

## Görsel Hedef Takibi Yöntemlerine Genel Bakış

### An Overview of Visual Target Tracking Methods

Bahri Maraş<sup>1</sup>, Nafiz Arica<sup>2</sup> ve Ayşın Ertüzün<sup>1</sup>

<sup>1</sup>Boğaziçi Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü

bahri.maras@boun.edu.tr, ertuz@boun.edu.tr

<sup>2</sup>Bahçeşehir Üniversitesi, Bilgisayar Mühendisliği Bölümü

nafiz.arica@eng.bau.edu.tr

#### Öz

Görsel hedef takibi, üzerinde uzun süredir çalışılmış ve halen araştırma konusu olmaya devam eden önemli bir bilgisayarla görü problemi. Hedef takibi problemi, sabit ya da hareketli bir kameradan alınan video bilgisi üzerinde ilgilenilen nesnenin izlenmesi olarak tanımlanabilir. Araştırma konusu olarak ilgi çekmesinin en önemli nedenleri, takibin yapıldığı ortam şartlarında ve takip edilecek nesne hareketinde oluşan değişimlerdir. Başarılı bir hedef takip algoritmasının, ortamda meydana gelen ışık değişimlerine, görüntü gürültüsüne, düşük karışıklığa, hedefin ortamdaki diğer nesnelere örtüşmesine, hedefi görüntüleyen kameranın istemsiz hareketlerine vb. karşı gürbüz olması gerekmektedir. Literatürdeki araştırmalar temel olarak üretici (generative) ve ayırdedici (discriminative) olarak iki başlık altına toplanmaktadır. Bu makalede her iki yaklaşımı temel alan son yıllarda geliştirilmiş hedef takibi algoritmaları incelenerek, mevcut yöntemlerin avantaj ve dezavantajları karşılaştırılmaları anlatılmaktadır. Ayrıca çalışmaların başarımlarını değerlendirmesi amacıyla literatürde kullanılan veri kümeleri ve karşılaştırma metrikleri de açıklanmaktadır.

**Anahtar Kelimeler:** Bilgisayarla görü, üretici yöntemler, ayırdedici yöntemler, yapılandırılmış destek vektör makineleri, derin öğrenme, Bayeşçi yaklaşımlar (Kalman süzgeci, parçacık süzgeci, vb.), dolandır matris.

#### Abstract

The visual target tracking has a long history and it still continues to be an active and important research problem in computer vision. Target tracking problem may be defined as tracking an object of interest from the video data recorded by a still or a moving camera. The variations in the conditions of the environment where tracking is performed as well as the changes in the motion of the object to be tracked are the major challenges that make visual target tracking an interesting problem. A successful target tracking algorithm should be robust against illumination variations in the environment, visual noise, low contrast, occlusions of the other objects in the environment, undesired movements of the camera which displays the target, etc. The research on visual target tracking fundamentally developed along two main streams: Generative techniques and discriminative

techniques. In this paper, both generative and discriminative target tracking algorithms have been investigated and their advantages and disadvantages are presented in terms of comparisons based on the analyses reported. Furthermore, the databases and the evaluation metrics which are used in the literature for the performance evaluation are explicated.

**Keywords:** Computer vision, generative methods, discriminative methods, structured SVM (Support Vector Machines), deep learning, Bayesian approaches (Kalman filter, particle filter etc ..), circulant matrix.

#### 1. Giriş

Hedef takibi, son yıllarda bilgisayarla görü alanında en çok ilginin gösterildiği ve çalışmanın yapıldığı problemlerden biridir. Hedef takibi problemi, sabit ya da hareketli bir kameradan (TV/IR) alınan video verisi üzerinde ilgilenilen nesnenin izlenmesi olarak tanımlanabilir. Askeri ve sivil birçok uygulamada karşımıza çıkan hedef takibine; bina/tesis güvenlik sistemleri ve trafik gözetleme kameralarında insan/yaya, araç takibi veya insansız hava araçlarından (İHA) aktarılan hava görüntülerinde şüpheli cisim/insan takibi uygulamaları örnek olarak verilebilir.

Literatürde hedef takip problemine, gerçek zamanlı yaklaşan çalışmalar olduğu gibi çevrim dışı çalışmalar da bulunmaktadır. Ancak bu makalede pratikte daha çok uygulanabilir olan gerçek zamanlı hedef takibi yöntemleri ele alınmaktadır. Gerçek zamanlı hedef takibinin doğru ve sürdürülebilir olarak gerçekleştirilebilmesi için takip yönteminin, ortamda meydana gelebilecek ışık değişimi, düzlem dışı dönüş, ölçek değişimi, örtüşme, biçim bozulması, hareket bulanıklığı, hızlı dinamik hareket, düzlem içi dönüş, görüş açısının dışına çıkılması, arkaplan ile karışım ve düşük çözünürlük gibi olumsuzluklara karşı başarılı bir şekilde çalışması gerekmektedir. Ancak mevcut yöntemler incelendiğinde tüm değişimlere karşı gürbüz bir algoritma geliştirilmesinin çok zor olduğu, bundan dolayı belirli alt problemlerin çözümüne yönelik yaklaşımlar geliştirildiği söylenebilir. Örneğin bir yöntem ışık değişimlerine karşı iyi sonuçlar verirken hedefin ortamda bulunan diğer nesnelere ile olan etkileşimini takip edememektedir. Öte yandan etkileşimleri başarı ile takip edebilen bir yöntem kamera açısından ya da hedefin dinamik hareketlerinden dolayı

oluşacak hedef görsel değişimlerini başarı ile algılayıp uyarı verememektedir.

Görsel takip çalışmaları tarihsel olarak, basit hedef modeli kullanarak arama yaklaşımıyla başlamış, daha sonra hedef modellerini yinelemeli olarak güncelleyen yaklaşımlar geliştirilmiştir. Diğer taraftan makine öğrenme yöntemlerinden faydalanarak hedef ve arkaplanın sınıflandırılması yönünde çalışmalar yapılmıştır. Son yıllarda ise yapılandırılmış destek vektör makineleri ile derin öğrenme yöntemlerine dayalı algoritmalar geliştirilmiştir. Bu çalışmaların bazılarında ise Bayesçi yaklaşımlar ile hedef model örnekleme gerçekleştirilmektedir. Bu çerçevede hedef takip yöntemleri genel olarak iki sınıfta toplanabilmektedir; üretici (generative) yöntemler ve ayırdedici (discriminative) yöntemler. Üretici yöntemler hedef takip problemini, hedef modeline benzer olan imge bölgelerinin/pencerelerinin aranması olarak formüle ederken, ayırdedici yöntemler hedefin arkaplandan ayırt edilebilmesi amacıyla hedef takibini sınıflandırma problemi olarak tanımlamaktadırlar.


Hedef takip yöntemlerinde, bir video üzerinde hedefin konum, hız, büyüklük, dönme vb. özelliklerinin izlenmesi amaçlandığından bu parametrelerin takip edilmesi için kullanılan yöntemler, gözlem ve hareket modellerinin örnekleme ve güncellenmesi açısından çeşitlilik göstermektedir. Gözlem modeli, hedefin takibinin yapılması amacıyla görsel özniteliklerinin bir referansa göre değerlendirilmesi için gerekli fonksiyon olarak tanımlanırken, hareket modeli ise hedefin konum, hız, rotasyon vb. dinamik hareket parametrelerinin takibi amacıyla tasarlanmış olan denklemler olarak adlandırılmaktadır. Gözlem ve hareket modellerinin örnekleme için Kalman ve parçacık süzgeçleri, ilinti ilişkileri, gradyan temelli uyarılma algoritmaları, Metropolis Hastings gibi örnekleme algoritmaları kullanılabilir. Gözlem ve hareket modellerinin güncellenmesi için ise Kalman ve parçacık süzgeçleri, kademeli temel bileşen analizi, seyrek temel bileşen analizi, doğrusal diskriminant analizi, Pozitif-Negatif (P-N) öğrenme, gerçek zamanlı adaboost, sırt regresyonu, yapılandırılmış destek vektör makineleri, ilinti süzgeci gibi yöntemler kullanılabilir. Bu makalede, [1] ve [2]'de araştırılan yöntemlere, en güncel çalışmalar ilave edilerek mevcut literatür çalışmalarının genişletilmesi ve en yüksek başarıyı sergileyen çalışmalara dikkat çekilmesi amaçlanmaktadır.

Makalenin ikinci ve üçüncü bölümlerinde sırasıyla üretici ve ayırdedici yöntemler anlatıldıktan sonra dördüncü bölümde, önerilen yöntemlerin başarımlarını değerlendirmelerinde kullanılan veri kümeleri ve karşılaştırma ölçütleri açıklanmaktadır. Beşinci bölümde mevcut tüm yöntemler hakkında genel bir karşılaştırmalı değerlendirme yapıldıktan sonra sonuçlara ve gelecek çalışmalara vurgu yapılmaktadır.

## 2. Üretici Yöntemler

Üretici yöntemler, hedef takip problemini hedef modeline benzer imge pencerelerinin sıralı olarak aranması yoluyla çözmektedir. Burada amaç, hedefin görsel modelinin oluşturulması ve bu modele karşılık gelen en iyi imge penceresinin bulunmasıdır. Bu sınıfa giren yöntemlerde arkaplan değerlendirmeye alınmamaktadır. Mevcut yöntemler hedef modelinin güncellenip güncellenmemesine;

güncellenmesi durumunda ise güncellenme şekline ve kısıtlamalara göre kendi arasında üçe ayrılmaktadır: Model karşılaştırmalı takip (Tracking With Template Matching (TTM)) [3], [4], [5], [6], [7], [8], [9], genişletilmiş görünüm modeli karşılaştırmalı takip (Tracking Using Template Matching With Extended Appearance Model (TTMEAM)) [10], [11], [12], [13] ve kısıtlama ile model karşılaştırmalı takip (Tracking Using Template Matching With Constraints (TTMC)) [14], [15], [16]. Üretici yöntemlere ait genel akış diyagramı Şekil-1'de sunulmaktadır.



Şekil-1: Üretici Yöntemlere Ait Genel Akış Diyagramı

### 2.1. Model Karşılaştırmalı Takip (TTM)

Model karşılaştırmalı takip yaklaşımına dayalı algoritmalarda ya videonun başında oluşturulmuş gözlem modeli ya da hedefin bir önceki video imgesinden yinelemeli olarak tahmin edilen hedef modeli kullanılmaktadır. Bu yöntem içinde öne çıkan incelemelerden birisi **Düzgelenmiş Çapraz İlinti (Normalized Cross-Correlation (NCC))** yöntemidir [3]. Bu yöntem, hedef modelinin (referans) mevcut video imgesi üzerinde çapraz ilintilerini kullanmakta ve Fourier dönüşümünden daha hızlı bir şekilde hedefin bulunmasını sağlamaktadır. Hedef, dikdörtgenel temel fonksiyonların toplamı şeklinde modellendikten sonra ilinti işlemi gerçekleştirilmektedir.

**Lucas Kanade takipçi (Lucas Kanade Tracker (KLT)) yöntemi** [4] ise bir önceki video imgesinde tahmin edilen hedef modelini bir sonraki video imgesinde bulabilmek için hedef modelinin afin parametrelerini (yer değiştirme, dönme, ölçekleme) yinelemeli şekilde tespit etmektedir. En iyi eğrilme

parametresini bulabilmek için Gauss Newton Gradyan İnişi yöntemi kullanılarak hedef modeliyle hedef olmaya aday imge pencereleri arasındaki hata, yinelemeli şekilde, en aza indirgenmeye çalışılmaktadır.

**Kalman Görünüm Takipçisine (Kalman Appearance Tracker (KAT))** [5] göre hedef modelini oluşturan pikseller renk uzayında sahip oldukları nitelik değerlerine göre takip edilmektedir. Takip işlemi, hedef modelini oluşturan her bir pikselin geçirdiği dönüşüme ait afin parametrelerin gradyan inişi algoritmasıyla bulunması esasına dayanır. Parametrelerin bulunması için hedef modelinin video boyunca yaşadığı görüntü değişimlerinin takip edilmesi gerekmektedir. Bu amaçla, piksellerin maruz kalacağı gürültü (ölçüm hatası, ışık değişimi vb.) Kalman süzgeciyle öngörülerek azaltılmaktadır. Kısmi örtüşme problemi Kalman süzgecinin ölçüm modelinde bulunan hata fonksiyonuyla birleştirilerek çözülmektedir.

**Parça Tabanlı Gürbüz Takip yöntemi (Fragments-based Robust Tracking (FRT))** [6], hedef modelinin yatay ya da dikey olarak belirli sayıda küçük dikdörtgen pencerelere bölünerek takip edilmesi mantığına dayanmaktadır. Her pencereye ait renk histogramları [17]'de belirtildiği şekilde tümleşik imge çıkarılarak ifade edilmektedir. Birden fazla pencerenin kullanılması, takibi yapılması istenen hedefin konum bilgisinin kaybolmasını engellemektedir. Hedef modelinden alınan parçalar ile mevcut imge üzerinde alınan parçalar arasındaki benzerliğin ölçülmesinde Öklid Mesafesi ve Earth Mover's Mesafesi [18] (Earth Mover's Distance (EMD)) metrikleri kullanılmaktadır. Son aşamada hedef konumunun tahmin edilmesi amacıyla bir karar verici kullanılarak takip gerçekleştirilmektedir.

**Düzensiz Yerel Takip (Locally Orderless Tracking (LOT))** [7] yönteminde ise hedef modeli üzerinde oluşacak yerel bozulmalar ya da değişimler takip edilmektedir. Hedef modeli ile hedef aday arasındaki benzerlik, süper piksel [19] sunumuyla ifade edildikten sonra parçacık süzgecinin olabirlik fonksiyonu olarak kullanılan EMD ile hesaplanmaktadır. Rotasyon ve ışık değişimi faktörleri parçacık süzgecinde kullanılan gürültü değişkenlerinin kullanılması ile modellenmekte ve yinelemeli olarak tahmin edilebilmektedir.

Model karşılaştırmalı bir diğer takip yöntemi olan **Ortalama kaydırma (Mean Shift Tracker (MST))** [8] yönteminde, hedef modeli ile aday imge pencereleri renk histogramları ile modellenmekte ve oluşturulan dağılımlar aralarındaki benzerlik Bhattacharyya uzaklık metriği kullanılarak bulunmaktadır. Bir sonraki imgede benzerliğin en fazla olduğu konumun belirlenmesi yinelemeli bir şekilde ortalama kaydırma algoritmasıyla gerçekleştirilir.

**Tespit-ile-Takip ve Marjinal Parçacık Süzgecinin Birleştirilmesiyle Nesne Takibi (Object Tracking by Combining Tracking-by-Detection and Marginal Particle Filter (TDMPF))** [9] yönteminde ise dolanır matris teorisi ile hızlı Fourier dönüşümü kullanan Gauss çekirdeğine dayalı tespit-ile-takip yöntemiyle marjinal parçacık süzgeci yöntemi bir arada kullanılmaktadır. Marjinal parçacık süzgeci, takip edilen nesnenin etrafında yayılan her bir parçacığın ağırlıklandırılması için süzgecin ölçüm safhasında Gauss

çekirdeğinden elde edilen skorları kullanılmaktadır. Marjinal parçacık süzgeçleme ile durum değişkenleri güncellenerek nesne konumu, bu konuma ait düzeltme değerleri ile nesneyi çevreleyen imge penceresinin boyutları tahmin edilmektedir.

## 2.2. Genişletilmiş Görünüm Modeli Karşılaştırmalı Takip (TTMEAM)

Bu yaklaşımda hedef takibi, video değişimlerine karşı hedef modelinin yinelemeli olarak güncellenmesi esasına dayanır. Modelin yinelemeli olarak güncellenmesi alt uzayda kademeli temel bileşenler analizi ya da diğer alt uzay sunum tekniklerinin kullanılması ile gerçekleştirilmektedir.

**Kademeli görsel takip (Incremental Visual Tracking (IVT))** [10], [20] yönteminde hedef hareketleri ve ortamdaki değişimlere karşı gürbüz bir şekilde takip yapılması amacıyla hedef, temel bileşenler analizinden faydalanarak alt uzayda modellenmektedir. Bu model, parçacık süzgecinin olabirlik fonksiyonunu kullanılarak hedefe ait konum, dönme ve ölçek bilgilerini takip etmeye çalışmaktadır.

**Örnekleme Takipçileri ile Takip Yöntemi ((Tracking By Sampling Trackers) TST )** [11] ise birden fazla takip ediciyi paralel olarak kullanılmaktadır. Her bir takip edici hareket modeli, gözlem modeli, durum denklem değişkenleri ve ölçüm modeli değişkenleri olmak üzere dört farklı unsurun bir araya getirilmesiyle oluşturulmaktadır. Bu unsurların çeşitlendirilerek örnekleme yapılmasındaki ana fikir, takibin yapıldığı ortamda meydana gelen ışık değişimleri, örtüşme, gürültü, poz değişimleri, ani dinamik hareketlere karşın takibin gürbüz şekilde yapılmasıdır. Takip edicilerin sonsal dağılımları, Metropolis Hastings algoritması kullanılarak hesaplanmakta ve en büyük değere sahip takipçinin verileri ile takip yapılmaktadır. Takip edicilerin sayısı ve özellikleri, hareket ve görünüm değişkenlerine bağlı olarak yinelemeli bir şekilde belirlenmektedir.

**Uyarlamalı Yapısal Yerel Seyrek Görünüm Modeli Kullanarak Görsel Takip (Visual Tracking Via Adaptive Structural Local Sparse Appearance Model (ASLA))** [12] yönteminde, seyrek (sparse) sunum tekniği kullanılarak hedefin konumsal ve bölümsel takibinin yapılması amaçlanmaktadır. Hedef modeli, birbiri ile örtüşecek şekilde alt pencerelere ayırışmakta ve bu pencerelerin öznitlikleri yerel seyrek kodlama tekniği ile bulunmaktadır. Pencerelere ait seyrek kodlar, modelin konumsal ve bölümsel bilgisini içermektedir. Hedef modeli ile hedef aday arasındaki benzerlik ölçütü ise muvazaat-havuzlama yöntemi ile elde edilmektedir. Bu yöntemin en önemli avantajlarından birisi yerel seyrek kodların geçmişte bulunmuş olan hedef modelleri ile yinelemeli olarak güncellenmesidir. Güncellenme, seyrek sunum tekniği ile kademeli alt uzayda öğrenim yönteminin birleştirilmesi ile yapılmaktadır [10]. Bu şekilde, örtüşmenin yaşanmadığı hedef modellerine daha fazla önem verilerek kısmi örtüşmeye ve model değişimlerine karşı etkin bir algoritma elde edilmektedir. Örnekleme için ise parçacık süzgeci kullanılmaktadır.

**Afin Grup Üzerinde Takip (Tracking on Affine Group (TAG))** [13] yönteminde ise, hedef modeli yinelemeli olarak güncellenmekte ve iki boyutlu afin dinamik hareket parçacık

süzgeci ile takip edilmektedir. Özellikle, yüksek dinamik hareket gösteren hedeflerin takibinde, durum denklem değişkenlerinin başarılı olarak tahmin edilmesi için en uygun önem fonksiyonunun bulunmasına yönelik araştırma yapılmaktadır.

### 2.3. Kısıtlama ile Model Karşılaştırmalı Takip (TTMC)

Hedef modeli, pencerelerden oluşacak şekilde seyrek sunum tekniği ile takip edilmeye çalışılmaktadır. Bu sayede tek bir çevreyici pencere ile yapılamayan takip işlemi birden fazla küçük pencere ile başarılmaktadır.

**Monte Carlo Örnekleme ile Takip (Tracking by Monte Carlo Sampling (TMC))** [14] yönteminde, hedef modeli yerel pencerelere ayrılarak modellenmekte ve takip edilmektedir. Pencerelerin, modelin merkezine göre örnekleme Basın Hopping Monte Carlo (BHMC) yöntemi ile yapılmakta olup, olabirlik dağılımları, fotometrik olabirlik dağılım modeli ile geometrik dağılım modelinin birleşimi ile elde edilmektedir. Önerilen yöntemin ana motivasyonu esnek ya da bükülebilir hedeflerin takibini sağlamaktır.

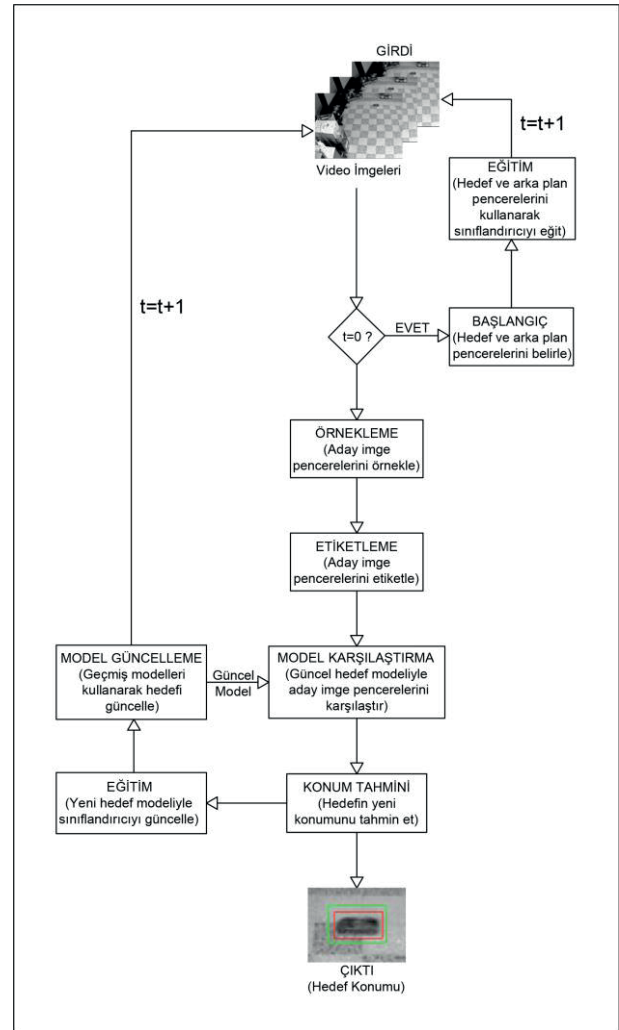
**Yinelemeli Birleştirilmiş Katman Takibi (Adaptive Coupled Layer Tracking (ACT))** [15] yönteminde ise ani ve büyük ölçekli görünüm değişimi geçiren, esnek ya da bükülebilir hedef modeli, pencerelere bölünerek takip edilmektedir. Hedefin hızı Kalman süzgeci kullanılarak tahmin edilmekte, imge pencerelerinde hedef modelin takibi iki katmanlı olarak sağlanmaktadır. Yerel katmanda, pencerelerin zamana bağlı olarak geometrik ve görünüm değişimleri Bayesçi yaklaşımla tahmin edilmekte ve sonsal dağılımları yüksek olan pencereler genel katmanda kullanılmaktadır. Genel katmanda ise seçilen pencerelerin bir araya getirilmesiyle hedefin görsel özelliklerine (renk, görünen hareket (piksel hareketi), şekil) ait sonsal dağılım oluşturulmaktadır.

**L1-Azaltma Takip yöntemi (L1-Minimization Tracker (L1T))** [16]'nde hedef takibi, seyrek sunum yöntemiyle parçacık süzgecini birlikte kullanan melez bir yaklaşımla yapılmaktadır. Pozitif (hedef olmaya aday) ve negatif (arkaplan olmaya aday) hedef modelleri seyrek sunum yöntemi kullanılarak seyrek matris oluşturulmakta ve tahmini hedef modeli bulunmaktadır. Pozitif ve negatif model katsayılarının L-1 azaltma yöntemi [21] ile güncellenmesi ile örtüşme ve gölge etkileri giderilirken, örnekleme için parçacık süzgecinden istifade edilmektedir. Bu güncellenmenin sonucunda hedef modeline ait seyrek sunum bulunmakta, parçacık süzgeci ile afin dönüşüme ait altı adet parametrenin (deformasyon için dört adet ve iki boyutlu hareket için iki adet) takibi gerçekleştirilmektedir.

## 3. Ayırdedici Yöntemler

Ayırdedici yöntemler, hedef modeli ile arkaplanın birbirinden ayırt edilmesi yoluyla model takibini gerçekleştirmektedirler. Hedef ile arkaplanın modellenilmesi için basit etiketleme-gruplama teknikleri, yapılandırılmış destek vektör makineleri ile derin öğrenme teknikleri kullanılmaktadır. Üretici yöntemlere nazaran en göze çarpan farklılık, hedef takibi

yanında arkaplanın da modellenerek takibinin yapılmasıdır. Ayırdedici yöntemler kendi içerisinde 3 gruba ayrılabilir: ayırdedici sınıflandırma ile takip (Tracking With a Discriminative Classifier (TDC)) [22], [23], [24], [25], [26] kısıtlama ile ayırdedici sınıflandırma kullanarak takip (Tracking Using Discriminative Classifier With Constraints (TDCC)) [27], [28], [29], [30], derin öğrenme ile görsel takip (Tracking With Deep Learning (TDL)) [31], [32]. Ayırdedici yöntemlere ait genel akış diyagramı Şekil-2'de sunulmaktadır.



Şekil-2: Ayırdedici Yöntemlere Ait Genel Akış Diyagramı

### 3.1. Ayırdedici Sınıflandırma İle Takip Yöntemi (TDC)

Hedef modeli ile arkaplanı öğrenmek için ayırdedici fonksiyon, adaboost ve Pozitif-Negatif öğrenme gibi yöntemlerle örneklenen imge pencereleri etiketlenerek hedef takibi yapılmaktadır.

**Önplan-Arkaplan takip yöntemi (Foreground-Background Tracker (FBT))** [22], hedef modeli ile arkaplanı ayırmak için desene dayalı ayırdedici bir yöntem kullanılmaktadır. Hedef modeline ve arkaplanına ait imge pencerelerinin desen özellikleri Gabor süzgeciyle çıkarıldıktan sonra doğrusal ayırma analizi [33] uygulanarak en iyi ayırdedici sınıflandırıcı bulunmaktadır. Arkaplan desen özelliklerinin takip süresine

dahil edilmesi, arkaplanı değerlendirmeyen hedef takip yöntemlerine nazaran üstünlük sağlamaktadır. Özetle, hedef takip problemi, hedef ile arkaplan imge pencerelerinin öznitelik uzayında maksimum ayırımı sağlayan vektörün bulunması problemine dönüştürülmektedir.

**Birden Fazla Örnek Öğrenme takip yöntemi (Multiple Instance Learning Tracker (MIT))** [23] ile ayırıcı sınıflandırıcı eğitilerek hedef modeli, arkaplan imge pencerelerinden ayrılabilir. Hedef modeli durum denklemleri ile dinamik olarak ifade edilmektedir. Durum değişkenlerine, hedef konumu dahil edilmekte, ölçek ve dönme parametreleri hariç tutulmaktadır. Hedef modeline benzer imge pencereleriyle arkaplana benzer imge pencereleri bireysel olarak etiketlenmek yerine dahil oldukları imge havuzları etiketlenmektedir. En az bir hedef modeline benzer imge penceresi bulunan havuz pozitif olarak etiketlenirken, arkaplan imge pencerelerinin bulunduğu havuz(lar) ise negatif olarak etiketlenmektedir. Havuzlarda bulunan imge pencerelerinin öğrenilmesinde Gerçek Zamanlı Ada-Boosting [34] kullanılmaktadır. Zayıf Haar öznitelik çıkarıcılarının bir araya getirilmesi ile güçlü Haar öznitelikleri oluşturulmakta ve bu şekilde görüntüdeki değişimlere karşı gürbüz hedef takibi gerçekleştirilebilmektedir.

**Takip, Öğrenme ve Tespit (Tracking, Learning and Detection (TLD))** [24] yöntemi, Lucas Kanade takip algoritması ile ikili sınıflandırıcı öğrenim yöntemini birlikte kullanarak takibin yapılmasını sağlamaktadır. Hedef modeli olmaya aday pencerelerin etiketleri, hedefin hareket izine olan uzaklıkları referans alınarak pozitif-negatif öğrenim yöntemiyle güncellenmektedir. Bir sonraki video imgesinde, yeni örneklenen ile geçmişte etiketleri düzeltilmiş olan pencereler kullanılarak sınıflandırıcı yeniden eğitilmekte ve Lucas Kanade takibi yapılmaktadır. Bu yöntemin başarısı, pozitif-negatif öğrenme yöntemindeki kısıtlayıcılarının “hata azaltım” özelliğine bağlıdır.

**Çekirdekleştirilmiş İlinti Süzgeci (Kernelized Correlation Filter (KCF))** [25], [26]’nde tespit ile takibin hızlı bir şekilde yapılabilmesi için dolanır matrisin ayrık Fourier dönüşümü ile olan bağıntısı ortaya konulmaktadır. Dolanır matrisin satırları, hedef modeli ile modelin çevrimsel kaydırmalarından oluşmaktadır. İmge pencerelerinin öğrenilmesi için sırt regresyonu, ayrık Fourier dönüşümü ile frekans uzayında tanımlanmaktadır. İmge pencerelerinin öğrenilmesi sonrasında elde edilen ağırlık parametreleri frekans uzayında test imgeleri ile çarpılarak hedefin muhtemel konumu bulunmaktadır. Öğrenme sırasında, üç boyutlu renk öznitelikleri ya da yönlü gradyan histogram öznitelikleri kullanmakta ve sırt regresyon problemi, çekirdek hilesi kullanılarak doğrusal hale getirilmektedir. [26]’da ise doğrusal çekirdeğin ikili uzayda tanımlanan yeni katsayılar ile birleştirilmesiyle **ikili korelasyon süzgeci (Dual Correlation Filter (DCF))** elde edilmektedir. Bu süzgeç, çekirdekleştirilmiş ilinti süzgecinin görevini, çekirdek hilesi kullanarak ikili uzayda yerine getirmektedir.

### 3.2 Kısıtlama İle Ayırıcı Sınıflandırma Kullanarak Takip Yöntemi (TDCC)

Bu sınıfta bahsedilen yöntemler, hedef modelinin ve

arkaplanın destek vektör makineleri ile eğitilmesi yoluyla sınıflandırıcı fonksiyonun değişen takip koşullarına göre güncellenmesi prensibine dayanmaktadır. Bu sayede yapılandırılmış destek vektör makinelerinin imge pencerelerine ait etiket değeri yerine hedef modelini çevreleyen pencerenin tahmini değeri elde edilmektedir.

**Çekirdekler ile Yapılandırılmış Çıktı Takibi (Structured Output Tracking With Kernels (STRUCK))** [27], [28] yönteminde yinelemeli takip yapılması amacıyla çekirdekleştirilmiş ve yapılandırılmış destek vektör makinelerinden yararlanılmaktadır. STRUCK yönteminde amaç, örnekleme ve etiketleme işlemlerini ayrık yapmak yerine doğrudan video imgeleri arasında yaşanan dönüşümleri tespit ederek takip yapmaktır. Öğrenme problemi, karesel en iyileme (LaRank) [35] ve ardışık en küçükleme ile en iyileme (Sequential Minimization Optimization (SMO)) [36] tekniğinin kullanılması ile çözümlenmektedir. [27]’de sadece iki boyutlu hareket değişkenleri kullanılırken, [28]’de ise iki boyutlu hareket değişkenine ek olarak ölçekleme değişkeni de kullanılmaktadır. Örnekleme amacıyla farklı arama yarıçaplarına bağlı basit bir mekanizma kullanılmakta ve model, kaba piksel değerleri, Haar veya histogram öznitelikleri ile tanımlanmaktadır. Öğrenme süresince ise doğrusal, Gauss ve kesişim çekirdeklerinden faydalanılmaktadır. [28]’de göze çarpan bir diğer gelişme de THUNDERSTRUCK yöntemiyle imge işlem hızının artırılmış olmasıdır. Ancak işlem hızı artırılırken, elde edilen sonuçlar STRUCK yöntemine göre azalma göstermektedir.

Son zamanlarda yapılandırılmış destek vektör makinelerinin kullanılması ile hedef takibinde ciddi gelişmeler yaşanmaktadır. Ancak bahse konu yöntemlerde, işlem süresini arttıran en iyileme ya da regresyon yöntemleri kullanmasından dolayı gerçek zamanlı uygulamalarda kullanımları kısıtlı olmaktadır. Bu problemi çözmek ve daha hızlı öğrenme ile takibin yapılmasını sağlamak amacıyla, **İkili Lineer Yapılandırılmış Destek Vektör Makineleri Kullanarak Hedef Takibi (Object Tracking via Dual Linear Structured SVM and Explicit Feature Map (DLSSVM))** [29] yöntemi öne sürülmüştür. Birincil doğrusal denklemin kapalı formda bulunmasıyla katsayıların kademeli olarak öğrenilmesi için çok yüksek boyutlu öznitelik vektörlerinin kullanımı mümkün olmaktadır. Bu sayede takibin güvenilirliği artırılırken, kesişim çekirdeğinde öznitelik haritalarının kullanılması ile de doğrusal olmayan karar sistemi takip problemine dahil edilmektedir. Öznitelik haritaları, CIE Lab [30] renk uzayına dayanan öznitelik sunumu [37] ile parametrik olmayan yerel kademe dönüşümünün (non-parametric local rank transform (LRT)) birlikte kullanılmasıyla elde edilmektedir. Bu haritalar [38] tek bileşenli sunum tekniği ile yeniden şekillendirilmektedir. LRT, ışık değişimine karşı olan zayıflığın azaltılması için kullanılmakta olup, doğrusal öğrenme problemi, [39] basit ikili koordinat iniş (basic dual coordinate descent (DCD)) yöntemi ile çözümlenmektedir. Böylece ağırlık katsayısı, SMO’nun aksine her yinelemede kademeli olarak öğrenilmektedir. Öğrenme sonucunda yapılandırılmış çıktıya en yüksek değeri sağlayan afin dönüşüm hedefe ait konum olarak kabul edilmektedir.

Hedef takip problemlerinde yaşanan bir diğer problem ise hedef modelinde sapmaların meydana gelmesidir. Entropi

**Azaltma Kullanarak Birden Çok Uzman Vasıtasıyla Gürbüz Takip (Robust Tracking via Multiple Experts Using Entropy Minimization (MEEM))** [30] yönteminde sapma probleminin giderilmesi amacıyla birden fazla uzman kullanım yaklaşımı izlenmektedir. Bu sayede hatalı model güncellenirken geçmişten gelen uzmanlar (geçmiş anlık modeller) kullanılarak hedef tahmini düzeltilmektedir. Bu amaçla, düzenlenmiş entropi eniyilemesi [40] ile kısmi-etiket öğrenme (partial-label learning) birlikte kullanılarak kayıp/hata fonksiyonu çözülmektedir. Takip algoritmasının çatisını oluşturan tespit-ile-takip kısmı ise doğrusal destek vektör makinelerinin öznelilik haritaları [38] ile birlikte kullanılmasıyla gerçekleştirilmektedir. Öznelilik haritaları, DLSSVM [29]'deki gibi bulunmakta ve kesişim çekirdeği kullanılarak doğrusal olmayan ayırdedici sınıflandırıcı bulunabilmektedir. Bu yöntem sayesinde geçmiş ya da mevcut hedef modelinde oluşan sapmaların tespiti ve onarımı için modelin geçmişe doğru güncellenmesi yapılmaktadır.

### 3.3. Derin Öğrenme İle Görsel Takip Yöntemi (TDL)

Son zamanlarda görsel takip uygulamalarında derin öğrenme yaklaşımlarından çokça faydalanılmaktadır. Gerçek zamanlı ya da çevrim dışı olarak geleneksel sinir ağları kullanılarak hedeften ve arkaplan örneklemelerinden öznelilik çıkarılmaktadır. Bu öznelilikler, ilinti süzgeçleri ile öğrenilmekte ve hedef takip edilmektedir.

**Hirerarşik Evrişimsel Öznelilikler ile Görsel Takip (HCFT (Hierarchical Convolutional Features for Visual Tracking))** [31] yönteminde geleneksel sinir ağları ile doğrusal ilinti süzgeçleri birlikte kullanılmaktadır. Hedefin gözlem modelindeki sapma probleminin engellenmesi için sinir ağının her katmanından elde edilen özellikler, doğrusal ilinti süzgecinden geçirilerek örneklenmektedir. **Derin Takip (Deep Track (DT))** [32]'te ise dört seviye evrişimli sinir ağlarından faydalanılarak hedefi en iyi ayırtıran öznelilik bulunmakta ve takip gerçekleştirilmektedir. Takip algoritması, Olasılıksal Gradyan İniş (Stochastic Gradient Descent (SGD)) en iyileştirme yöntemi ile Gauss dağılım örneklemesini birlikte kullanmaktadır. İmge pencerelerinden çıkarılan üç adet ayrı öznelilik (iki adet farklı parametrelerle yerel olarak normalleştirilmiş öznelilikler ve bir adet gradyan özneliği) eş zamanlı olarak evrişimsel sinir ağlarına uygulanmakta ve elde edilen skora göre o anki tahmini hedef durumu tespit edilmektedir.

## 4. Karşılaştırma Ölçütleri

Bahsedilen yöntemlerin başarımlarının adil olarak karşılaştırılması için kullanılacak video bilgi bankaları [1], [2]'de belirtilmiştir. [41] ALOV300++ (Amsterdam Library of Ordinary Videos) video bilgi bankasında takibi zorlaştıran birçok durumun yansıtıldığı yaklaşık üç yüz adet video bulunmaktadır. Ayrıca literatürde sıklıkla kullanılmakta olan ve kesin referans (groundtruth) bilgisi bulunan videoların bir araya getirilmesi ile oluşturulmuş olan TB (Tracking Benchmark)-100 ve TB-50 video bilgi bankaları [42] yer almaktadır.

Hedef takibinin en önemli unsurlarından birisi de takip yönteminin başarısının ölçülmesidir. Bu ölçümlerin

yapılabilmesi için literatürde birden fazla metrik öne sürülmektedir. Bu metrikler belirlenirken hedef ile kesin referans arasındaki pozisyon bilgisinin doğruluğu, video süresince hedefte oluşabilecek görsel değişimlere karşı gürbüz ölçüm yeteneği gibi faktörler göz önünde bulundurulmaktadır. Yalnızca bir hedefin takibi amacıyla kullanılan en genel metriklere [1]'de yer verilmektedir. Takip süresince referans alınan 3 hata tipi mevcuttur.

- Sapma: Takip edilen hedef konumunun kesin referans değerinden sapması.
- Yanlış Pozitif: Takip algoritmasının hedef olmayan bir nesneyi hedef olarak tanımlaması.
- Yanlış Negatif: Takip algoritmasının hedefi tanımlayamayıp yerini saptayamaması

Hedefi çevreleyen pencere ile kesin referans penceresinin örtüşme miktarını ölçmek maksadıyla kullanılan en yaygın yöntem PASCAL metriği olup (1)'de belirtilmiştir.

$$\frac{|H^i \cap KR^i|}{|H^i \cup KR^i|} \geq 0.5 \quad (1)$$

$H^i$ , i'ninci video imgesinde hedefi çevreleyen pencereyi,  $KR^i$  ise kesin referans penceresini temsil etmekte olup, şartın sağlanması durumunda takibin başarı ile yapıldığı anlaşılmaktadır. Tablo-1'de sunulan metriklerin hesaplanmasında ise doğru pozitif, yanlış pozitif ve yanlış negatiflerin sayısını belirten  $n_{dp}, n_{yp}, n_{yn}$  parametreler kullanılmakta olup hassasiyet (precision) ve anımsama (recall) sırasıyla  $n_{dp}/n_{dp} + n_{yp}$  ve  $n_{dp}/n_{dp} + n_{yn}$  ile hesaplanmaktadır.

Tablo-1'de belirtilen metriklerin yanı sıra, tek-geçişli değerlendirme (One-Pass Evaluation (OPE)), zamansal gürbüzlük değerlendirmesi (Temporal Robustness Evaluation (TRE)) ve konumsal gürbüzlük değerlendirmesi (Spatial Robustness Evaluation (SRE)) yaklaşımları ile de takip algoritmasının gürbüzlüğü değerlendirilmektedir. OPE yaklaşımında, hedef takibi, ilk imgede kesin referans bilgisi kullanılarak başlatılır ve video sonuna kadar doğruluk ya da başarı ölçümü Tablo-1'de belirtilen metriklerle hesaplanmaktadır. TRE yaklaşımında, her hedef takip denemesine farklı bir imgeden başlanmakta ve elde edilen sonuçlar deneme adedine bölünerek ortalama başarı hesaplanmaktadır. SRE yaklaşımında ise takibe kesin referans bilgisine gürültü eklenmesi ile başlanarak hedef tespitinin hatalı yapıldığı durumların benzetimine olanak sağlanmaktadır.

## 5. Genel Değerlendirme

Bu bölümde şu ana kadar bahsedilen yöntemler hakkında objektif değerlendirmelere yer verilmektedir. Değerlendirmeler referanslarda sunulan sonuçlara göre yapılarak yöntemler karşılaştırılmaktadır.

**Üretici yöntem** grubuna dahil olan **hedef modeli kullanarak hedef takibi** yapan NCC [3], işlem hızı ile ön plana çıkarken hedef modelinin yinelenmeli olarak güncellenmemesi hedef takibini zorlaştırmaktadır. **KLT** [4] ile afin dönüşüm parametreleri başarılı şekilde takip edilmekte; **KAT** [5] ile

afin dönüşüm parametreleri başarı ile hesaplanmakta ve kısmi örtüşme durumunda hedef modeli güncelleme mekanizması durdurulmaktadır. Bu sayede hedef modelinin hatalı olarak güncellenmesi engellenmektedir. **FRT** [6] yönteminde ise esnek olmayan, parçalı bir hedefin takibi için ilerleme sağlanmakta ve EMD uzaklık metriğinin kullanımıyla doğruluk oranını arttırılmaktadır. Ancak örnekleme yönteminin ilkel olması dinamik hareketin takibinde problem yaratmakta ve hedef modelinin yinelemeli olarak güncellenmemesi ani poz değişimlerine karşı hatayı arttırmaktadır. **LOT** [7]'ta göze çarpan en önemli özellik parçacık süzgecinin dinamik hareketin takibinde örnekleme amacıyla kullanılmasıdır. Yöntemin zayıf tarafı ise gri seviyeli imgelerle çalışmaya olanak sağlamamasıdır. Hedef modelinin yinelemeli olarak güncellenmesi ile hedef takip başarısı arttırılmaktadır. **TDMPF** [9], dolanır matris teorisi ile hızlı Fourier dönüşümü kullanan Gauss çekirdeğine dayalı tespit-ile-takip yöntemiyle marjinal parçacık süzgecini birleştirerek hızlı dinamik harekete karşı gürbüz takip yapmaktadır. Bunu sağlayan yöntemlerden bir diğeri olan **IVT** [10]'da ise hedef temel bileşenlerinin kademeli olarak yinelenmesi ve hedef modelinin oluşturulması yöntemin, gözlem değişimlerine karşı gürbüz olmasını sağlarken parçacık süzgecinin kullanımı dinamik hareketlere karşı bağımsızlık sağlamaktadır. **TST** [11]'de ise diğer yöntemlerden farklı olarak birden fazla takip edicinin kullanılması takibin daha güvenilir yapılmasına olanak sağlamaktadır. **ASLA** [12]'da hedef modeli yinelemeli olarak güncellenerek parçacık süzgecinin kullanımı ile dinamik hareketin takibi gerçekleştirilebilmektedir. **Kısıtlama ile model takibinde** kullanılan yöntemler: **TMC** [14], **ACT** [15], **LIO** [16], esnek ya da bükülebilir olmayan ve yüksek gözlem değişimi geçiren hedeflerin takibinde başarı sağlamaktadır. **Ayırddedici yöntem** grubunda bulunan ve ayırddedici sınıflandırma kullanılarak hedef takibi yapan **FBT** [22] yöntemi, hedef ve arkaplan ayırımında arkaplanın hedef modeline benzerlik gösterdiği durumlarda problem yaşamaktadır. **MIT** [23]'te ise Haar özniteliklerinin kullanımının ölçek değişimine ve dönmeye karşı bağımsızlık sağlarken örneklemin ilkel olarak yapılmasının dinamik harekete karşı zayıflık oluşturduğu belirtilmektedir. **KCF** [25], [26] literatürde çok yüksek işlem hızı, basit algoritması ve doğruluk oranı ile öne çıkmaktadır. Ancak yöntem herhangi bir hata tespit ya da hareket modeli bulma fonksiyonuna sahip olmamakta, afin dönüşüm parametresi (ölçek, dönme, yer değiştirme vb.) bulmaya yönelik hesaplama yapmamaktadır.

**Ayırddedici sınıflandırmayı destek vektör makineleri** kullanarak yapan yöntemlerden biri olan **STRUCK** [27], [28]'ta kaba piksel değerlerinin doğrusal çekirdek ile, Haar özniteliklerinin Gauss çekirdeği ile histogram özniteliklerinin ise kesişim çekirdeği ile kullanılması sonucunda en iyi takip başarı ve doğruluk değerlerinin elde edildiği anlaşılmaktadır. En iyi sonuçlar, Gauss çekirdeği ile Haar özniteliklerinin birlikte kullanılması ile bulunmaktadır. **THUNDERSTRUCK** yöntemi ise **STRUCK** denemelerine göre daha başarılı sonuç vermemesine rağmen imge işleme hızının yüksek olması ile dikkat çekmektedir. Örneklemin ilkel yapılması dinamik harekete karşı zafiyet yaratmaktadır. **DLSSVM** [29]'de oluşturulan öznitelik haritalarının, tek bileşenli sunum tekniği ile ifade edilmesi hedef takibini hem doğruluk hem de başarımlı açısından geliştirmektedir. **MEEM** [30] özellikle ciddi örtüşme ya da gözlem değişimi geçiren hedeflerin bulunduğu

videolarda daha başarılı olmaktadır. Bu durum hedef modelinin geriye doğru öğrenilmesinden kaynaklanmaktadır. Literatürde son yıllarda ilgi çekmekte olan diğer bir çalışma ise **derin öğrenme** yaklaşımını temel alan **HCFT** [31] yöntemidir. Bu yöntem geleneksel sinir ağları ile doğrusal ilinti süzgeçlerini birleştirerek hedef takibinde yüksek doğruluk ve başarıya imza atmıştır. Ancak hata oluşması durumunda gözlem modelinin yeniden düzeltilmesine olanak sağlayacak bir kontrol ya da yeniden tespit algoritmasına sahip olmaması zayıf yönü olarak ifade edilebilir. **DT** [32], modeli arkaplandan ayıran en iyi özniteliklerin öğrenilmesinde başarı sağlamaktadır. SGD'de kullanılan hata fonksiyonunun modifiye edilmesi ile yöntemin hızı arttırılmakta olup SGD ile Gauss dağılım örneklemesinin birleştirilmesi ile model değişimlerine ve etiketleme hatalarına karşı gürbüz sonuç elde edilmektedir.

Verilen tüm bilgiler ışığında incelenen yöntemlere ait özellikler ile avantajlı/dezavantajlı olduğu konular Tablo-2'te sunulmuştur.

## 6. Sonuç ve Gelecek Çalışmalar

Hedef takibi problemi, sabit ya da hareketli bir kameradan alınan video bilgisi üzerinde ilgilenilen nesnenin izlenmesi olarak tanımlanabilmektedir.

Gerçek zamanlı hedef takibinin doğru ve sürdürülebilir olarak gerçekleştirilebilmesi için takip yönteminin, ortamda meydana gelebilecek ışık değişimi, düzlem dışı dönüş, ölçek değişimi, örtüşme, bozulma, hareket bulanıklığı, hızlı dinamik hareket, düzlem içi dönüş, görüş açısının dışına çıkılması, arkaplan ile karışım ve düşük çözünürlük gibi olumsuzluklara karşı başarılı bir şekilde çalışması gerekmektedir. Bu makalede, yukarıda adı geçen problemlerin çözülmesi için geliştirilen **üretici yöntemler** ile **ayırddedici yöntemler** grubuna dahil 21 adet yöntem incelenmiştir. Üretici yöntemler takip süresince sadece hedefe önem verirken, ayırddedici yöntemler aynı anda hem hedefin hem de arkaplanın takip edilmesine olanak sağlamaktadır. Yapılan inceleme ve ortaya çıkan değerlendirme sonucunda gözlem süresince oluşan problemlerin tamamına karşı gürbüz çalışan bir yöntem henüz geliştirilememiş olup yöntemler önceden belirlenmiş problemlere yönelik olarak tasarlanmışlardır.

Görsel hedef takip çalışmaları tarihsel olarak incelendiğinde; basit hedef modeli ile arama yaklaşımıyla başlamış yıllar içinde çok farklı yöntemler önerilmiş ve son yıllarda hedef ve arkaplan sınıflandırmasına dayalı özellikle yapısal destek vektör makineleri ve derin öğrenme yöntemlerini kullanan algoritmalarla belirli bir noktaya ulaşılmıştır. Bu kapsamda gelecekte yapılacak araştırmaların, derin öğrenme veya diğer ayırddedici algoritmaların (marjinal) parçacık süzgeçleri ile desteklenerek esnek olmayan hedeflerin de takibine imkan sağlanması yönünde gelişeceği öngörülmektedir. Ayrıca birden fazla hedefin eş zamanlı olarak olasılık hipotez yoğunluk (Probability Hypothesis Density (PHD)) süzgeci ile takibi, takibin yapıldığı sahneye yeni giren ya da çıkan hedeflerin tespit ve takibi gibi problemlerin ise gelecek araştırmalara yön vereceği düşünülmektedir.

## 7. Kaynaklar

- [1] A.W. M. Smeulders, D. M. Chu, R. Cucchiara, S. Calderara, A. Dehghan, and M. Shah. "Visual Tracking: An Experimental Survey. PAMI, 36(7):1442–1468, 2014.
- [2] Y. Wu, J. Lim, and M.-H. Yang. "Online Object Tracking: A Benchmark. In CVPR, 2013.
- [3] K. Briechele and U. D. Hanebeck, "Template Matching Using Fast Normalized Cross Correlation," in Proc. SPIE, vol. 4387. 2001, pp. 95–102.
- [4] S. Baker and I. Matthews, "Lucas-Kanade 20 Years on: A Unifying Framework," IJCV, vol. 56, no. 3, pp. 221–255, 2004.
- [5] H. T. Nguyen and A. W. M. Smeulders, "Fast Occluded Object Tracking By A Robust Appearance Filter," IEEE Trans. Pattern Anal. Mach. Intell., vol. 26, no. 8, pp. 1099–1104, Aug. 2004.
- [6] A. Adam, E. Rivlin, and I. Shimshoni, "Robust Fragments-Based Tracking Using The Integral Histogram," in Proc. IEEE CVPR, Washington, DC, USA, 2006.
- [7] D. L. Shaul Oron, Aharon Bar-Hillel, and S. Avidan, "Locally Orderless Tracking," in Proc. IEEE CVPR, Providence, RI, USA, 2012.
- [8] D. Comaniciu, V. Ramesh, and P. Meer, "Real-time Tracking of Non-rigid Objects Using Mean Shift," in Proc. IEEE CVPR, Hilton Head Island, SC, USA, 2000. 53\_MST
- [9] Maraş, Bahri, Nafiz Arica, and Ayşın Baytan Ertüzün. "Object tracking by combining tracking-by-detection and marginal particle filter." Signal Processing and Communication Application Conference (SIU), 2016 24th. IEEE, 2016.
- [10] D. A. Ross, J. Lim, and R. S. Lin, "Incremental Learning For Robust Visual Tracking," IJCV, vol. 77, no. 1–3, pp. 125–141, 2008.
- [11] E. Maggio and A. Cavallaro, "Tracking By Sampling Trackers," in Proc. IEEE ICCV, Barcelona, Spain, 2011, pp. 1195–1202.
- [12] X. Jia, H. Lu, and M.-H. Yang, "Visual Tracking Via Adaptive Structural Local Sparse Appearance Model," in Proc. IEEE Conf. Comput.Vis. Pattern Recognit., 2012, pp. 1822–1829.
- [13] J. Kwon and F. C. Park, "Visual Tracking Via Geometric Particle Filtering on the Affine Group With Optimal Importance Functions," in Proc. IEEE CVPR, Miami, FL, USA, 2009. 56\_TAG
- [14] J. Kwon and K. M. Lee, "Tracking of a Non-Rigid Object Via Patch-based Dynamic Appearance Modeling
- [15] L. Cehovin, M. Kristan, and A. Leonardis, "An Adaptive Coupled-layer Visual Model For Robust Visual Tracking," in Proc. IEEE ICCV, Barcelona, Spain, 2011.
- [16] X. Mei and H. Ling, "Robust Visual Tracking Using L1 Minimization," in Proc. IEEE 12th ICCV, Kyoto, Japan, 2009.
- [17] F. Porikli. "Integral Histogram: A Fast Way To Extract Histograms In Cartesian Spaces." In Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2005.
- [18] Y. Rubner, C. Tomasi, and L. Guibas. "The Earth Mover's Distance As a Metric For Image Retrieval." Int. Journal of Computer Vision (IJCV), 40(2):91–121, 2000.
- [19] S. S. Boltz, F. Nielsen, "Earth Mover Distance On Superpixels," ICIP, 2010.
- [20] M. Isard and A. Blake, "A Mixed-State Condensation Tracker With automatic Model-Switching," in Proc. 6th ICCV, Bombay, India, 1998.
- [21] Schmidt, M. (2005). "Least Squares Optimization With L1-norm Regularization," Technical report, CS542B Project Report.
- [22] H. T. Nguyen and A. W. M. Smeulders, "Robust Track Using Foreground-background Texture Discrimination," IJCV, vol. 68, no. 3, pp. 277–294, 2006.
- [23] B. Babenko, M.-H. Yang, and S. Belongie, "Visual Tracking With Online Multiple Instance Learning," in Proc. IEEE CVPR, Miami, FL, USA, 2009.
- [24] Z. Kalal, J. Matas, and K. Mikolajczyk, "P-N Learning: Bootstrapping Binary Classifiers by Structural Constraints," in Proc. IEEE CVPR, San Francisco, CA, USA, 2010.
- [25] J. F. Henriques, R. Caseiro, P. Martins, and J. Batista. "Exploiting The Circulant Structure of Tracking-by-Detection With Kernels," In ECCV, 2012.
- [26] J. F. Henriques, R. Caseiro, P. Martins, and J. Batista. "Highspeed Tracking With Kernelized Correlation Filters," PAMI, 2014.
- [27] S. Hare, A. Saffari, and P. H. Torr. "Struck: Structured Output Tracking With Kernels," in ICCV, 2011.
- [28] S. Hare, S. Golodetz, A. Saffari, V. Vineet, M. M. Cheng, S. L. Hicks, P. H. S. Torr, "Struck: Structured Output Tracking with Kernels", IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015.
- [29] Jifeng Ning, Jimei Yang, Shaojie Jiang, Lei Zhang and Ming-Hsuan Yang. "Object Tracking Via Dual Linear



- Conference on Computer Vision and Pattern Recognition (CVPR), pp. 4266-4274, Las Vegas, USA, 2016.
- [30] J. Zhang, S. Ma, and S. Sclaroff. "MEEM: Robust Tracking Via Multiple Experts Using Entropy Minimization," in ECCV, 2014.
- [31] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks For Large-scale Image Recognition," ICLR, 2015.
- [32] H. Li, Y. Li, and F. Porikli, "Deeptrack: Learning Discriminative Feature Representations By Convolutional Neural Networks For Visual Tracking," in BMVC, 2014.
- [33] Welling M. "Fisher Linear Discriminant Analysis," notes for Linear Discriminant Analysis.
- [34] Grabner H., Grabner M., Bischof H. "Proceedings of the British Machine Vision Conference" (BMVC'06), Vol. 1 (2006), pp. 47-56.
- [35] Antoine Bordes, Leon Bottou, Patrick Gallinari, Jason Weston, "Solving Multiclass Support Vector Machines With LaRank," Proceedings of The 24 th International Conference on Machine Learning, p. 89-96, June 20-24, 2007, Corvallis, Oregon , USA.
- [36] J. C. Platt, "Fast Training of Support Vector Machines Using Sequential Minimal Optimization," MIT Press, 1999, pp. 185-208.
- [37] Zabih, R., Woodfill, J., "Non-parametric Local Transforms For Computing Visual Correspondence," In: Eklundh, J.-O. (ed.) ECCV 1994. LNCS, vol. 801, Springer, Heidelberg (1994)
- [38] Maji, S., Berg, A.C., "Max-margin Additive Classifiers For Detection," In: CVPR (2009)
- [39] D. Ramanan, "Dual Coordinate Solvers For Large-scale Structural SVMs," in <http://arxiv.org/abs/1312.1743>, 2014.
- [40] Grandvalet, Y., Bengio, Y., "Semi-supervised Learning By Entropy Minimization," in: NIPS (2005)
- [41] Alov300.org, 'Amsterdam Library of Ordinary Videos for Evaluating Visual Trackers Robustness'. [Online] . Available: <http://www.alov300.org/>.
- [42] Cvlab.hanyang.ac.kr, 'Visual Tracker Benchmark'. [Online]. Available: [http://cvlab.hanyang.ac.kr/tracker\\_benchmark/datasets.html](http://cvlab.hanyang.ac.kr/tracker_benchmark/datasets.html)
- [43] Ri.cmu.edu, 'Lucas-Kanade 20 Years On'. [Online]. Available: [http://www.ri.cmu.edu/research\\_project\\_detail.html?project\\_id=515&menu\\_id=261](http://www.ri.cmu.edu/research_project_detail.html?project_id=515&menu_id=261)
- [44] Cs.technion.ac.il, 'Fragtrack-Robust Fragments-based Tracking Using the Integral Histogram'. [Online]. Available: <http://www.cs.technion.ac.il/~amita/fragtrack/fragtrack.htm>
- [45] Eng.tau.ac.il, 'Locally Orderless Tracking'. [Online]. Available: <http://www.eng.tau.ac.il/~oron/LOT/LOT.html>
- [46] Cs.toronto.edu, 'Incremental Learning for Robust Visual Tracking'. [Online]. Available: <http://www.cs.toronto.edu/~dross/ivt>
- [47] Cv.snu.ac.kr, 'Tracking by Sampling Trackers'. [Online]. Available: <http://cv.snu.ac.kr/research/~vts/>
- [48] Faculty.ucmerced.edu, 'Visual Tracking via Adaptive Structural Local Sparse Appearance Model'. [Online]. Available: [http://faculty.ucmerced.edu/mhyang/project/cvpr12\\_jia\\_project.htm](http://faculty.ucmerced.edu/mhyang/project/cvpr12_jia_project.htm)
- [49] Cv.snu.ac.kr, 'Tracking of a Non-Rigid Object via Patch-based Dynamic Appearance Modeling and Adaptive Basin Hopping Monte Carlo Sampling'. [Online]. Available: <http://cv.snu.ac.kr/research/~bhmctracker/>
- [50] Vicos.si, 'Visual Tracking using Global and Local Visual Information'. [Online]. Available: <http://www.vicos.si/Research/LocalGlobalTracking>
- [51] Dabi.temple.edu, 'L1 Tracker' . [Online]. Available: [http://www.dabi.temple.edu/~hbling/code\\_data.htm#L1\\_Tracker](http://www.dabi.temple.edu/~hbling/code_data.htm#L1_Tracker)
- [52] Vision.ucsd.edu, 'Tracking with Online Multiple Instance Learning'. [Online]. Available: [http://vision.ucsd.edu/~bbabenko/project\\_miltrack.html](http://vision.ucsd.edu/~bbabenko/project_miltrack.html)
- [53] Github.com, 'Tracking, Learning and Detection'. [Online]. Available: <https://github.com/mrgloom/openTLD-1/find/master>
- [54] Robots.ox.ac.uk, 'Kernelized Correlation Filters'. [Online]. Available: <http://www.robots.ox.ac.uk/~joao/circulant/>
- [55] Samhare.net, 'Struck:Structured Output Tracking with Kernels'. [Online]. Available: <http://www.samhare.net/research/struck>
- [56] Comp.polyu.edu.hk, 'Object Tracking via Dual Linear Structured SVM and Explicit Feature Map'. [Online]. Available: <http://www4.comp.polyu.edu.hk/~cslzhang/DLSSVM/DLSSVM.htm>
- [57] Cs-people.bu.edu, 'MEEM: Robust Tracking via Multiple Experts using Entropy Minimization'. [Online]. Available: <http://cspeople.bu.edu/jmzhang/MEEM/MEEM.html>
- [58] Sites.google.com, 'Hierarchical Convolutional Features for Visual Tracking'. [Online]. Available: <https://sites.google.com/site/chaoma99/iccv15-tracking>

Tablo-1: Metriklerin Özellikleri

ni	Denklem	Tanımı	Metriğin Amacı	Parametreler
	$2 \times \frac{\text{Hassasiyet} \times \text{Anımsama}}{\text{Hassasiyet} + \text{Anımsama}}$	Hassasiyet ve Tanımlamanın Bir Arada Kullanıldığı Metrik.	Doğruluk	Hassasiyet Anımsama
	$\frac{1}{N_{frames}} \sum_i 2x \frac{p_i \times r_i}{p_i + r_i}$	Hedef Penceresi ile Kesin Referans Penceresinin Örtüşüm Ortalamasını Veren Metrik.	Doğruluk	$p_i = \frac{ H^i \cap KR^i }{ H^i }$ $r_i = \frac{ H^i \cap KR^i }{ KR^i }$
f Takip	$1 - \frac{\sum_i n_{yp}^i + n_{yn}^i}{\sum_i g^i}$	Hedef Pencere ile Kesin Referans Penceresinin Kaç Defa Örtüşüğünü Gösteren Metrik.	Doğruluk	$g^i = i$ 'nci imgede bulunan kesin referans penceresinin sayısı. 0 yada 1. $n_{yp}^i, n_{yn}^i$
f Takip	$\frac{1}{ M_s } \sum_{i \in M_s} \frac{ H^i \cap KR^i }{ H^i \cup KR^i }$	Hedef Pencere ile Kesin Referans Penceresinin Örtüşme Oranını Gösteren Metrik.	Doğruluk	$M_s$ = Kesin Referans Penceresi ile Hedef Penceresinin Örtüştüğü İmgelerin Toplam Sayısı. $H^i, KR^i$
Ortalama Değeri	$\frac{1}{N_{imge}} \sum_i \frac{ H^i \cap KR^i }{ H^i \cup KR^i }$	Hedef Pencere ile Kesin Referans Penceresinin Ortalama Örtüşme Oranını Gösteren Metrik.	Doğruluk	$N_{imge}, H^i, KR^i$
	$1 - \frac{\sum_{i \in M_s} d(H^i, KR^i)}{n}$	Hedef Pencere ile Kesin Referans Penceresinin	Konum	$M_s, H^i, KR^i$

Tablo-2: Takip yöntemlerinin özellikleri

Takip Yöntem Tipi	Yöntem Tip Sınıfları	Yöntemler	Gözlem Modeli (Öznetlik)	Gözlem Modeli Güncelleme	Hareket Modeli/Örnekleme	Üstünlükleri	Zayıflıkları	Kod/ Ref.	Referans
Özetici Yöntemler	TTM	NCC	Piksel	---	Çapraz İlini	Hızlı İşlem Zamanı.	Gözlem Modeli Güncellenmemektedir.	---	3
		KLT	Piksel	---	En Dik İnış Yöntemi	Affin transformasyon Başarı İle Takip Edilmektedir.	Gözlem Modeli Güncellenmemektedir.	Matlab/43	4
		KAT	Piksel	Kalman Süzgeci	Gradyan İnış Yöntemi	Affin Transformasyon Başarı İle Takip Edilmektedir.	---	---	5
		FRT	Histogram	---	Dairesel Alan İçinde	EMD İle Başarılı Karşılaştırma. Konum Doğruluğu.	Gözlem Modeli Güncellenmemektedir.	C++/44	6
		LOT	HSV (Hue Saturation Value) ile Süper Piksel	Parçacık Süzgeci	Parçacık Süzgeci	EMD İle Başarılı Karşılaştırma. Parçacık Süzgecinin Kullanım	Gri Formatlı İmgelerde Çalışmamaktadır.	Matlab-Mex/45	7
	TDMPF	Piksel	---	Marjinal Parçacık Süzgeci	Dinamik Hareketlere Karşı Gürbüz.	İşlem Süresi Yavaş.	Matlab	9	
	TTMEAM	IVT	Piksel	Kademeli Temel Bileşen Analizi (TBA)	Parçacık Süzgeci	Kademeli TBA ile Modelin Güncellenmesi. Parçacık Süzgecinin Kullanım Unutma Faktörü.	Hızlı Poz ve Işık Değişiminde Güncelleme.	Matlab/46	10
		TST	HSI Piksel	Seyrek Temel Bileşen Analizi	Metropolis Hastings	Birden Fazla Takip Edicinin Kullanılması.	---	Binary/47	11
		ASLA	Seyrek Sunum	Seyrek Temel Bileşen Analizi	Parçacık Süzgeci	Model Güncelleme. Parçacık Süzgeci.	---	Matlab/48	12
	TTMC	TMC	Renk Histogram	Yerel Modun Manzarası	Basın Hopping Monte Carlo	Esnek yada Bükülebilir Olmayan Hedeflerin Takibi.	---	Matlab/49	14
ACT		HSV Histogram	Bayeşçi Yaklaşım	Kalman Süzgeci	Esnek yada Bükülebilir Olmayan Hedeflerin Takibi.	---	Matlab-C/50	15	
LIT		Seyrek Sunum	L1 Azaltma Yöntemi	Parçacık Süzgeci	Ön Plan ve Arkaplanın Güncellemede Kullanılması.	---	Matlab/51	16	
Ayrıntılı Yöntemler	TDC	FBT	Piksel İle Gabor Süzgeçleme	Doğrusal Diskriminant Analizi	Üniform	Hedef İle Arkaplanın Modellemesi	Arkaplan İle Hedefin Benzerlik Göstermesi Durumunda Takip Problemi	---	22
		MIT	Haar	Online Adaboost	Dairesel Alan İçinde	Haar Öznetlikleri Ölçek ve Rotasyona Karşı Gürbüz.	Örnekleme Modelinin Dinamik Harekete Karşı Zayıflığı	C++/52	23
		TLD	LBP	P-N Öğrenme	Lucas Kanade	Hatalı Etiketlemelerin Düzeltilmesi	---	C++/53	24
		KCF, DCF	Piksel veya HOG	Sirt Regresyonu ile DFT	Dolanır Matris Kullanımı	İşlem Hızı Çok Yüksek	Affin Transformasyon Parametre Takibinin Olmaması.	Matlab/54	25, 26
	TDCC	STRUCK, THUNDERSTRUCK	Piksel, Haar ve HOG	Destek Vektör Makineleri İle SMO Opt.	Dairesel Alan İçinde	Hedef İle Arkaplan Model Öğrenme Doğruluğu	Örnekleme Modelinin Dinamik Harekete Karşı Zayıflığı	C++/55	27,28
		DLSSVM	Cie-Lab ve LRT ile tek bileşenli sunum	Destek Vektör Makineleri İle DCD Opt.	Dairesel Alan İçinde	Öznetlik Haritalarının Tek Bileşenli Sunumu	Değişken Ölçek Parametre Kullanımı İşlem Hızını Azaltmaktadır.	Matlab/56	29
		MEEM	Cie-Lab ve LRT ile tek bileşenli sunum	Destek Vektör Makineleri İle SMO Opt. ve PLL ile öğrenme	Dairesel Alan İçinde	Ciddi Örtme ve Model Farklılığına Karşı Gürbüz	Sadece İki Boyutlu Hareket Parametrelerinin Takibi	Matlab-Mex/57	30
	TDL	HCFT	CNN Öznetlikleri	İlinti Süzgeci Ağırlık Katsayısı	İlinti Süzgeci	Uzaysal ve Görsel Bilginin Takibi	Hedef Model Hatasının Kontrol Edilememesi	Matlab/58	31
		DT	CNN Öznetlikleri (piksel ve gradyan)	SGD	Gauss Dağılım	Hedefi Ayrıran En İyi Öznetliklerin Öğrenimi	---	---	32



**Ayşın ERTÜZÜN**

Dr. Ayşın Ertüzün, 1981 yılında Boğaziçi Üniversitesi Elektrik-Elektrik Mühendisliği Bölümü'nden BS derecesi (onur derecesi ile), 1984'de McMaster Üniversitesi Elektrik ve Bilgisayar Mühendisliği Bölümünden M. Eng. derecesi (yüksek onur derecesi ile) ve 1989 yılında Boğaziçi Üniversitesi Elektrik-Elektrik Mühendisliği Bölümü'nden doktora derecesi aldı. 1988 yılından bu yana Boğaziçi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nde öğretim üyesidir; halen profesör olarak görev yapmaktadır. Kasım 2016'dan beri araştırmasından sorumlu rektör yardımcılığı görevini yürütmektedir.

Dr. Ertüzün'ün araştırma faaliyetleri istatistiksel sinyal işleme üzerine yoğunlaşmıştır; özellikle kestirim, algılama ve nesne izleme problemleri üzerinde çalışmaktadır. Bayesçi sinyal işleme, kör sinyal işleme, uyarlanabilir sinyal işleme, doku analizi ve örüntü tanıma ilgi alanlarına girmektedir. Boğaziçi Üniversitesi Sinyal ve İmge Laboratuvarı (BUSIM) ve Akıllı Sistem Laboratuvarı (ISL) ile bağlantılıdır.

Parçacık filtreleri ve Bayesçi sinyal işleme, alfa kararlı dağılımlar, bağımsız bileşen analizi, doku hata algılama ve örüntü tanıma, istatistiksel yöntemlerin hata tespit problemlerine uygulanması, ters evrişim ve kaynak ayrıştırması, rüzgar hızı tahmini, görüntülerin gürültüden arınması, 2-boyutlu kafes süzgeçler, uyarlanabilir sinyal işleme, yüksek mertebeden istatistikler, dalgacıklar ve uygulamaları gibi konularda dergilerde ve konferans bildiri kitapçıklarında 80'den fazla bilimsel makalenin yazarlığını ve/veya ortak yazarlığını yapmıştır.

IEEE Sinyal İşleme ve İletişim Dernekleri, IAPR – International Association of Pattern Recognition (Uluslararası Örüntü Tanıma Derneği), IEICE – The Institute of Electronics, Information and Communication Engineers (Elektronik, Bilgi ve İletişim Mühendisleri Enstitüsü) ve TOTIAD – Türk Örüntü Tanıma ve İmge Analizi Derneği üyesidir. IAPR'de çeşitli komite ve kurullarda yer almıştır. Birçok ulusal ve uluslararası konferansın düzenleme ve/veya teknik komitelerinde görev yapmıştır. 2011 yılından beri "Elsevier Signal Processing" dergisinin editörler kurulunda; 2016 yılından beri EMO Bilimsel Derginin Danışma Kurulu'nda yer almaktadır.

**Bahri MARAŞ**

Bahri MARAŞ, 2005 yılında Deniz Harp Okulu'ndan BS derecesi almıştır. 2005-2010 yılları arasında Deniz Kuvvetleri Komutanlığı bağlı muhtelif firkateyn ve hücumbotta elektronik subayı ve silah subayı görevlerini yerine getirmiştir. 2010 yılında, Güney California Üniversitesi, Los Angeles, CA, Elektrik Mühendisliği Bölümünde yüksek lisans eğitimine başlamıştır. 2012 yılında M.Eng. derecesini aldıktan sonra Gölcük Tersanesi Komutanlığı, Kocaeli'de Silah Sistemleri Mühendisi olarak çalışmaya başlamıştır. Halihazırda Gölcük Tersanesi Komutanlığında Silah Sistemleri Fabrika Müdürlüğü görevinde bulunmakta olup görevi süresince güdümlü mermi atıcı sistemleri ile atış kontrol sistemlerinin Deniz Kuvvetleri Komutanlığına bağlı savaş gemilerinde entegrasyon ve bakım faaliyetlerinin planlanması ve yönetimini sağlamaktadır. Aynı zamanda 2013 yılından günümüze kadar geçen sürede ise Boğaziçi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümünde doktora eğitimine devam etmektedir. Motivasyonu sayısal sinyal işleme, imge işleme, bilgisayarla görme, örüntü tanıma, bayesçi sinyal işleme ve uyarlanabilir süzgeç teorisi hakkında olmakla birlikte mevcut araştırma alanı alçak irtifalarda uçan İHA (İnsansız Hava Aracı)'dan elde edilen videolarda hedef takibi konusu üzerinde yoğunlaşmıştır.

**Nafiz ARICA**

Nafiz Arıca, 1991 yılında Deniz Harp Okulu'ndan BS derecesi almıştır. Deniz Kuvvetleri Komutanlığında dört yıl süreyle muhabere ve hareket subaylığı görevlerini yerine getirmiştir. 1995 yılında, hem M.Eng. hem de doktora derecesini aldığı ODTÜ (Orta Doğu Teknik Üniversitesi) Bilgisayar Mühendisliği Bölümüne katılmıştır. 1998 yılında, hazırlamış olduğu tez ODTÜ'de yılın tezi olarak ödüllendirilmiştir. Doktora sonrası araştırma çalışmalarını, Illinois Üniversitesi Beckman Enstitüsü, Urbana-Champaign, IL ve Naval Postgraduate School, Monterey, CA Bilişim Bilimi Bölümünde gerçekleştirmiştir. 2004 ile 2013 yılları arasında Deniz Harp Okulu Bilgisayar Mühendisliği Bölümü, İstanbul'da öğretim üyesi olarak çalışmıştır. Halihazırda Bahçeşehir Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği bölümünde profesör olarak görev yapmakla birlikte ayrıca Fen Bilimleri Enstitüsü Müdürü görevini de yerine getirmektedir. Mevcut araştırma alanları cisim tespit, tanıma ve takip, İHA (İnsansız Hava Aracı)'lar için yol planlama ve yüz ifadesi analizi konularını içermektedir. IEEE üyesidir.