dizisi için elde edilen görsel takip sonuçları gösterilmiştir. Bu görüntü dizisinde takip edilen hedef, çok sık örtüşme olayına maruz kalmaktadır. Görsel sonuçlardan da görüleceği gibi önerilen yöntem diğer yaklaşımlara göre daha iyi hedef takip performansı sergilemektedir. Önerilen KS kestirim yaklaşımı ve örtüşme tespit aşaması sayesinde hedef, diğer BODB temelli yaklaşımlara nazaran daha iyi başarımlar göstermektedir.




Şekil 5.10. “Woman” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları

Şekil 5.11, “Race1” dizisi için elde edilen görsel takip sonuçlarını göstermektedir. Önerilen yöntem ve diğer yöntemler hedefi başarıyla takip edebilmektedir. Takip edilen hedefte manevra hareketinin görüldüğü 43. ve 175. çerçevelerde, önerilen yöntem hedefin konumunu, diğer yöntemlere göre daha kötü kestirmiştir. Bunun nedeni, KS’de kullanılan önsel kestirim değerine, ölçüm verisine oranla daha çok önem verilmesidir. Hedef konum kestiriminde yapılan hata, manevra hareketinin sonlandığı andan itibaren azalmakta, hedefin izlenmesi diğer yöntemlere nazaran daha başarılı bir şekilde gerçekleşmektedir.




Şekil 5.11. “Race1” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları

Şekil 5.12’de “Jogging2” dizisi için hedef takip yöntemlerinin görsel sonuçları verilmiştir. Görsel sonuçlardan da açıkça görüldüğü gibi önerilen yöntem, diğer yöntemlere göre daha üstün bir hedef takip başarımı sağlamaktadır. ICTL yaklaşımı, hedefin örtüşmeye maruz kalması sonrasında, hedefi kaybetmektedir. Bunun nedeni, örtüşme sonrasında hedefin olası konumunu belirten parçacıkların, hedefin gerçek konumu etrafında bulunmamasıdır. Diğer yandan MC yaklaşımı, hedefi başarıyla takip etse de, özellikle dizinin sonlarına doğru ölçekleme problemiyle karşılaşmaktadır. COV yaklaşımında hedef, zaman zaman kaybedilmektedir. Önerilen yöntem, örtüşme tespiti, Gauss ağırlıklandırma yaklaşımı ve KS sayesinde hedefi başarıyla takip etmektedir.



Şekil 5.12. “Jogging2” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları

Şekil 5.13, “Subway” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçlarını göstermektedir. Hedefin yarı örtüşmeye maruz kaldığı bu görüntü dizisinde hedef, MC yaklaşımı hariç diğer yöntemlerde başarılı bir şekilde takip edilmiştir. Görsel sonuçlardan görüldüğü gibi, önerilen yöntem ile ICTL ve COV yöntemlerinin hedef takip performansları birbirine yakındır. Nitekim nesnel sonuçlarda “Subway” dizisi için belirtilen hedef takip hatasının ortalama ve standart sapma değerleri, görsel sonuçları doğrulamaktadır.



Şekil 5.13. “Subway” dizisi için önerilen yöntem ile diğer yöntemlerin görsel takip sonuçları

Şekil 5.14’te, önerilen yöntemde kullanılan KS ve GTF’nin hedef takibindeki performansı gösterilmiştir. Bu doğrultuda, sadece KS, sadece GTF ve her iki yaklaşım kullanılarak, hedef takip performansları karşılaştırılmıştır. Şekil 4.16’da kesin referans, siyah bölge içinde gösterilmiştir. KS ve GTF’nin birarada kullanıldığı yaklaşımda elde edilen hedef takip bölgesi kırmızı bölgeye karşılık gelmektedir. Benzer şekilde, sadece KS ve sadece GTF yaklaşımlarıyla elde edilen hedef bölge, sırasıyla yeşil ve mavi renkle temsil edilmektedir. KS ve GTF’nin ayrı ayrı kullanılması durumunda, hedefin konumu iyi kestirilememektedir. Bununla birlikte, her iki yaklaşımın birarada kullanılması durumunda örtüşme ve benzer öznelilik betimleyicilerin görüldüğü sahnelerde hedef daha gürbüz bir yapıyla takip edilmektedir. Ani hareketlerin görüldüğü ve ölçek değişiminin fazla olduğu görüntü dizilerinde, KS ve GTF’nin ayrı ayrı kullanılması hedef takip performansını kötü etkilemektedir.



Şekil 5.14. Önerilen yöntemde sadece KS, sadece GTF ve her iki yaklaşımın birarada kullanılmasıyla elde edilen hedef takip sonuçları

## 5.5.Sonuç

Tez kapsamında gerçekleştirilen bu çalışmada, KS ve GTF temelli gürbüz bir hedef takip yaklaşımı önerilmiştir. Önerilen yaklaşımda takip edilen hedef bölge, ortak değişinti matrisiyle betimlenmiştir. Önerilen örtüşme tespiti sayesinde, daha doğru hedef takip sonuçları elde edilmiştir. Detaylı nesnel ve görsel sonuçlar, önerilen yöntemin hedef takip başarımındaki gürbüzlüğünü açıkça ortaya koymaktadır. Önerilen yöntem, hedeflerin ani hareketine duyarsız olduğu gibi, hedefin yavaş değişimlerinden de etkilenmemektedir. Önerilen yöntemi, BODB temelli çoklu hedef takibine genişletmek mümkündür.

## **6.ORTAK DEĞİŞİNTİ BETİMLEYİCİ TEMELLİ HEDEF TAKİBİNDE PİKSEL SEYRELTME YAKLAŞIMLARI**

Bu bölümde, ortak değişinti betimleyici temelli hedef takibinin işlem yükünü azaltmak için özgün bir yöntem önerilmiştir. Önerilen yöntem, ortak değişinti betimleyicilerinin daha az sayıda piksel kullanarak oluşturulmasına dayanmaktadır. Bu bölümde ayrıca, farklı piksel seyreltme yaklaşımları kullanılarak oluşturulan ortak değişinti betimleyici temelli hedef takip yaklaşımlarının performansları irdelenmiştir.

### **6.1. Piksel Seyreltme Yaklaşımları**

Bilgisayar görü uygulamalarında önerilen yöntemlerin, performanslarının yanı sıra, düşük işlem yüküne de sahip olması istenmektedir. Literatürde yapılmış hareket kestirim temelli çalışmalarda, işlemsel yükü azaltmak için, blok uyumlama esnasında tüm pikseller yerine daha az sayıda piksel kullanılmaktadır.

Hareket kestiriminde bloklar arası karşılaştırmada piksel seyreltme işlemi ile daha az sayıda piksel kullanmak mümkündür. En az sayıda piksel seçilerek, bloğa ait doku ve kenar bilginin en az kayıpla korunması arzu edilen bir durumdur. Seçilen pikseller, blok için bir örüntü oluşturmaktadır. Bu örüntü, bloğun doku ve kenar bilgisinin ne kadar korunduğunu gösteren uzamsal homojenlik ve yönlü kapsama bakımından incelenebilmektedir.

Uzamsal homojenlik, blok içinde seçilmeyen piksellerin, en yakınında seçilen piksellere uzaklıkların, ortalama ve standart sapma değerlerine karşılık gelmektedir. Uzamsal homojenlik için hesaplanan ortalama ve standart sapma değerleri Eşitlik (6.1)'de verilmiştir.

$$\mu = \frac{1}{(p_b - p_s)} \sum_{i=1}^{p_x} \sum_{j=1}^{p_y} \|(i, j) - S(i, j)\|$$

$$\sigma^2 = \frac{1}{(p_b - p_s)} \sum_{i=1}^{p_x} \sum_{j=1}^{p_y} (\|(i, j) - S(i, j)\| - \mu)^2$$
(6.1)

$p_b$  ve  $p_s$  sırasıyla blok içindeki tüm piksel sayısını ve seçilen piksel sayısını göstermektedir.  $p_x$  ve  $p_y$  ise bloğun genişlik ve yüksekliğini belirtmektedir.  $S(i, j)$  seçilen pikselin koordinatını göstermektedir. Ortalama ve standart sapma değerlerinin küçük olması, uzamsal homojenliğin fazla olduğunu göstermektedir. Yönlü kapsama ise  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  veya  $135^\circ$ 'lik açılarda (Şekil 6.1 (h)) kenar üzerinde en az bir pikselin seçili olmasıyla ilişkilidir.

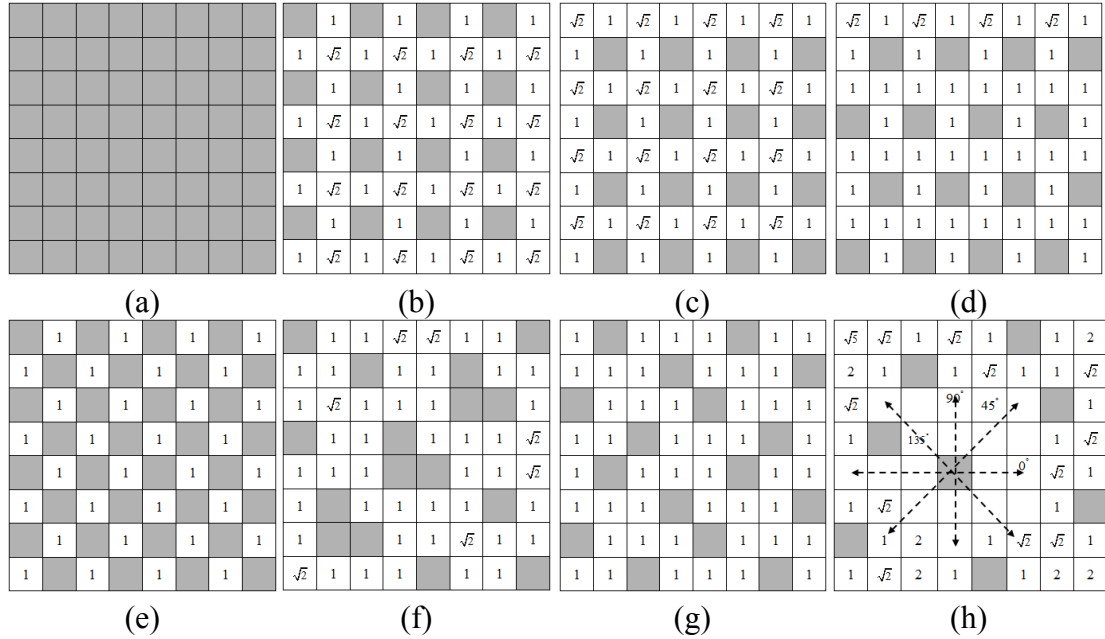
Literatürde yapılan çalışmalarda kullanılan piksel seyreltme örüntüleri ve bu örüntülerin uzamsal homojenlik ve yönlü kapsama değerleri, Tablo 6.1'de verilmiştir. Tablo 6.1'de verilen piksel seyreltme yaklaşımlarının  $8 \times 8$  blok boyutu için piksel örüntüleri, Şekil 6.1'de gösterilmiştir.

Tablo 6.1. Piksel seyreltme örüntülerin uzamsal homojenlik ve yönlü kapsama değerleri

Örüntü	Piksel seyreltme oranı	Uzamsal homojenlik		Yönlü kapsama			
		$\mu$	$\sigma^2$	$0^\circ$	$90^\circ$	$45^\circ$	$135^\circ$
Tam	1:1	0	0	$\frac{8}{8}$	$\frac{8}{8}$	$\frac{15}{15}$	$\frac{15}{15}$
Quarter [98]	4:1	1.14	0.04	$\frac{4}{8}$	$\frac{4}{8}$	$\frac{7}{15}$	$\frac{7}{15}$
Rectangular	4:1	1.14	0.04	$\frac{4}{8}$	$\frac{4}{8}$	$\frac{7}{15}$	$\frac{7}{15}$
Hexagonal [99]	4:1	1.03	0.11	$\frac{4}{8}$	$\frac{8}{8}$	$\frac{12}{15}$	$\frac{12}{15}$
Quincunx [100]	2:1	1	0	$\frac{8}{8}$	$\frac{8}{8}$	$\frac{8}{15}$	$\frac{8}{15}$
Yu [101]	4:1	1.06	0.02	$\frac{8}{8}$	$\frac{8}{8}$	$\frac{7}{15}$	$\frac{9}{15}$
4-Queen [102]	4:1	1	0	$\frac{8}{8}$	$\frac{8}{8}$	$\frac{10}{15}$	$\frac{10}{15}$
8-Queen [102]	8:1	1.32	0.14	$\frac{8}{8}$	$\frac{8}{8}$	$\frac{8}{15}$	$\frac{8}{15}$

[102]'de hareket kestirim işlemini hızlandırmak için N-queen piksel seyreltme yaklaşımı önerilmiştir. Önerilen yaklaşımın hareket kestirim performansı, farklı piksel seyreltme yaklaşımları ile karşılaştırılmıştır. [103]'te N-queen piksel seyreltme yaklaşım temelli hareket kestirimi için donanım mimarisi önerilmiştir. [104,105]'te

hareket kestiriminde blok uyumlama için genetik algoritma temelli en uygun piksel örüntü yapısının seçimi önerilmiştir.



Şekil 6.1. Piksel seyreltme örüntüleri. (a) Tam, (b) Quarter, (c) Rectangular, (d) Hexagonal, (e) Quincunx, (f) Yu, (g) 4-Queen, (h) 8-Queen

## 6.2. Piksel Seyreltme Yaklaşımları ile Ortak Değişinti Betimleyicilerin Oluşturulması


Literatürde BODB temelli hedef takibinin hesapsal yükünü düşürmek için farklı yöntemler mevcuttur. Örneğin BODB'ler, tümlev imge gösterim yöntemiyle hızlı bir biçimde hesaplanabilmekte, bu sayede hedef takibinin işlem yükü azaltılmaktadır. Benzer şekilde, [95]'te önerilen yaklaşımdaki gibi BODB'ler, hedefin tüm noktaları yerine hedefin önemli noktaları üzerinden hesaplanarak işlemsel yük düşürülebilmektedir.

Hedef takibinde tümlev imge gösterim yöntemi, genellikle her bir görüntü çerçevesinin tüm boyutu için hesaplanmaktadır. Görüntü çerçevesinin boyutunun artması durumunda, BODB'yi oluşturmak için harcanan süre de artmaktadır. Diğer yandan PS temelli hedef takibinde, çerçevenin tüm bölgesi için tümlev imge gösterimini kullanmak yerine hedefin yerinin tahmin edildiği konum etrafındaki bölge için tümlev imge gösterimi tanımlanabilmektedir. Bununla birlikte hedef



hareketinin ani deęişim göstermesi durumunda, bölgesel tümlev imge gösterim yönteminin hesapsal yükü artmaktadır.

Bu çalışmada, BODB'lerin elde edilmesinde, hedef bölge üzerindeki tüm piksellerin kullanılması yerine piksel seyreltme yaklaşımları ile daha az sayıda piksel kullanılmıştır. Önerilen yöntem sayesinde, tümlev imge gösterim yöntemi kullanılmadan oluşturulan BODB için gereken hesapsal yük, kullanılan piksel seyreltme örüntüsüne baęlı olarak azalmaktadır. Şekil 6.2'de, 8×8 blok boyutu üzerinden 8-queen piksel seyreltme yaklaşımı ile seçilen öznitelik vektörleri gösterilmiştir.



Şekil 6.2. 8×8 blok boyutu üzerinden 8-queen yaklaşımına göre öznitelik vektörlerin seçilmesi

Şekil 6.2'de gösterilen  $f_i$  öznitelik vektörleri kullanılarak oluşturulan çok deęişkenli yapı, Eşitlik (6.2)'de ifade edilmiştir.

$$\mathbf{M} = [\mathbf{f}_1 \quad \dots \quad \mathbf{f}_i \quad \dots \quad \mathbf{f}_{64}] \quad (6.2)$$


$$\hat{\mathbf{M}} = [\mathbf{f}_1 \quad \mathbf{f}_2 \quad \mathbf{f}_3 \quad \mathbf{f}_4 \quad \mathbf{f}_5 \quad \mathbf{f}_6 \quad \mathbf{f}_7 \quad \mathbf{f}_8]$$

$\mathbf{M}$ , blok üzerindeki tüm pikseller için tanımlı bütün öznitelik vektörlerinin kullanıldığı çok deęişkenli yapıya karşılık gelmektedir.  $\hat{\mathbf{M}}$  ise blok üzerindeki seçili pikseller üzerinden hesaplanan öznitelik vektörlerini içermektedir.

Piksel seyreltme temelli BODB görünüm modelini oluştururken, farklı blok boyutlarındaki hedef bölgeler için de piksel seyreltme işleminin tanımlanması gerekmektedir. Bu çalışmada, piksel seyreltme örüntüleri  $p_x \times p_y$  blok boyutları için yeniden tanımlanmış, tanımlanan bu örüntüler BODB temelli hedef takibinde

görünüm modelinin oluşturulmasında kullanılmıştır. Örneğin, Şekil 6.3'te  $16 \times 16$  blok boyutuna genişletilmiş 8-queen piksel örüntüsü gösterilmiştir.

BODB temelli hedef takibinde hesapsal yükü düşürmek amacıyla önerilen özgün yaklaşımın başarımı, COV [61] yöntemiyle karşılaştırılmıştır. Önerilen yaklaşımda, görünüm modelinde kullanılan öznitelik vektörleri ile model güncelleme aşaması, COV yöntemiyle aynıdır. Benzer şekilde hedef, COV yöntemindeki gibi tam arama yaklaşımıyla aranmaktadır.




Şekil 6.3.  $16 \times 16$  blok boyutuna genişletilmiş 8-queen piksel örüntüsü

### 6.3. Nesnel Hedef Takip Sonuçları


Önerilen yöntemin başarımını değerlendirmek için F-ölçütü kullanılmıştır. Bu başarımlar, tam piksel örüntü yapısına karşılık gelen COV yöntemiyle karşılaştırılmıştır.

Şekil 6.4'te, "Jogging1" dizisi için farklı piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takip performansları gösterilmiştir. Bütün piksel seyreltme yaklaşımlarında, F-ölçütü değerleri birbirlerine yakın değerdedir. Şekil 6.4 (b)'de küçük kesitte gösterildiği gibi, farklı piksel seyreltme yaklaşımlarıyla oluşturulan BODB'ler, hedef takip performansını önemli ölçüde etkilememektedir. Diğer yandan, yaklaşık 75. çerçevede tüm yaklaşımların F-ölçütünde görülen ani düşme, örtüşme durumundan kaynaklanmaktadır.



Şekil 6.4. “Jogging1” dizisi için farklı piksel seyreltme yaklaşımları kullanılarak elde edilen hedef takip performansları (a) tam kesit, (b) küçük bir kesit

Şekil 6.5’te, “Jogging2” dizisi için benzer şekilde farklı piksel seyreltme yaklaşımları kullanılarak oluşturulan BODB temelli hedef takip performansları gösterilmiştir. Piksel seyreltme yaklaşımlarıyla oluşturulan BODB, genel hedef takip performansını çok değiştirmemektedir. Şekil 6.5 (b)’den de görüldüğü gibi, piksel seyreltme yaklaşımları, tam örüntüye göre nispeten dah iyi performans göstermektedir. Bunun nedeni, hedef bölgesinde seçilen piksellerin karakteristik özelliklerinden kaynaklanmaktadır. Tüm piksel seyreltme yaklaşımları ve tam örüntü için, görüntü dizisinin sonlarına doğru F-ölçütünde yer yer performans kayıpları görülmektedir. Bunun nedeni, sahnede takip edilen hedefin karakteristik özelliklerine benzer bölgelerin olmasıdır. Bu durumda, hedef kestirimi hatalı olarak yapılmaktadır.



Şekil 6.5. “Jogging2” dizisi için farklı piksel seyreltme yaklaşımları kullanılarak elde edilen hedef takip performansları (a) tam kesit, (b) küçük bir kesit

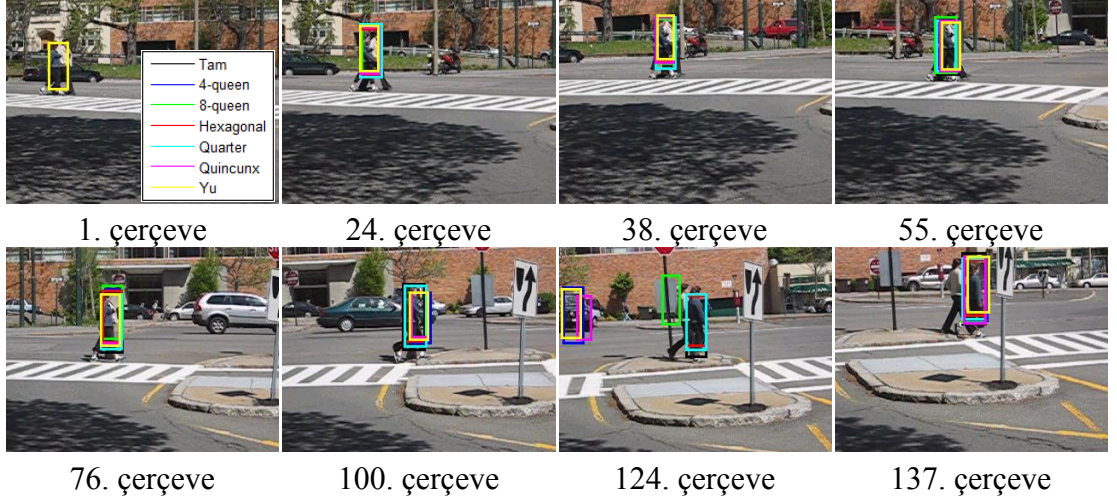
Tablo 6.2’de tam piksel örüntü ve farklı piksel seyreltme yaklaşımları kullanılarak oluşturulan BODB temelli hedef takibinde, tüm çerçeveler için elde edilen ortalama F-ölçüt değerleri verilmiştir. Tablo 6.2’den açıkça görüldüğü gibi, piksel seyreltme yaklaşımları ile elde edilen hedef performansları, genel olarak tam piksel örüntü yaklaşımı ile elde edilen performansa yakın değerlerdedir. Bununla birlikte, 8-queen yaklaşımında kullanılan piksel sayısı, diğer yaklaşımlara göre daha az olduğu için, bazı dizilerde nispeten daha düşük takip performansı elde edilebilmektedir. Diğer yandan, 1/4 oranında alt örnekleme kullanan piksel seyreltme yaklaşımları, 1/2 oranında alt örnekleme kullanan Quincunx piksel seyreltme yaklaşımıyla rekabet edici bir performansa sahiptir. Bu nedenle, BODB’yi oluşturmak için 1/2 oranında alt örnekleme kullanan piksel seyreltme yaklaşımı yerine, daha düşük işlem yüküne sahip 1/4 oranında alt örnekleme kullanan piksel seyreltme yaklaşımlarını tercih etmek mümkündür.

Tablo 6.2. Tam piksel örüntü ve farklı piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibinde tüm çerçeveler için elde edilen ortalama F-ölçüt değerleri

Örüntü Diziler	Tam 1:1	Quarter 4:1	Hexagonal 4:1	Quincunx 2:1	Yu 4:1	4-queen 4:1	8-queen 8:1
Jogging1	0.8235	0.7683	0.7936	0.8207	0.7722	0.7807	0.8042
Jogging2	0.8398	0.8432	0.8623	0.8406	0.8481	0.8608	0.8438
Race1	0.6758	0.6623	0.6862	0.6683	0.6663	0.6729	0.5852
Subway	0.7626	0.6599	0.6526	0.6788	0.6407	0.7010	0.4735
Crowd	0.8228	0.7778	0.7848	0.8216	0.7883	0.7690	0.6834
EnterExit	0.6735	0.6239	0.6415	0.6262	0.6194	0.6076	0.6519
Reenter1f.	0.6699	0.5672	0.6111	0.6607	0.6407	0.6865	0.6594
Couple	0.6833	0.7556	0.7411	0.6835	0.6831	0.6831	0.7159


#### 6.4. Görsel Hedef Takip Sonuçları

Şekil 6.6’da “Couple” dizisi için farklı piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibinin görsel sonuçları gösterilmiştir. Görsel takip sonuçlarından görüldüğü gibi, hemen hemen tüm piksel seyreltme yaklaşımları ile oluşturulan BODB’ler, hedefi, tüm çerçeve boyunca izleyebilmektedir.



Şekil 6.6. “Couple” dizisi için farklı piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibin görsel sonuçları

Şekil 6.7’de “Race1” dizisi için elde edilen görsel sonuçlar gösterilmiştir. Görsel sonuçlardan açıkça görüldüğü gibi hemen hemen tüm görüntü çerçevesinde, tüm piksel seyreltme yaklaşımları ile oluşturulmuş BODB’ler, birbirlerine yakın hedef takip performansı sergilemektedir. Bununla birlikte, 1/8 oranında alt örnekleme kullanan 8-queen piksel seyreltme yaklaşımı, diğer piksel seyreltme yaklaşımlarına göre nispeten daha kötü performans göstermektedir.



Şekil 6.7. “Race1” dizisi için piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibin görsel sonuçları

## 6.5. Sonuç

Bu çalışmada, BODB temelli hedef takibinin hesapsal yükünü azaltmak için özgün bir yöntem önerilmiştir. Literatürde, hareket kestirimi için blok uyumlama esnasında

kullanılan piksel seyreltme yaklaşımlarından yola çıkılarak, BODB'ler daha az sayıda piksel seçilerek oluşturulmuştur. Nesnel ve görsel sonuçlardan görüldüğü gibi, piksel seyreltme yaklaşımları ile oluşturulan BODB temelli hedef takibi, tam örüntü ile oluşturulan BODB temelli hedef takibine göre benzer takip performansına sahiptir. Diğer yandan hesapsal yük, tümlev imge gösterim tekniğinin kullanılmadığı durumlarda, seçilen piksel örüntüsüne bağlı olarak 1/2, 1/4 hatta 1/8 oranında azalmaktadır.

## SONUÇLAR VE ÖNERİLER

Bu tez kapsamında, öncelikle ortak değişinti matrislerin karşılaştırılmasında iyileştirilmiş benzemezlik ölçütü önerilmiştir. Standart BODB temelli hedef takibinde, benzemezlik ölçütünde sadece hedef nesnelere ait öznitelik vektör dağılımları kullanılmaktadır. Önerilen yöntem ile öznitelik vektör dağılımlarının yanında, öznitelik vektör ortalamalarının da dikkate alındığı iyileştirilmiş bir benzemezlik ölçütü önerilmiştir. Deneysel sonuçlardan da görüldüğü gibi, önerilen yöntem sayesinde hedefler, standart BODB temelli hedef takip yöntemine göre daha yüksek hedef takip başarımına sahiptir. Önerilen yöntemin hesapsal yükü ile standart BODB temelli hedef takip yönteminin hesapsal yükü hemen hemen aynıdır. Önerilen yöntemde, iyileştirilmiş benzemezlik ölçütündeki ağırlıklandırma parametrelerini uyarlamalı bir şekilde hesaplayarak, daha yüksek hedef takip performansı elde etmek de mümkündür.

Tez kapsamında önerilen diğer özgün çalışmada, Kalman süzgeci ve Gauss ağırlıklandırma temelli gürbüz bir hedef takip yaklaşımı önerilmiştir. Görünüm modelinin ortak değişinti betimleyici ile oluşturulduğu bu yöntemde, hedefler başarıyla takip edilmektedir. Nesnel ve görsel sonuçlar, önerilen yöntemin başarımını açıkça ortaya koymaktadır. Önerilen yöntemin performansı, hedeflerin ani ve yavaş değişimlerinden etkilenmemektedir. Bu çalışmada ayrıca, örtüşme tespiti için yeni bir yaklaşım önerilmiştir. Bu yaklaşım sayesinde, örtüşmeler yüksek başarıyla tespit edilebilmektedir. Bununla birlikte, sahnede örtüşme süresine bağlı olarak, örtüşme anlarını tespit etmek güçleşebilmektedir. Önerilen yöntemi, çoklu hedef takibine uyarlamak da mümkündür.

Bu tez kapsamında ayrıca, BODB temelli hedef takibin hesapsal yükünü düşürmeye yönelik özgün bir yaklaşım önerilmiştir. Önerilen yaklaşımın temeli, hedef bölge üzerinden daha az sayıda piksel seçerek ortak değişinti matrislerin oluşturulması yöntemine dayanmaktadır. Literatürde bulunan farklı piksel seyreltme yaklaşımları ile oluşturulan ortak değişinti matrislerin hedef takip başarımları irdelenmiştir.

Deneysel sonuçlardan da görüldüğü gibi, hedef takip performansından çok fazla ödün vermeden BODB temelli hedef takibini daha düşük hesapsal yük ile gerçekleştirmek mümkündür. Önerilen yaklaşım, tümlev imge gösterim yönteminin tercih edilmediği durumlarda geçerlidir.



## KAYNAKLAR

- [1] Grewal M. S., Andrews A. P., *Kalman filtering: theory and practice using MATLAB*, 3rd ed., Wiley, New Jersey, U.S.A., 2008.
- [2] Bernardo J. M., Smith F. M., *Bayesian theory*, 1st ed., Wiley, New Jersey, U.S.A., 2000.
- [3] Kalman R. E., A new approach to linear filtering and prediction problems, *Transaction of the ASME- Journal of Basic Engineering*, 1960, **82**, 35-45.
- [4] Therrien C. W., *Discrete random signals and statistical signal processing*, 1st ed., Prentice Hall, New Jersey, U.S.A., 1992.
- [5] Barkat M., *Signal detection and estimation*, 2nd ed., Artech House, U.S.A., 2005.
- [6] Brookner E., *Tracking and Kalman filtering made easy*, 1st ed., Wiley, New Jersey, U.S.A., 1998.
- [7] Larson R. E., Dressler M. R., Ratner R. S., Application of the extended Kalman filter to ballistic trajectory estimation, Master's thesis, Stanford Research Institute, California, 1967, 5188-103.
- [8] Daum F., Nonlinear filters: Beyond the Kalman filter, *IEEE Aerospace and Electronic Systems Magazine*, 2005, **20**(8), 57-69.
- [9] Corigliano A., Mariani S., Parameter identification in explicit structural dynamics performance of the extended Kalman filter, *Computer Methods in Applied Mechanics and Engineering*, 2004, **193**(36), 3807-3835.
- [10] Julier S., Uhlmann J., Whyte H. D., A new approach for filtering nonlinear systems, *Proceedings of the American Control Conference*, Seattle, U.S.A., 21-23 June 1995.
- [11] Wan E. A., Van der Merwe R., The unscented Kalman filter for nonlinear estimation, *Adaptive Systems for Signal Processing, Communications and Control Symposium*, Lake Louise, U.S.A., 01-04 October 2000.
- [12] Julier S., Uhlmann J., A new extension of the Kalman filter to nonlinear systems, *International Symposium Aerospace/Defense Sensing, Simulations and Controls*, Orlando, U.S.A., 20-25 April 1997.
- [13] Doucet A., Fretias N. D., Gordon N., An Introduction to sequential Monte Carlo methods, Editors: Doucet A., Fretias N. D., Gordon N., *Sequential Monte Carlo Methods in Practice*, 1st ed., Springer-Verlag, New York, U.S.A., 1-14, 2001.

- [14] Gordon N., Salmond D. J., Smith F. M., Novel approach to nonlinear and non-gaussian bayesian state estimation, *IEEE Proceedings F, Radar and Signal Processing*, 1993, **140**(2), 107-113.
- [15] Isard M., Blake A., Condensation-conditional density propagation for visual tracking, *International Journal of Computer Vision*, 1998, **29**(1), 5-28.
- [16] Arulampalam M. S., Maskell S., Gordon N., Clapp T., A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking, *IEEE Transactions on Signal Processing*, 2002, **50**(2), 174-188.
- [17] Kong. A., Liu J. S., Wong W. H., Sequential imputations and bayesian missing data problems, *Journal of the American Statistical Association*, 1994, **89**(425), 278-288.
- [18] Musso C., Oudjane N., Gland F. L., Improving regularized particle filters, Editors: Doucet A., Fretias N. D., Gordon N., *Sequential Monte Carlo Methods in Practice*, 1st ed., Springer-Verlag, New York, U.S.A., 247-271, 2001.
- [19] Harris C., Stephens M., A combined corner and edge detector, *4th Alvey Vision Conference*, University of Manchester, England, 31 August-02 September 1988.
- [20] Kanade T., Collins R., Lipton A., Burt P., Wixson L., Advances in cooperative multi sensor video surveillance, *Image Understanding Workshop*, Monterey, California, 20-23 November 1998.
- [21] Lowe D., Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, 2004, **60**(2), 91-110.
- [22] Liu L. Y., Sang N., Huang R., Background subtraction using shape and colour information, *Electronics Letters*, 2010, **46**(1), 41-43.
- [23] Zhang H., Wu K., A vehicle detection algorithm based on three-frame differencing and background subtraction, *Internatinal Symposium on Computational Intelligence and Design (ISCID)*, Hangzhou, China, 28-29 October 2012.
- [24] Stauffer C., Grimson W. E. L., Adaptive background mixture models for real time Tracking, *Computer Vision and Pattern Recognition*, Fort Collins, Colorado, 23-25 June 1999.
- [25] Lee D. S., Effective Gaussian mixture learning for video background subtraction, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(5), 827-832.
- [26] Hoprasert T., Harwood D., Davis S., A statistical approach for real time robust background subtraction and shadow detection, *Proceedings of the 7th IEEE International Conference on Computer Vision*, Corfu, Greece, 20-27 September 1999.

- [27] Buch N., Orwell J., Velastin S. A., Detection and classification of vehicles for urban traffic scenes, *5th International Conference on Visual Information Engineering*, Xian, China, 29 July-01 August 2008.
- [28] Fehr D., Sivalingam R., Morellas V. R., Papanikolopoulos N., Loffallah O., Counting people in groups, *6th IEEE International Conference on Advanced Video and Signal Based Surveillance*, Genova, Italy, 2-4 September 2009.
- [29] Boudoukh G., Leichter I., Rivlin E., Visual tracking of object silhouettes, *16th IEEE International Conference on Image Processing (ICIP)*, Cairo, 7-10 November 2009.
- [30] Dalal N., Triggs B., Histograms of oriented gradients for human detection, *IEEE Conference on Computer Vision Pattern Recognition*, San Diego, U.S.A., 20-25 June 2005.
- [31] Gavrilu D., Pedestrian detection from a moving vehicle, *6th European Conference on Computer Vision (ECCV)*, Dublin, Ireland, 26 June-01 July 2000.
- [32] Comaniciu D., Ramesh V., Meer P., Real-time tracking of non-rigid objects using mean shift, *IEEE Conference on Computer Vision Pattern Recognition*, Hilton Head Island, South Carolina, 13-15 June 2000.
- [33] Zhang S., Yao H., Gao P., Robust object tracking combining color and scale invariant features, *Visual Communications and Image Processing*, San Diego, U.S.A., 27-30 November 2012.
- [34] Manjunath B. S., Ma W. Y., Texture features for browsing and retrieval of image data, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996, **18**(8), 837-842.
- [35] Ojala T., Pietikainen M., Maenpaa T., Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(7), 971-987.
- [36] Bakhtari A., Benhabib B., An active vision system for multitarget surveillance in dynamic environments, *IEEE Transactions on Systems, Man, and Cybernetics*, 2007, **37**(1), 190-198.
- [37] Huang C. M., Fu L. C., Multitarget visual tracking based effective surveillance with cooperation of multiple active cameras, *IEEE Transactions on Systems, Man, and Cybernetics*, 2011, **41**(1), 234-247.
- [38] Song B., Chowdhury K. R., Robust tracking in a camera network: A multi-objective optimization framework, *IEEE Journal of Selected Topics in Signal Processing*, 2008, **2**(4), 582-596.
- [39] Wang H., Liu C., Zhang X., Li Q., Multi-camera tracking based on information fusion in video surveillance, *2nd International Congress on Image and Signal Processing*, Tianjin, China, 17-19 October 2009.

- [40] Javed O., Rasheed Z., Shafique K., Shah M., Tracking across multiple cameras with disjoint views, *IEEE International Conference on Computer Vision*, Nice, France, 13-16 October 2003.
- [41] Zhu L. Z., Hwang H. S., Cheng H. S., Tracking of multiple objects across multiple cameras with overlapping and non-overlapping views, *Circuits and Systems*, Taipei, Taiwan, 24-27 May 2009.
- [42] Takemura N., Miura J., View planning of multiple active cameras for wide area surveillance, *IEEE International Conference Robotics and Automation*, Roma, Italy, 10-14 April 2007.
- [43] Zhanfeng Y., Zhou S. K., Chelappa R., Robust two-camera tracking using homography, *IEEE International Conference on Acoustics, Speech, and Signal Processing*, Montreal, Canada, 17-21 May 2004.
- [44] Eshel R., Moses Y., Homography based multiple camera detection and tracking of people in a dense crowd, *IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, Alaska, 23-28 June 2008.
- [45] Di M., Joo E. M., Beng L. H., A comprehensive study of Kalman filter and extended Kalman filter for target tracking in wireless sensor networks, *IEEE International Conference on Systems, Man, and Cybernetics*, 12-15 Ekim 2008.
- [46] Bhuyan M. K., Lovell B. C., Bigdeli A., Tracking with multiple cameras for video surveillance, *Proceedings of the 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications*, Glenelg, Australia, 3-5 December 2007.
- [47] Xiaolong D., Jianying X., Weizhong G., Bayesian target tracking based on particle filter, *Journal of Systems Engineering and Electronics*, 2005, **16**(3), 545-549.
- [48] Sherrah J., Ristic B., Redding N. J., Particle filter to track multiple people for visual surveillance, *Computer Vision, IET*, 2011, **5**(4), 192-200.
- [49] Chen P., Qian H., Wang W., Zhu M., Contour tracking using gaussian particle filter, *Image Processing, IET*, 2011, **5**(5), 440-447.
- [50] Das S., Kale A., Vaswani N., Particle filter with a mode tracker for visual tracking across illumination changes, *IEEE Transactions on Image Processing*, 2012, **21**(4), 2340-2346.
- [51] Jung M. W., Ching T. S., Shen C., Sei C. W., Omni-directional camera networks and data fusion for vehicle tracking in an indoor parking lot, *IEEE International Conference on Advanced Video and Signal Based Surveillance*, Sydney, Australia, 22-24 November 2006.
- [52] Chin S. F., Chin S. L., A high definition human face tracking system using the fusion of omni directional and ptz cameras mounted on a mobile robot, *5th*

*IEEE Conference on Industrial Electronics and Applications*, Taichung, Taiwan, 15-17 June 2010.

- [53] Yilmaz A., Javed O., Shah M., Object tracking: A survey, *ACM Journal of Computing Surveys*, 2006, **38**(4), 1-45.
- [54] Yang H., Shao L., Zheng F., Wang L., Song Z., Recent advances and trends in visual tracking: A review, *Journal Neurocomputing*, 2011, **74**(18), 3823-3831.
- [55] URL-1: <http://homepages.inf.ed.ac.uk/rbf/CAVIAR/DATA1/> (Ziyaret tarihi: 10 Ocak 2014).
- [56] Nummiaro K., Meier K. E., Gool V. L., A color-based particle filter, *Proceedings of Workshop on Generative-Model Based Vision*, Copenhagen, Denmark, 53-60 June 2002.
- [57] Maggio E., Smerladi F., Cavallaro A., Combining colour and orientation for adaptive particle-filter based tracking, *Proceedings British Machine Vision Conference*, Oxford Brookes University, England, 5-8 September 2005.
- [58] Yang F., Lu H., Zhang W., Chen Y. W., Visual tracking via bag of features, *Image Processing, IET*, 2012, **6**(2), 115-128.
- [59] Tuzel O., Porikli F., Meer P., Region covariance: A fast descriptor for detection and classification, *European Conference on Computer Vision (ECCV)*, Graz, Austria, 7-13 May 2006.
- [60] Forstner W., Moonen B., A metric for covariance matrices, *Department of Geodesy and Geoinformatics*, 113-128, 1999.
- [61] Porikli F., Tuzel O., Meer P., Covariance tracking using model update on lie algebra, *In Proc. IEEE Conference Computer Vision and Pattern Recognition*, New York, U.S.A., 17-22 June 2006.
- [62] Viola P., Jones M. J., Robust real-time object detection, *ICCV Workshop on Statistical and Computation Theories of Vision*, Vancouver, Canada, U.S.A., 13-15 July 2001.
- [63] Porikli F., Integral histogram: A fast way to extract histograms in cartesian spaces, *Computer Vision and Pattern Recognition*, San Diego, U.S.A., 20-25 June 2005.
- [64] Porikli F., Tuzel O., Fast construction of covariance matrices for arbitrary size image windows, *IEEE International Conference on Image Processing*, Atlanta, U.S.A., 8-11 October 2006.
- [65] Porikli F., Tuzel O., Meer P., Covariance tracking using model update based on means on riemannian manifolds, *IEEE Conference Computer Vision and Pattern Recognition*, New York, U.S.A., June 2006.

- [66] Pennec X., Fillard P., Ayache N., A riemannian framework for tensor computing, *International Journal of Computer Vision*, 2006, **66**(1), 41-66.
- [67] Porikli F., Kocak T., Robust license plate detection using covariance descriptor in a neural network framework, *IEEE International Conference on Video and Signal Based Surveillance*, Sydney, Australia, 22-24 November 2006.
- [68] Tuzel O., Porikli F., Meer P., Human detection via classification on riemannian manifolds, *IEEE Conference on Computer Vision and Pattern Recognition*, Minneapolis, U.S.A., 17-22 June 2007.
- [69] Yao J., Odobez J. M., Fast human detection from videos using covariance features, *8th International Workshop on Visual Surveillance Workshop*, Marseille, France, 12-18 October 2008.
- [70] Palaio H., Batista J., A region covariance embedded in a particle filter for multi-objects tracking, *8th International Workshop on Visual Surveillance*, Marseille, France, 12-18 October 2008.
- [71] Wu Y., Wu B., Liu J., Lu H., Probabilistic tracking on riemannian manifolds, *19th International Conference on Pattern Recognition*, Florida, USA, 8-11 December 2008.
- [72] Zhang S., Yao H., Liu S., Chen X., Gao W., A covariance-based method for dynamic background subtraction, *19th International Conference on Pattern Recognition*, Florida, USA, 8-11 December 2008.
- [73] Pang Y., Yuan Y., Li X., Gabor based region covariance matrices for face recognition, *IEEE Transactions on Circuits and Systems for Video Technology*, 2008, **18**(7), 989-993.
- [74] Alahi A., Bierlaire M., Kunt M., Object detection and matching with mobile cameras collaborating with fixed cameras, *10th European Conference on Computer Vision*, Marseille, France, 12-18 October 2008.
- [75] Hu H., Qin J., Lin Y., Xu Y., Region covariance based probabilistic tracking, *Proceedings of the 7th World Congress on Intelligent Control and Automation*, Chongqing, China, 25-27 June 2008.
- [76] Ge Y., Yu J., Robust visual tracking using incremental appearance descriptor update, *Proceedings of the IEEE International Conference on Automation and Logistica*, Qingdao, China, 1-3 September 2008.
- [77] Tyagi A., Davis J. W., Potamianos G., Steepest descent for efficient covariance tracking, *IEEE Workshop on Motion and Video Computing*, Copper Mountain, Colorado, 8-9 January 2008.
- [78] Arsigny V., Fillard P., Pennec X., Ayache N., Geometric means in a novel vector space structure on symmetric positive-definite matrices, *SIAM Journal on Matrix Analysis and Applications*, 2006, **29**(1), 328-347.

- [79] Li X., Hu W., Zhang Z., Zhang X., Zhu M., Cheng J., Visual tracking via incremental lod-euclidean riemannian subspace learning, *IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, Alaska, 23-28 June 2008.
- [80] Kluckner S., Mauthner T., Bischof H., A covariance approximation on euclidean space for visual tracking, *Proceedings of the 33rd Workshop of the Austrian for Pattern Recognition*, Stainz, Austria, 14-15 May 2009.
- [81] Wang G., Liu Y., Shi H., Covariance tracking via geometric particle filtering, *2nd International Conference on Intelligent Computation Technology and Automation*, Zhangjiajie, China, 10-11 October 2009.
- [82] Tuna H., Onaran İ., Çetin E. A., Image description using a multiplier-less operator, *IEEE Signal Processing Letters*, 2009, **16**(9), 751-753.
- [83] Cargill C. P., Rius U. C., Mery D., Soto A., Performance evaluation of the covariance descriptor for target detection, *Proceedings of the International Conference of the Chilean Computer Science Society*, Santiago, Chile, 10-12 November 2009.
- [84] Metzler J., Willersinn D., Robust tracking of people in crowds with covariance descriptors, *Visual Information Processing XVIII*, Florida, U.S.A., 13-17 April 2009.
- [85] Hong X., Chang H., Shan S., Chen X., Gao W., Sigma set: A small second order statistical region descriptor, *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, U.S.A., 20-25 June 2009.
- [86] Wu P., Wang J., Zhang Q., Covariance tracking algorithm based on particle filter and adaptive template update, *2nd International Conference on Education Technology and Computer*, Shanghai, China, 22-24 June 2010.
- [87] Ding X., Huang C., Huang F., Region covariance based object tracking using monte carlo method, *8th IEEE International Conference on Control and Automation*, Xiamen, China, 9-11 June 2010.
- [88] Ma B., Wu Y., Covariance matching for pde-based contour tracking, *6th International Conference on Image and Graphics*, Hefei, P. R. China, 12-15 August 2011.
- [89] Yao J., Odobez M. J., Fast human detection from joint appearance and foreground feature subset covariances, *Computer Vision and Image Understanding*, 2011, **115**(10), 1414-1426.
- [90] Min J. H., Papanikolopoulos N., Smith E. C., Morellas V., Feature-based covariance matching for a moving target in multi-robot following, *19th Mediterranean Conference on Control & Automation*, Corfu, Greece, 20-23 June 2011.

- [91] Undurraga C., Mery D., Improving tracking algorithms using saliency, *Proceedings of the 16th Iberoamerican Congress conference on Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, Pucon, Chile, 15-18 November 2011.
- [92] Ayedi W., Snoussi H., Abid M., A fast multi-scale covariance descriptor for object re-identification, *Pattern Recognition Letters*, 2012, **33**(14), 1902-1907.
- [93] Wu Y., Wang J., Lu H., Wang J., Lu H., Wang J., Ling H., Blasch E., Bai L., Real-time probabilistic covariance tracking with efficient model update, *IEEE Transactions on Image Processing*, 2012, **21**(5), 2824-2837.
- [94] Hu W., Li X., Luo W., Zhang X., Single and multiple object tracking using log-euclidean riemannian subspace and block-division appearance model, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, **34**(12), 2420-2440.
- [95] Çakır S., Aytaç T., Yıldırım A., Beheshti S., Gerek N. Ö., Çetin E. A., Hedef izleme için önemli noktalar üzerinden hesaplanan bölgesel ortak değişinti betimleyicileri, *20. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU)*, Muğla, Türkiye, 18-20 Nisan 2012.
- [96] Zhang X., Li W., Hu W., Ling H., Maybank S., Block covariance based  $l_1$  tracker with a subtle template dictionary, *Pattern Recognition*, 2013, **46**(7), 1750-1761.
- [97] Bruyas A., Papanikolopoulos N., A genetic algorithm for the construction of optimized covariance descriptors, *21th Mediterranean Conference on Control & Automation*, Chania, Greece, 25-28 June 2013.
- [98] Bierling M., Displacement estimation by hierarchical block matching, *Proceedings of the SPIE Conference on Visual Communications and Image Processing*, Boston, USA, 25 October 1988.
- [99] Choi K. T., Chan S. C., Ng T. S., A new fast motion estimation algorithm using hexagonal subsampling pattern and multiple candidate search, *IEEE International Conference on Image Processing (ICIP)*, Lausanne, Switzerland, 16-19 September 1996.
- [100] Lengwehasatit K., Ortega A., Probabilistic partial-distance fast matching algorithms for motion estimation, *IEEE Transactions on Circuits and Systems for Video Technology*, 2001, **11**(2), 139-152.
- [101] Yu Y., Zhou J., Chen C. W., A novel fast block motion estimation algorithm based on combined subsamplings on pixels and search candidates, *Journal Visual Communication Image Representation*, 2001, **12**(1), 96-105.
- [102] Wang C. N., Yang S. W., Liu C. M., Chiang T., A hierarchical decimation lattice based on n-queen with an application for motion estimation, *IEEE Signal Processing Letters*, 2003, **10**(8), 228-231.



- [103] Wang C. N., Yang S. W., Liu C. M., Chiang T., A hierarchical n-queen decimation lattice and hardware architecture for motion estimation, *IEEE Transactions on Circuits and Systems for Video Technology*, 2004, **14**(4), 429-440.
- [104] Saha A., Toward optimal pixel decimation patterns for block matching in motion estimation, *15th International Conference on Advanced Computing and Communications*, Guwahati, India, 18-21 December 2007.
- [105] Saha A., Mukherjee J., Sural S., New pixel-decimation patterns for block matching in motion estimation, *Signal Processing: Image Communication*, 2008, **23**(10), 725-738.

## **KİŞİSEL YAYINLAR ve ESERLER**

- [1] **Akbulut O.**, Urhan O., Ertürk S., İyileştirilmiş benzerlik kriteri kullanarak bölgesel ortak değişinti betimleyici tabanlı olasılıksal nesne takibi, *21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*, Girne, KKTC, 24-26 Nisan 2013.
- [2] **Akbulut O.**, Ertürk S., Enhanced covariance descriptor based robust target tracking using kalman guided gaussian similarity weighting, *IET Image Processing*, değerlendirilmek üzere gönderildi.

## ÖZGEÇMİŞ

1982 yılında Kütahya'nın Gediz ilçesinde doğan Orhan Akbulut, ilköğrenimini 1 Eylül İlköğretim Okulu'nda, orta ve lise öğrenimini ise Gediz Mustafa Necip Alayeli Anadolu Lisesi'nde tamamladı. Lisans ve yüksek lisans derecelerini sırasıyla 2005 ve 2007 yıllarında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden aldı. 2005 yılından itibaren Kocaeli Üniversitesi İşaret ve Görüntü İşleme Laboratuvarında (KULIS) arařtırmacı olarak görev yaptı. TÜBİTAK ve Kore Arařtırma Vakfı tarafından desteklenen EEEAG/106E115 nolu projede önerilen "Sıkıřtırılmıř Video Kalitesinin İyileřtirilmesi için Optimal ve Optimale-Yakın Son-Süzgeçleme" projesinde, tam zamanlı arařtırmacı olarak görev aldı. 2007 yılından beri Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda doktora eğitime devam etmektedir.