

**DÖNERKANAT TİPİNDE BİR İNSANSIZ HAVA ARACIYLA  
VİDEO TABANLI ÜST DÜZEY İŞLEVLERİN TASARLANMASI**

**NEVREZ İMAMOĞLU**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**HAZİRAN 2010**

**ANKARA**

Fen Bilimleri Enstitü onayı

---

Prof. Dr. Ünver KAYNAK  
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

---

Prof. Dr. Mehmet Önder EFE  
Anabilim Dalı Başkanı

Nevrez İMAMOĞLU tarafından hazırlanan DÖNERKANAT TİPİNDE BİR İNSANSIZ HAVA ARACIYLA VİDEO TABANLI ÜST DÜZEY İŞLEVLERİN TASARLANMASI adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

---

Prof. Dr. Mehmet Önder EFE  
Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Yrd. Doç. Dr. Tolga GİRİCİ

Üye : Prof. Dr. Mehmet Önder EFE

Üye : Yrd. Doç. Dr. Ahmet Murat ÖZBAYOĞLU

## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Nevrez İMAMOĞLU

**Üniversitesi** : TOBB Ekonomi ve Teknoloji Üniversitesi  
**Enstitüsü** : Fen Bilimleri Enstitüsü  
**Anabilim Dalı** : Elektrik ve Elektronik Mühendisliği  
**Tez Danışmanı** : Prof. Dr. Mehmet Önder EFE  
**Tez Türü ve Tarihi** : Yüksek Lisans – Haziran 2010

**Nevrez İMAMOĞLU**

**DÖNERKANAT TİPİNDE BİR İNSANSIZ HAVA ARACIYLA  
VIDEO TABANLI ÜST DÜZEY İŞLEVLERİN TASARLANMASI**

**ÖZET**

Video işleme çalışmaları arasında havadan gözetleme ile uygulama geliştirmek araştırmacılar için ilgi çekici bir problemdir. Gözetleme uygulamalarında önemli çalışmalardan biri görüntüdeki nesnenin ayrıştırılması ve tanınması diğeri ise görüntüdeki nesnenin takip edilmesidir. Her iki konuda da literatürde çeşitli çözümler önerilmiştir. Sağladığı yararlı bilgiler sebebiyle görüntü işleme çalışmalarında dalgacık dönüşümü yöntemine bu problemlerin çözümünde sıkça başvurulmaktadır. Bu çalışmada dalgacık dönüşümünden yararlanılarak birbirine ilişkilendirilebilir iki ayrı uygulama yapılmıştır. İki uygulamada da farklı ölçek ve oryantasyonlarda analiz imkânı sağlayan Gabor dalgacıklarına başvurulmuştur. İlk çalışmada görüntüdeki nesneyi arka plandan Gabor dalgacıkları ile ayırarak elde edilen örüntünün istenen nesne sınıfına ait olup olmadığı belirlenmiştir. En yakın komşu, en yakın  $k$ -komşu, Bayes ve yapay sinir ağı sınıflandırma yöntemleri kullanılarak örüntülerin istatistiksel özellikleri üzerinden başarımların analizi yapılmıştır. Bayes sınıflandırma yöntemi elde edilen özellik vektörlerine en iyi cevabı vermiştir. Yapay sinir ağı sınıflandırma yöntemi de kabul edilebilir bir başarıma sahiptir. Diğer çalışmada ise hareketli kamera ile havadan alınan görüntüdeki önceden belirlenmiş nesnenin takibi gerçekleştirilmiştir. Gradient tabanlı Gabor dalgacık gösterimine ait görüntü üzerinden ele alınan şablonlardan ikili pencere seçilerek bulunan değiştirilmiş-Zernike özellikleri yardımıyla şablon eşleme yöntemi gerçekleştirilmiştir. Ayrıca şablon eşleme aşamasında beklenen arama noktası çevresinde şablonlar arasında ağırlıklandırılmış uzaklık ölçütü kullanılarak başarımların daha yüksek bir yapıya oluşturulmaya çalışılmıştır. Geliştirilen algoritma gözlemci hareketi varken, nesne hareket halindeyken veya hareketsizken, gürültülü video görüntüsünde ve yüksek ışık değişimi mevcutken takip işlemini başarıyla gerçekleştirmiştir.

**Anahtar Kelimeler:** Dalgacık Dönüşümü, Özellik Çıkarma, Nesne Tanıma, Şablon Eşleme, Nesne Takibi

**University** : TOBB Economics and Technology University  
**Institute** : Institute of Natural and Applied Sciences  
**Science Programme** : Electrical and Electronics Engineering  
**Supervisor** : Prof. Dr. Mehmet Önder EFE  
**Degree Awarded and Date** : M.Sc. – June 2010

**Nevrez İMAMOĞLU**

**DESIGN OF VIDEO BASED HIGH LEVEL FUNCTIONS  
FOR A QUADROTOR TYPE UNMANNED AERIAL VEHICLE**

**ABSTRACT**

Among the video processing applications, aerial video surveillance is one of the interesting topics for researchers. Object segmentation and recognition system is one important topic for surveillance, and the other one is object tracking. There are various solutions developed with lots of researches to handle these problems. Wavelet transform analysis is one of the tools used to implement such applications because it yields useful information on image processing applications. In this work, two related application is implemented by taking advantage of wavelet transform. Gabor wavelets which provide analysis with different scales and orientations are utilized in both implementations. The aim of the first work is segmentation of the object from background image with the aid of Gabor wavelets, and classification of the pattern whether it belongs to the desired object or not. Nearest neighbor,  $k$ -nearest neighbor, Bayesian and artificial neural network classifiers are used to analyze the performance of the statistical features of the patterns. Bayesian classifier results in best accuracy. Artificial neural network also has a satisfactory performance to be used for classification. The other application is the tracking of an object on an aerial video taken from a moving observer. Tracking of the object is accomplished by using double window gradient based Gabor representation of a gray scale image and the extraction of pseudo-Zernike moment for feature selection to match best similar template around next expected pixel among consecutive frames. In addition, template matching process takes advantage of the weighted distance to find best matching template around an expected search point to obtain a better performance on tracking result. The algorithm to track the object on an aerial video satisfies the tracking task even under the circumstances where the observer is moving, the target object is moving or not moving, video record is low quality with noise, and there are high illumination changes.

**Keywords:** Wavelet Transform, Feature Extraction, Object Recognition, Template Matching, Object Tracking

## TEŐEKKÜR

Çalıőmalarım boyunca göstermiő olduđu güven, sunduđu çalıőma ortamı, deđerli yardım ve katkılarıyla beni yönlendiren danıőmanım Prof. Dr. Mehmet Önder EFE'ye yine kıymetli tecrübelerinden faydalandıđım TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü öğretim üyelerine,

İnsansız Hava Aracı Laboratuvarında birlikte çalıőtıđım her zorlukta önerilerini, yardımlarını ve arkadaşlıklarını esirgemeyen takım arkadaşlarım Aydın ERESEN, Mert ÖNKOL, Necdet Sinan ÖZBEK ve Yusuf BUĐDAY'a

Bu günlere gelmemde katkısı olan büyüklerime, arkadaşlarıma, özellikle desteklerini hiçbir zaman esirgemeyen AKIN ailesine ve herőeyden önemlisi her koşulda tereddütsüz beni destekleyen ve bana güvenen aileme teőekkürlerimi sunarım.

Bu tez TÜBİTAK tarafından 107E137 referans numaralı "Dönerkanat Tipinde Bir İnsansız Hava Aracıyla Otonom Yörünge Takibi ve Görüntüleme" başlıklı proje tarafından desteklenmiőtir. Eđitimim süresince projedeki desteklerinden dolayı TÜBİTAK'a teőekkürü borç bilirim.

## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ	xi
KISALTMALAR	xiii
1. GİRİŞ	1
1.1. İnsansız Hava Araçları	1
1.2. Ayırıştırma ile İlgili Çalışmalar	3
1.3. Özellik Çıkarma Yöntemleri	7
1.4. Sınıflandırma Çalışmaları	10
1.5. Gözetleme ve Takip Üzerine Yapılmış Çalışmalar	12
1.6. Tezin İçeriği	16
2. DALGACIK DÖNÜŞÜMÜ	18
2.1. Haar Dalgacık Dönüşümü	19
2.2. Daubechies Dalgacık Dönüşümü	23
2.3. Görüntü İşlemede Haar ve Daubechies Dalgacık Dönüşümü	24
2.4. Gabor Dalgacıkları	27
3. ARKA PLANDAN NESNENİN AYRIŞTIRILMASI	32
3.1. Bölge Büyütme	33
3.1.1. Çekirdekli Bölge Büyütme	34

3.1.2. Bulanık Bölge Büyütme	40
3.2. Gabor Dalgacıkları ile Ayırıştırma	42
4. ÖZELLİK ÇIKARMA	44
4.1. İstatistiksel Özellikler	44
4.2. Dalgacık Dönüşümü Tabanlı Özellik Çıkarma Yöntemi	46
4.3. Geometrik Momentler	47
4.4. Tchebichef Momentleri	48
4.5. Zernike Momentler	49
4.6. Değiştirilmiş-Zernike Momentleri	51
5. YAPAY ZEKÂ UYGULAMALARI	52
5.1. En Yakın Komşu	52
5.2. En Yakın $k$ Komşu	54
5.3. Bayes Sınıflandırıcı	55
5.3.1. Minimum Uzaklık Sınıflandırıcısı	57
5.4. Yapay Sinir Ağları	58
6. UYGULAMALAR VE DENEYSEL SONUÇLAR	64
6.1. Ayırıştırma - Sınıflandırma Uygulaması ve Sonuçları	64
6.2. Nesne Takibi Uygulaması ve Sonuçları	67
6.2.1. Görüntünün Gösterimi	68
6.2.2. Özellik Çıkarma	74
6.2.3. Şablon Eşleme ve Nesne Takibi	75
6.2.4 Nesne Takibi Uygulamasının Sonuçları	77
6.3. Sonuç	82



KAYNAKLAR

84

ÖZGEÇMİŞ

91

## ÇİZELGELERİN LİSTESİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 1.1. 2004 ve 2007 İHA programlarının sayısı	2
Çizelge 6.1. Sınıflandırma sonuçları	67
Çizelge 6.2. Yöntemlerin ortalama hata ve hata varyans değerleri	78

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Geliştirilen dönerkanat aracı	2
Şekil 2.1. Tek boyutlu sinyal için 3 seviyeli dalgacık dönüşümü	22
Şekil 2.2. İki boyutlu dalgacık dönüşümü	24
Şekil 2.3. Araba görüntüsü	25
Şekil 2.4. Araba görüntüsünün Haar dönüşümü	25
Şekil 2.5. Araba görüntüsünün Daub4 dönüşümü	26
Şekil 2.6. Araba görüntüsüne ait 3 seviye Haar dönüşümü	26
Şekil 2.7.. Araba görüntüsüne ait 3 seviye Daub4 dönüşümü	27
Şekil 2.8. Farklı ölçek ve oryantoslarda 64x64 Gabor dalgacıkları	29
Şekil 2.9. $v = 0$ ve $\mu = 0,1,\dots,8$ için 24x24 Gabor dalgacıkları yüzeyleri	30
Şekil 2.10. $v = 1$ ve $\mu = 0,1,\dots,8$ için 24x24 Gabor dalgacıkları yüzeyleri	30
Şekil 2.11. $v = 2$ ve $\mu = 0,1,\dots,8$ için 24x24 Gabor dalgacıkları yüzeyleri	31
Şekil 3.1. Orijinal görüntü	35
Şekil 3.2. ÇBB için eşik değeri 19	36
Şekil 3.3. ÇBB için eşik Değeri 25	36
Şekil 3.4. ÇBB için eşik Değeri 30	37
Şekil 3.5. ÇBB için eşik Değeri 35	37
Şekil 3.6. ÇBB için eşik Değeri 40	38
Şekil 3.7. ÇBB için eşik değeri 19 ile seçilmiş nokta 1	38
Şekil 3.8. ÇBB için eşik değeri 19 ile seçilmiş nokta 2	39
Şekil 3.9. ÇBB için eşik değeri 19 ile seçilmiş nokta 3	39
Şekil 3.10. BBB yöntemi sonucu nokta 1	41
Şekil 3.11. BBB yöntemi sonucu nokta 2	41
Şekil 3.12. Gabor ayrıştırma sonuçları	42
Şekil 4.1. Zernike moment için şablon yapısı	49
Şekil 5.1. İki özellikli uzayda iki nokta arasındaki Euclid mesafesi	53
Şekil 5.2. İki özellikli uzayda iki sınıf için en yakın komşu	53
Şekil 5.3. İki özellikli uzayda iki sınıf için en yakın $k$ komşu	54
Şekil 5.4. Nöron yapısı	58
Şekil 5.5. Çok girişli tek çıkışlı YSA	62
Şekil 5.6. Çok girişli çok çıkışlı YSA	63
Şekil 6.1. Sınıflandırmada kullanılan nesne resimleri	65
Şekil 6.2. Gabor ayrıştırma görüntüleri	65
Şekil 6.3. Ayrıştırılmış nesnelerin şablonları	66
Şekil 6.4. Gabor dalgacıklarının reel parçasının yüzey grafiği	69
Şekil 6.5. Gabor dalgacıklarının reel parçasının görüntüsü	69
Şekil 6.6. Gabor dalgacıklarının sanal parçasının yüzey grafiği	70
Şekil 6.7. Gabor dalgacıklarının sanal parçasının görüntüsü	70
Şekil 6.8. Videodan alınan görüntü	72
Şekil 6.9. Videodan alınan görüntünün yükselteli grafiği	72
Şekil 6.10. Görüntünün Gabor dalgacık gösteriminin yükselteli grafiği	73
Şekil 6.11. Görüntünün amaçlanan gösteriminin yükselteli grafiği	73
Şekil 6.12. Şablona ait iki pencere seçimi	74
Şekil 6.13. Ağırlıklandırma fonksiyonunun yüzey grafiği	77
Şekil 6.14. Geliştirilen yöntemin takip sonuçları	79
Şekil 6.15. NÇK şablon eşleme yönteminin takip sonuçları	80

Şekil 6.16. İDŞE yönteminin takip sonuçları  
Şekil 6.17. Yöntemlerin hata grafiği

81  
82

## KISALTMALAR

### Kısaltmalar Açıklama

<b>Ar-Ge</b>	Araştırma-Geliştirme
<b>BBB</b>	Bulanık Bökge Büyütme
<b>BCO</b>	Bulanık c-Ortalama
<b>ÇBB</b>	Çekirdekli Bölge Büyütme
<b>İDŞE</b>	İki Durumlu Şablon Eşleme
<b>İHA</b>	İnsansız Hava Aracı
<b>LM</b>	Levenberg-Marquardt
<b>NÇK</b>	Normalize Çapraz Korelasyon
<b>TDY</b>	Ton Doygunluk Yeğlilik
<b>YSA</b>	Yapay Sinir Ağları

## 1. GİRİŞ

Video ve görüntü işleme çalışmaları birçok alana yayılmış durumdadır. Görüntü ve video işleme teknikleri medikal, robotik ve hava araçları gibi birçok çalışma alanında kullanılmaktadır. Bu alanlardan birisi de İnsansız Hava Aracı (İHA) tabanlı uygulamalardır. İHA projelerinde video tabanlı işlevlerin gerçekleştirilmesi de araştırmacılar için sıkça ele alınan problemlerdir. Bu nedenle öncelikli olarak İHA ile ilgili bazı bilgiler verilecektir, ardından projenin hedefindeki İHA olarak ele alınan dönerkanata değinilecektir ve sonrasında tezin ana amacı olan video ve görüntü işleme ilgili yapılan çalışmalar ele alınacaktır.

### 1.1. İnsansız Hava Araçları

İlerleyen teknoloji ile İHA üzerine çalışmalar son yıllarda ivme kazanmıştır. İHA'nın farklı sektörlerde birçok alanda kullanılması üzerine çalışmalar mevcuttur ve bu çalışmalar üzerine Araştırma-Geliştirme (Ar-Ge) faaliyetleri hızla devam etmektedir. İHA projeleri üç ana sektörde yapılmaktadır; birincisi savunma sanayi, ikincisi sivil sektör, ve son olarak da eğitim sektörü olarak görülebilir.

İHA konusundaki en büyük yatırımlar hiç şüphesiz savunma sanayisi tarafından gerçekleştirilmektedir. Sarris [1] İHA üzerine yaptığı incelemesinde, 1997 yılı verilerine göre İHA pazarındaki 2.3 milyar dolar olan gelir miktarının 2.22 milyar dolarlık kısmının savunma sanayisine kalan kısmının ise özel sektöre ait olduğunu belirtmiştir. Sarris'in yazısındaki verilere göre özel sektördeki gelirin %60'lık kısmı Kuzey Amerika ve Avrupa'ya aittir ve günümüzde bu bütçe miktarlarının daha da fazla olduğu bir gerçektir [1]. Bu nedenle bu tür projelere ait Ar-Ge çalışmalarına aktarılan bütçe de artış göstermektedir. Everaerts'in çalışması [2] bu artışı gözler önüne sermektedir. Everaerts'in de belirttiği üzere Çizelge 1.1 2004 ve 2007 yıllarına ait sektörlerle ilgili UVS-International internet sitesinde kayıtlı İHA programlarının sayısını göstermektedir [2].


Yapılan çalışmalarda birçok türde İHA modeli kullanılmaktadır; uçak, helikopter, 3-motorlu dönerkanat ve 4-motorlu dönerkanatlar birer örnektir. İHA projelerinin değişik kullanım şekilleri mevcuttur, bunlardan en yaygını keşif ve gözetleme

işlevleridir. Puri [3] makalesinde İHA projeleri üzerine bir inceleme yapmıştır. Bu incelemede [3] belirtilen İHA kullanımlarına örnekler, İHA üzerine bilgiler ve çeşitli yerlerde yapılan İHA projelerinin içeriklerine ait bilgiler verilmiştir.

Çizelge 1.1. 2004 ve 2007 İHA programlarının sayısı

	2004	2007
<b>Savunma Sanayi</b>	392	491
<b>Özel Sektör</b>	33	61
<b>İki Amaçlı</b>	39	117
<b>Araştırma</b>	43	46

TOBB ETÜ İnsansız Hava Araçları Laboratuvarında İHA olarak dönerkanat tasarlanıp geliştirilmiştir. Geliştirilen dönerkanat tipindeki araca yönelik çalışılan konular ise otomatik kontrol ve gözetlemenin de dahil olduğu video tabanlı analiz işlevleridir. Şekil 1.1’de tasarlanan dönerkanat aracı görülmektedir.



Şekil 1.1. Geliştirilen dönerkanat aracı

Bu tezin amacı ise kontrol dışındaki görüntü tabanlı işlevlerin gerçekleştirilmesi üzerinedir. Görüntü tabanlı işlevler dönerkanat aracının dinamiklerinden ve aracın tipinden bağımsız olarak herhangi bir İHA üzerine monte edilmiş kameradan alınan görüntüler ile geliştirilebilir. Bu tez çalışmasında önemli olan kameranın bulunduğu aracın modelinden ziyade görüntü üzerinde amaçlanan işlevlerin gerçekleştirilmesidir. Bu sayede tezin amacına yönelik olarak ele alınacak görüntüler üzerinde geliştirilen algoritmalar iç veya dış ortam için dönerkanat gözetleme işlevini de gerçekleştirecektir. Bu bakımdan sonraki bölümlerde literatür taraması dönerkanat ve onun kontrolünden ziyade dönerkanat üzerinde uygulanabilecek görüntü ve video işleme çalışmaları üzerine yoğunlaşmaktadır.

## 1.2. Ayırıştırma ile İlgili Çalışmalar

Video tabanlı işlevlerde gözetleme, nesne takibi ve sınıflandırma gibi araştırma konularında kullanılan en yaygın çalışmalardan birisi de ayırıştırma<sup>1</sup> üzerinedir. Ayırıştırma işlevlerinin başarısı gözetleme, takip veya sınıflandırma ana hedeflerinin başarımında önemli yer tutmaktadır. Literatürde farklı yöntemler ile birçok çalışma bulunmaktadır [4-27]. Yapılan bu çalışmaları iki ana gruba ayırabiliriz; nesne veya desenlerin birbirinden ayrılması [1-13, 19-27], diğeri ise hareket bilgisine dayalı ayırıştırma [14-18, 26].

Ayırıştırma işlemleri için temel birçok teknik -kenarların çıkarılması, eşik değeri, bölge büyütme, su ayırım hattı<sup>2</sup> ve hareket bilgisi ile ayırıştırma vs.- Gonzalez ve Woods [4] tarafından belirtilmiştir. Bunlar arasında ilk olarak yaygın olarak kullanılan eşik değeri yöntemini ele alabiliriz [4]. Bu yöntem basit arka plan ve ışık değişimlerinin çok az olduğu durumlarda kullanılabilir. Eşik değeri yöntemi kullanılarak nesnenin arka plandan tam olarak ayrılabilmesi için hem nesnenin hem de arka planın olabildiğince düzgün renk dağılımına sahip olması gerekir. Ayrıca ayırıştırma için belirlenen eşik değerinin iyi seçilmesi gerekmektedir. Eşik değeri yönteminin eşik değeri seçmedeki eksikliğini gidermek adına global eşik değeri yöntemi sunulmuştur [4]. Global eşik değeri yönteminin de seçilen eşik değeri

---

<sup>1</sup> İng. *segmentation*

<sup>2</sup> İng. *watershed*



bakımından en iyi sonucu vereceği söylenemez. Bu nedenle, global eşik değeri için en iyi seviyeyi belirlemek adına Otsu yöntemi ele alınmıştır [4]. Bu yöntem ile klasik eşik değeri ve global eşik değeri yöntemlerinden daha iyi sonuç elde edilmiştir [4]. Ayrıca global eşik değerin daha düzgün seçilebilmesi için gürültü azaltma ve kenar bilgilerini kullanma yöntemleri de Gonzalez ve Woods tarafından ele alınmıştır [4]. Ayırıştırma işlemi yaparken tek bir eşik değeri kullanmak yerine birden fazla eşik değeri seçilmesi ile ayırıştırma işlemi geliştirilebilir, bu yapı çoklu eşik değeri yöntemi olarak sunulmuştur [4]. Son olarak eşik değeri yöntemleri arasında değişken eşik değeri yöntemi ele alınmıştır, bu yöntemle görüntü parçalara ayrılıp her bir parçada eşik değeri ayrı değerlendirilmiştir ve ek olarak değişken eşik değeri yöntemi ile geliştirilen yürüyen ortalama yöntemi de gösterilmiştir [4]. Yürüyen ortalama yönteminde görüntü üzerinde belirli bir alanda, alanın ortalama değerine göre eşik değeri yöntemi kullanılarak ayırıştırma yapılmaktadır. Bu iki yöntem yerel eşik değeri yöntemleri olarak belirtilmiştir [4]. Eşik değeri yöntemleri hızlı ve uygulaması kolay yöntemlerdir, fakat bu yöntemler arka planın karmaşık olduğu durumlarda işlevselliklerini yitirebilmektedirler. Bu nedenle ayırıştırma işlemleri için farklı yöntemler de geliştirilmiştir.

Gonzalez ve Woods'un da [4] ifade ettiği gibi farklı bir yöntem olarak bölge büyütme yöntemi seçilen birden fazla noktada bağlantılı bileşenleri bulup gruplamaya dayalı bir ayırıştırma algoritmasıdır. Literatürde bölge büyütme yöntemi kullanılarak birçok ayırıştırma yapısı geliştirilmiştir [4-13]. Atıfta bulunulan çalışmalara bakılırsa, bölge büyütmenin medikal görüntüleme çalışmalarında sıkça başvurulan bir ayırıştırma yöntemi olduğu görülmektedir. Adams ve Bischof bölge büyütme yöntemini kullanarak çeşitli görüntü örnekleri üzerinde – yapay üretilmiş resim, bir hücrenin mikro grafik resmi ve x-ray resimleri- ayırıştırma yapmayı başarmışlardır, ayrıca bu yöntem elle ve otomatik çekirdek seçimi şeklinde iki şekilde aktarılmıştır [5]. Hojjatoleslami ve Kitler bölge büyütme yöntemini iki farklı süreksizlik ölçüsü, ortalama kontrast ve çevresel kontrast, kullanarak ayırıştırılması istenen alanın sınırlarını elde edecek şekilde ele almışlardır [6]. Yaptıkları çalışmada Hojjatoleslami ve Kitler, kafa bölgesinden alınan MR görüntüsünde beyinde belirli bölgelerin ayırıştırılmasını sundukları yöntemle başarmışlardır [6]. Feng ve ekibi bölge büyütme yönteminde otomatik çekirdek seçimini ayrık kosinüs dönüşümünden elde edilen özellikleri yarışmalı öğrenme sinir ağı modeli yardımıyla yapmıştır [7].

Eđitilmiş sinir ađı modeli yardımıyla otomatik olarak elde edilen çekirdekler bölge büyütmede kullanılarak MPEG formatındaki video görüntüleri üzerinde ayrıştırma işlemi yapılmıştır [7]. Otomatik çekirdek seçimi için literatürde farklı yöntemler de ele alınmıştır [8-9]. Ek olarak bölge büyütme yönteminde çekirdek etrafında alanları belirlerken bulanık mantık yardımıyla da iyi sonuçlar elde edildiđi görülmüştür [10-13].

Görüntü üzerinde ayrıştırma yapılabileceđi gibi hareket bilgisi kullanılarak da ayrıştırma işlemleri yapılmaktadır [14-18]. En basit yaklaşım sabit bir gözlemcinin kaydettiđi video üzerinde hareket eden nesnenin ayrıştırılması üzerine gerçekleştirilen algoritmalarıdır. Hareketli bölgenin ayrıştırılması üzerine farklı birçok yöntem [14] kaynađında ele alınmıştır. Yapılan çalışmada arka plan farkı alma yöntemleri –basit fark alma, medyan filtreleme ile arka plan modelleme, ađırlıklı toplam ve çift arka plan yöntemleri- ve istatistiksel yöntemler –istatistiksel basit fark alma, benzerlik oranı, maksimum fark, ađırlık merkezi analizi ve Hough dönüşümü yöntemleri- incelenerek karşılaştırmaları yapılmıştır [14]. Horn ve Schunk farklı bir model olarak optik akış yönteminin görüntünün farklı nesnelere göre ayrıştırılmasında kullanılabileceđini belirtmişlerdir [15]. Optik akış yönteminin hesaplanması için bir yapı geliştirilip bu yapı ile görüntü üzerindeki optik akış deđerlerinin bulunması sağlanmışır [15]. Wedel ve ekibi ortaya attıkları geliştirilmiş TV- $L^1$  optik akış yöntemi ile dinamik bölgelerin ayrıştırılmasında başarı elde etmişlerdir [16]. Geliştirilen yöntem ile ışık deđerlerindeki deđişime daha gürbüz bir sistem oluşturulmuştur, ayrıca çalışma sonuçlarında ayrıştırma işlemlerinin başarımı da gösterilmiştir [16]. Hareket vektörü ve renk bilgisi eşleşmesinden elde edilen bilgilerle alan tabanlı parametrik hareket ayrıştırma yöntemi de farklı bir yaklaşım olarak öne sürülmüştür [17]. İki çerçeve arasındaki hareket bilgisini takiben renk deđerlerinin yardımıyla alan tabanlı ikinci bir ayrıştırma gerçekleştirerek iki basamaklı bir ayrıştırma algoritması oluşturulmuştur [17]. Schoenemann ve Cremers resmi birbirinden farklı iki tanımlayıcı bölgeye ayıracak bir ayrıştırma algoritması geliştirmişlerdir [18]. Sunulan yapı ile parametrik hareket modeli ve grafik kesim yöntemi sayesinde karmaşık görüntülerin de ayrıştırılması sağlanmışır [18].

Literatürde ek olarak öbikleme<sup>3</sup> yöntemleri de kullanılarak ayrıştırma işlevleri gerçekleştirilmektedir [19-22]. Chen ve ekibi *K*-Ortalama yöntemi kullanarak ayrıştırma işlemini başarmıştır [19]. Geliştirilen algoritmada geleneksel *K*-Ortalama yöntemine ek olarak Ton Doygunluk Yeşinlik (TDY<sup>4</sup>) renk uzayından elde edilen renkli ve gri ton sıklık grafiği<sup>5</sup> bilgileri ile kütle merkezinin ilk atanması ve öbek sayısı otonom olarak belirlenmektedir [19]. Kaynak [19]'da geliştirilen algoritmanın renkli görüntülerde ayrıştırma işlemine hızlı ve verimli bir yaklaşım getirdiği sonucuna varılmıştır. Chen ve ekibi üç boyutlu görüntü verileri üzerinde uyarlamalı *K*-Ortalama yöntemi ve bilgiye dayalı morfolojik işlemleri bir arada ele alan bir algoritma geliştirerek kalp kesityazarları<sup>6</sup> üzerinde ayrıştırma işlemi gerçekleştirmiştir [20]. Öbikleme yönteminde Gibbs rasgele alanlar yardımıyla alanlar modellenmeye çalışılmış ve ardından yapısı bilinen bölgenin bu bilgiye dayalı morfolojik işlemlerle istenen bölgelerin ayrıştırılması sağlanmıştır [20]. Li ve ekibi *K*-Ortalama yönteminin merkez iklendirme safhasındaki hassasiyetini daha gürbüz hale getirebilmek adına Uzaysal Çekirdek tabanlı *K*-Harmonik Ortalama algoritmasını geliştirmiştir [21]. Yapılan çalışmada farklı görüntülerin değişik ışık yoğunluğu ve gürültü altındaki sonuçları da ele alınarak sistemin başarımı incelenmiştir [21]. Chuang ve ekibi diğer bir öbikleme yöntemi olan Bulanık *c*-Ortalama (BCO) algoritmasını gürültüye daha dayanıklı hale getirecek bir yöntem sunmuştur [22]. Klasik BCO yönteminin aksine geliştirilen BCO yapısında çevre piksellerin üyelik değerleri yardımıyla, yani görüntüdeki uzamsal bilgiden faydalanarak, gürültüye karşı klasik öbikleme metotlarından daha iyi sonuç alınmıştır [22].

Filtreler ve dönüşümlerin kullanılması da ayrıştırma işlemlerinde ele alınabilecek yollardır. Bu işlemler ayrıştırma öncesi görüntünün iyileştirilmesi, farklı bir şekilde gösterilmesi veya sıkıştırılması şeklindeki ön işlemler olabileceği gibi ayrıştırma algoritmasının temel yapısı da olabilirler. Dalgacık dönüşümünün ayrıştırma algoritmalarında kullanılması da araştırmacılar için son zamanlarda sıkça ele alınan bir konudur. Literatürde dalgacık dönüşümünden faydalanılarak geliştirilen birçok ayrıştırma algoritması mevcuttur [23-27]. Liu ve ekibi piramit yapıdaki görüntü

---

<sup>3</sup> İng. *clustering*

<sup>4</sup> İng. *Hue Saturation Value (HSV)*

<sup>5</sup> İng. *histogram*

<sup>6</sup> İng. *tomography*

ayrıştırması ile hiyerarşik su ayırım hattı ayrıştırmasını birleştiren bir algoritma geliştirmiştir [23]. Bu algortmada Haar dalgacık dönüşümü ile çok seviyeli görüntü elde edilerek farklı çözünürlüklerde işlem yapılmasına olanak sağlanmıştır [23]. Sentetik apertür<sup>7</sup> radar görüntüleri üzerinde otonom ayrıştırma işlemi gerçekleştiren bir algoritma [24] ile sunulmuştur [24]. Li ve ekibi dalgacık paketleri sayesinde elde ettikleri örüntü özellik kümeleriyle öğreticisiz bir öbikleme yapısı oluşturarak ayrıştırma işlemini başarmıştır [24]. Dechénes ve Guise durağan dalgacık dönüşümü yardımı ile elde ettikleri kenar bilgilerinin sınıflandırılmasını sağlayarak ilgili bölgelerin ayrıştırılmasını sağlamışlardır [25]. Kullanılan durağan dalgacık dönüşümünün davranışı Gauss fonksiyonun birinci dereceden türevine benzemektedir ve kenar çıkarma uygulamalarına uygundur [25]. Wiskott Gabor ve Mallat dalgacık dönüşümlerini bir arada kullanarak elde ettiği bilgilerle görüntüdeki farklı bölgelerin ayrıştırılmasını sağlamıştır [26]. Gabor dalgacık dönüşümü akış bilgilerinin elde edilmesine yardım etmiştir ve Mallat dalgacık dönüşümünün sağladığı kenar bilgilerine ulaşılmıştır, iki farklı gösterimin verdiği bilgiler ile görüntüdeki hareketler incelenerek bölgeler birbirinden ayrılmıştır [26]. Wei ve Bartels çalışmalarında Gabor dalgacık dönüşümü sayesinde gösterimini yaptıkları görüntünün istatistiksel bir ölçüt ile öğreticisiz şekilde ayrıştırma işlemi gerçekleştirmişlerdir [27].

### 1.3. Özellik Çıkarma Yöntemleri

Görüntülerden özellik çıkarma işlemi örüntü ve nesne sınıflandırma veya görüntü geri erişimi<sup>8</sup> çalışmalarında çok önemli bir yer tutmaktadır. Bölüm 1.2'de de tartışıldığı üzere ayrıştırma işlemlerinde de görüntüden çıkarılacak özelliklerin kullanıldığı çalışmalar mevcuttur. Özellik çıkarma yöntemleri daha büyük boyuttaki görüntünün incelenmesi yerine görüntüyü daha az sayıdaki veri ile tanımlayabilen algoritmalarıdır.

Görüntünün betimlenmesini sağlayan özellik çıkarma yöntemlerini iki ana gruba ayırabiliriz; sınır betimlemeleri ve alan betimlemeleri [4, 28]. Sınır uzunluğu, zincir kodu, Fourier betimleyicileri ve istatistiksel momentler sınır betimlemelerine

---

<sup>7</sup> İng. *aperture*

<sup>8</sup> İng. *retrieval*

verilebilecek örneklerdir [4, 28]. Sınır özelliklerini kullanabilmek için özellikleri çıkarılmak istenen görüntünün iyi bir şekilde ayrıştırılmış ve sınırlarının belirlenmiş olması gerekir. Böylelikle çıkarılan özellikler nesneyi en iyi şekilde tasvir edebilecektir. Görüntü kalitesinin düşüklüğü, gürültü ve ışık değişimi gibi etkenler yüzünden ayrıştırma işleminde oluşacak hatalar nesnenin sınırlarıyla tanımlanmasını güçleştirebilir. Sınır özelliklerini belirlemek yerine bölgeyi tanımlayıcı özellikler kullanmak sınır özelliklerine göre daha tanımlayıcı ve gürbüz olabilir.

Bölge özellikleri literatürde örüntünün<sup>9</sup> betimlenmesinde sıkça kullanılan yöntemlerdir ve birçok bölge betimleme yöntemi bulunmaktadır [4, 28]. Bölgenin özellikleri ikili görüntü haline dönüştürülmüş görüntüden elde edilebileceği gibi bölgenin gri tonlamadaki örüntüsünden de elde edilebilir. Nesneyi betimlemek adına alanı, yapısının sıklığı<sup>10</sup>, saçılması veya dağılması gibi özellikler ikili görüntü üzerinde uygulanabilir [4, 28]. Moment değerlerinin hesaplanması gri tondaki örüntü özellikleri için de kullanılabilir.

Video işlevlerinin en iyi şekilde yapılabilmesi için örüntüden çıkarılan özelliklerin örüntüdeki nesnenin boyutundan, dönmesinden ve ışık değişimlerinden bağımsız olması sağlanmalıdır. Ayrıca belirtilen bağımsız olma koşullarına ek olarak gürültüye karşı gürbüzlüğü ve işlem karmaşıklığının az olması sistemin başarımını etkilemektedir. Kullanılan özellik çıkarma yöntemlerinin başarımlarının hem işlem karmaşıklığı hem de belirleyici olma özelliği göz önünde bulundurularak ele alınması gerekir. Bu nedenle daha güvenilir bir betimleme isteniyor ise örüntüler daha fazla ve ayrıntılı bilgi ile tanımlanmalıdır. Güvenilir bir sistem için örtünün özelliklerinin örüntüyü en iyi şekilde tanımlaması sağlanmalıdır. Gri tondaki ya da renkli tondaki örüntülerin özelliklerinin çıkarılması istatistiksel yöntemlerle, moment bilgileriyle ve dalgacık dönüşümü yardımıyla elde edilebilir [4, 28-46].

Örüntüye ait istatistiksel bilgiler ile örüntünün betimlenmesi en temel örüntüden özellik çıkarma yöntemlerindedir [29-32]. Kumar ve Ramaswamy örüntüye ait birinci derece ve ikinci derece istatistiksel bilgilerinden faydalanarak boru hattındaki akışı algılamaya çalışmışlardır [29]. Borchani ve Stamon yine istatistiksel

---

<sup>9</sup> İng. *pattern*

<sup>10</sup> İng. *compactness*

özellikler yardımıyla örüntüleri sınıflandırarak benzer örüntülere geri erişim sağlayacak bir çalışma yapmışlardır [30]. İstatistiksel bilgilerin örüntülerin özelliklerinin çıkarılmasında faydalı bilgiler sağladığı kaynak [29] ve [30]'da görülmektedir.

İstatistiksel bilgilerden farklı olarak literatürde momentlerin hesaplanmasına dayalı yöntemler de kullanılmaktadır [33-42]. Hu çalışmasında geometrik moment özellikleri oluşturarak geometrik örüntülerin ve alfabetik karakterlerin tanınması konusunu ele almıştır [33]. Yapılan çalışmada geometrik momentlerin dönme, ölçekleme ve yer değiştirmeden değişimsiz bir tanımlama sağladığı belirtilmiştir [33]. Yang ve Albregtsen değişimsiz geometrik momentlerin hesaplanmasında hızlı bir yöntem önererek ikili görüntüde geliştirdikleri hesaplama yönteminin doğru sonuçlar verdiğini göstermişlerdir [34]. Khotanzad ve Hong dönme, ölçekleme ve yer değiştirmeden değişimsiz Zernike momentlerinin hesaplanmasını sunmuşlardır, ayrıca yaptıkları çalışmada alfabetik karakterler üzerinde Zernike momentlerin değişimsizlik özelliklerini ikili örüntüler üzerinde test etmişlerdir [35]. Zernike momentlerin işlem yükünün yüksek olmasından dolayı hızlı bir şekilde Zernike moment hesaplanmasını sağlayan bir yaklaşım Mukundan ve Ramakrishnan tarafından geliştirilmiştir [36]. Gu ve ekibi [37] de Mukundan ve ekibi gibi Zernike momentlerin hesaplanmasında geliştirdikleri yöntemi sunup daha önce geliştirilmiş iki farklı Zernike moment hesaplama yöntemi [36,38] ile hesap yüklerinin karşılaştırmasını yapmıştır. Mukundan ve ekibi ayrık Tchebichef polinomlarını temel olarak dik moment fonksiyonlarını [39] kaynağında vermektedir. Bu çalışmada Tchebichef momentlerin analitik özelliklerin korunmasında geleneksel Legendre momentler ile Zernike momentlerinden daha iyi olduğu vurgulanmıştır [39]. Chong ve ekibi yaptıkları çalışmada değiştirilmiş-Zernike<sup>11</sup> momentlerin Legendre ve Zernike momentlere göre hesap yükünün fazlalığına ve karmaşıklığına değinerek geliştirdikleri algoritma ile işlemsel açıdan daha verimli şekilde değiştirilmiş-Zernike momentlerin hesaplanmasını göstermiştir [40]. Geliştirilen yöntem ikili ve gri tondaki iki farklı görüntü üzerinde denenerek farklı derecelerdeki hesaplama zamanı farklı yöntemlerin hesaplama zamanlarıyla karşılaştırılıp yöntemin hızına vurgu yapılmıştır [40]. Prokorp ve Reeves değişimsiz momentler, dönele momentler, dik

---

<sup>11</sup> İng. *pseudo-Zernike*

momentler, kompleks momentler ve standart momentleri incelemişlerdir [41]. Yapılan çalışmada hangi tür momentin üstün olduğu söylenememektedir, fakat yüksek dereceli momentlerin gürültüye daha hassas olduğu belirtilmiştir [41]. Teh ve Chin de geometrik, Legendre, Zernike, değiştirilmiş-Zernike, dönele ve kompleks momentleri inceleyen bir çalışma yapmışlardır [42]. Genel olarak Zernike ve değiştirilmiş-Zernike momentlerinin diğerlerine üstünlük sağladığı belirtilmiş, ayrıca değiştirilmiş-Zernike momentlerinin de Zernike momentlere göre gürültüye daha az duyarlı olduğu yapılan çalışmada vurgulanmıştır [42].

Literatürde burada anılan yöntemlerin dışında da yöntemler bulunabilir; örneğin dalgacık dönüşümü de özellik çıkarmada sıkça kullanılan bir yaklaşımdır [43-46]. Sarlashkar ve ekibi dalgacık dönüşümü sonucu oluşan ortalama görüntüyü vektör haline getirerek basit bir özellik çıkarma yöntemi öne sürmüştür [43]. Bahsedilen yöntemde resmin boyutunun değişmesi dalgacık dönüşümü ile oluşturulan özellik sinyalinin şeklini değiştirmemiştir böylece boyuttan bağımsız bir özellik yapısı elde edilebilmiştir [43]. Zhang ve ekibi yaptıkları sınıflandırma çalışması için dalgacık dönüşümü sonucu oluşan alt görüntülerin enerjilerini hesaplayarak özellik çıkarma işlemini yapmıştır ve bu özellikleri kullanarak sınıflandırma işlemini gerçekleştirmiştir [44]. Bhagavathy ve Chabra dalgacık dönüşümü sonucu oluşan detay görüntülerden her basamakta standart sapma değerlerini hesaplamışlardır ve en son ortalama görüntünün standart sapma ve ortalama değerini bularak görüntü geri erişim sistemi için özellik vektörü oluşturmuşlardır [45]. Liang ve Kuo dalgacık dönüşümü kullanılarak görüntü gösterim ve betimleme sistemi oluşturmuşlardır [46]. Dalga kılavuzu adı verilen sistem dalgacık dönüşümü ile sıkıştırılıp şifreleme aşamasında dalgacık uzayında renk, örüntü ve nesne şekil betimleyicileri ile indekslenmiştir [46].

#### **1.4. Sınıflandırma Çalışmaları**

Sınıflandırma algoritmaları görüntü geri erişimi ve örüntü-nesne tanıma çalışmalarının son basamağıdır. Seçilecek yöntemler sistemin başarımını önemli ölçüde etkileyebilmektedir. Önemli olan eldeki özellik veri kümesi ile beraber kullanılacak sınıflandırma yöntemiyle sınıflandırmanın başarımında en yüksek doğruluğa ulaşabilmektir. Farklı yapıları ile birçok sınıflandırma algoritması

mevcuttur [47-60]. Sınıflandırmadaki başarı kadar işlem karmaşıklığı ve işlem yükü de seçim yaparken bir ölçüt olabilir. Literatür taramasının bu bölümünde tez kapsamında da ele alınan en yakın komşu, Bayes ve yapay sinir ağları sınıflandırıcıları üzerine durulacaktır

Sınıflandırmada kullanılacak en temel yöntem en yakın komşu yöntemidir [47, 48]. Kaynak [49] ile en yakın komşu kuralının örüntü sınıflandırma yöntemi olarak analizi yapılmıştır, ayrıca  $k$ -en yakın komşu ve Bayes gibi yöntemler de bu çalışmada incelenmiştir [49]. Yeterli sayıda ve düzgün dağılmış verilerle en yakın komşu kuralı sınıflandırma çalışmalarında kabul edilebilir bir yöntemdir [47]. Tsymbal ve ekibi farklı özellik çıkarma yöntemlerini en yakın komşu yöntemi ile beraber kullanarak sınıflandırma çalışması yapmış, özelliklerin en yakın komşu kuralına göre başarımlarını incelemiştir [50]. Mahar ve ekibi ise  $k$ -en yakın komşu yöntemini kullanarak imza doğrulama işlevini farklı özellik çıkarma yöntemleri –ızgara özellikleri, global özellikler ve örüntü özellikleri- ile deneyerek yöntemlerin başarımlarını karşılaştırmıştır [51].

Sınıflandırma çalışmalarında uzaklık bilgisi dışında istatistiksel ve olasılık bilgilerinin yardımıyla da sınıflandırma gerçekleştirilebilmektedir [47, 48]. Ses tanıma alanında gürültü sinyali üzerinde varsayım yapmadan sinyalin kendisinden, olduğu haliyle, çıkartılan özellikler yardımıyla sınıflandırma işlemi [52] kaynağında gerçekleştirilmiştir [52]. Yapılan çalışmada Bayes sınıflandırıcı kullanan yeni bir spektrografik maske kestirim yöntemi sunulmuştur ve gürültü kestirimi yapılmadan sinyalin kendisiyle yapılan çalışmada gözle görülür bir başarı sağlanmıştır [52]. Partridge ve Jabri çalıştıkları yüz tanıma sisteminde buldukları gürbüz Mahalanobis uzaklık ölçütünü yine geliştirdikleri hiyerarşik özellik çıkarma yöntemiyle beraber kullanarak tanıma işlevini başarmışlardır [53]. Geliştirilen algoritma farklı veri kümeleri üzerinde birçok sınıflandırma yöntemi ile başarımlar ve hesap süresi bazında karşılaştırılmıştır [53]. Masip ve ekibi gerçek zamanlı yüz algılama ve sınıflama yaptıkları çalışmada yüz algılama için ek özellikler ile geliştirilmiş Bayes sınıflandırıcıdan ve yüz sınıflandırmak için de en yakın komşu yönteminden faydalanıp, geliştirdikleri yüz algılama ve tanıma sistemiyle kullandıkları veri tabanında yaptıkları testlerde yüksek başarımlar elde etmiştir [54]. Yüz tanıma çalışmaları haricinde el yazısı ile karakter tanıma üzerine sınıflandırma işlemini iki



aşamalı şekilde yapacak yöntemin geliştirilmesi [55] kaynağında ele alınmıştır. Önerilen iki aşamalı yöntemde ilk sınıflandırma olarak sapmalı şehir bloğu uzaklığı ve ince sınıflandırma için de asimetrik Mahalanobis uzaklığı yardımıyla test verileri üzerinde çok yüksek bir başarımla elde edilebilmiştir [55].

Sınıflandırma çalışmalarında araştırmacıların en çok üzerinde durduğu konulardan birisi de sinir ağları yapısı ile sınıflandırma, nesne veya örüntü algılama ve tanıma yapılmasıdır [56-60]. Zhang yaptığı çalışmada sınıflandırma üzerine sinir ağlarının gelişimini aktarmıştır [56]. Sinir ağları ve geleneksel sınıflandırma yöntemleri arasında bağlantıları, sınıflandırmada öğrenme ve genellemelerdeki ödünleşmeleri, özellik seçimi gibi konulara da yapılan tarama çalışmasında değinilerek sinir ağlarının sınıflandırma açısından kullanılabilirliği ele alınmıştır [56]. Sonuç olarak sinir ağları birçok sınıflandırma çalışması için geleneksel sınıflandırma yöntemlerine ek olarak tercih edilebilecek bir yöntem olarak sunulmuştur [56]. Rowley ve ekibi yaptıkları çalışmada sinir ağları yardımıyla yüz algılama işlemini gerçekleştirmiştir [57]. Görüntülerdeki yüz olan ve olmayan alt görüntüler kullanılarak eğitilen sinir ağları buluşsal yöntemsiz tek ağ, buluşsal yöntemli tek ağ, iki ağı karar mekanizması ve üç ağı karar mekanizması gibi farklı yapılar ile denenerek başarımları farklı veri tabanlarında incelenmiştir [57]. Sonuç olarak [57] kaynağında sinir ağları kullanarak geliştirilen yüz algılama sisteminin yüksek başarımla sergilediği gözlemlenmiştir. Correia ve ekibi yaptıkları çalışmada örüntü üzerinde uyguladıkları dalgacık dönüşümü yardımıyla elde ettikleri özelliklerle çok katmanlı sinir ağlarını eğiterek farklı yapıda oluşturdukları eğitim modellerinin karşılaştırmasını yapmıştır [58]. Gonzalez ve ekibi geliştirdikleri görüntü geri erişim sisteminde dairesel şablonların histogramlarından buldukları dalgacık dönüşümü katsayılarını çok katmanlı sinir ağı modeli üzerinde kullanarak benzer uçak sınıflarına veri tabanından ulaşılmasını sağlamıştır [59]. Sahoolizadeh ve ekibi Gabor dalgacıkları yardımıyla gösterimini yaptıkları görüntülerde çok katmanlı sinir ağları yardımıyla yüz algılaması işlevini gerçekleştirmiştir [60].

## **1.5. Gözetleme ve Takip Üzerine Yapılmış Çalışmalar**

Gözetleme işlevleri üzerine literatürde birçok çalışma vardır. Trafik kontrolü, yangın kontrolü, güvenlik, belirli bir hedefin takip edilmesi bu örneklerden bazılarıdır.

Bütün bu çalışmalarda amaç en gürbüz ve doğruluğu en yüksek sonuçlara ulaşabilmektir.

Hu ve ekibi [61] gözetleme konusundaki incelemelerini, nesne hareketlerinin algılanması, nesnenin sınıflandırılması ve nesne takibi başlıkları altında yapmıştır. Kaynak [61]'de belirtilen incelemelerde hareket algılama çalışmaları üç madde ile ele alınmıştır; arka plan çıkartma, zamana ait fark alma ve optik akış yöntemleridir [61]. Şekil tabanlı ve hareket tabanlı nesne sınıflandırması Hu ve ekibi tarafından çalışmalarında belirtilmiştir [61]. Nesne takibi konusunda ise Hu ve ekibi dört method incelemiştir; bölge tabanlı takip, aktif sınır tabanlı takip, özellik tabanlı takip ve model tabanlı takip [61].

Kontitsis ve ekibi [62] İHA ile gözetleme çalışmasında yangın tespiti üzerine çalışmıştır. Kontitsis ve ekibi çekirdekli bölge büyütme yöntemini kullanarak ayrıştırma işlemi yapmıştır ve bulanık sınıflandırıcı ile bölgelerin yangın tehdidi olup olmadığına karar vermiştir [62]. Ayrıca, yapılan çalışmada kullanılan özelliklerde parametre seçimi yapılırken genetik algoritmaya başvurulmuştur [62].

Kumar ve ekibi [63] havadan video gözetlemesi ve kullanımı üzerine bir incelemede bulunmuştur. İncelemede görüntüyü ana bileşenlerine ayırmak üzerine durulmuştur [63]. Yapılan bu çalışmada görüntü üzerindeki ana bileşenler olarak zemin geometrisi, hareketli nesnelere, görüntüye ait statik ve dinamik bileşenler ele alınmıştır [63]. Geliştirilen yöntemlerle birbirinden bağımsız nesnelere takip edilebilmesi üzerine bir inceleme yapılmıştır [63].

Cohen ve Meidoni gözetleme çalışmalarında hareketli nesnenin bulunması ve bu nesnenin hareket yolunun tespit edilmesi üzerine durmuşlardır [64]. Hareketin algılanmasında optik akış yönteminden faydalanılmıştır [64]. Hareketli bölgelerin birbiriyle bağlantısını kurmak için bölgelerin grafiksel betimlemesi ele alınmıştır [64]. Bu betimlemeleri diğer görüntüler üzerinde eşleyerek hedef nesnenin ilişkilendirilmesi sağlanmıştır [64]. Ayrıca bu ilişkilendirme sırasında hareketli nesnenin sonraki görüntülerde izleyeceği optimal yolun belirlenmesi sağlanmıştır [64].

Kang ve ekibi yüksek paralaks<sup>12</sup> içeren video görüntüleri üzerinde hareketin tespit edilmesini sağlayacak bir algoritma sunmuştur [65]. Yaptıkları çalışma sapma, eğilme, yaklaşma uzaklaşma gibi yani kameranın üç boyutlu ekseninde yapacağı hareketlerde bile hareketli nesnelerin tespitini hedeflemektedir [65]. Bunu başarmak için optik akış tabanlı hareketin filtrelenmesini sağlayan bir algoritma geliştirilmiştir [65]. Bu algoritma kameranın üç boyutta yaptığı hareketlerin iki boyutlu görüntüde oluşturacağı kısıtlamalara rağmen başarılı sonuçlar vermiştir [65].

Değişen video görüntüsü üzerinde dinamik katman gösterimine dayalı hareket algılama ve hareketin takibi Tao ve ekibi tarafından gerçekleştirilmiştir [66]. Yapılan çalışmada dinamik katman gösterimine ait üç ana unsurun - hareket, üyelik ve görünüş - her bir görüntü penceresinde tahmin edilmesine dair bir algoritma kullanılmıştır [66]. Bu ana unsurlar kullanılarak hedef hareketlerinin yeri görüntüde tespit edilerek takip işlemi yapılmıştır ve bu algoritma havadan gözetleme için kullanılabilir bir algoritma olarak sunulmuştur [66].

Görüldüğü üzere gözetleme işlevleri arasında takip işlevi çok önemli bir yer tutmaktadır ve yeni yöntemlerin geliştirilmesi açısından insan veya araç takibi araştırmacılar tarafından sıkça ele alınmaktadır. Takip sistemleri nesnenin bir sonraki pozisyonunun videodan gelecek görüntüdeki bir sonraki çerçeve için tahmin edilmesi ya da nesnenin görüntüdeki pozisyonunun videodan gelen her çerçevede o an tespit edilmesi şeklinde olabilir [67-70]. Takip işlemlerindeki amaç ardışık görüntü çerçevelerinde takip edilmesi istenen nesnenin takip işlevini en doğru ve hesap yükü açısından da en az olacak şekilde tasarlanmasıdır. Genellikle hesap karmaşıklığı yüksek olan algoritmaların hesap yükü düşük olan algoritmalara göre takip işlevlerinde başarımları açısından daha iyi sonuçlar vermesi beklenir. Gerçek zamanlı tanıma ve takip uygulamalarının doğruluk ve işlem yükü gibi ölçütleri ele alırken sistemin olabildiğince yüksek hızda çalışması sağlanmalıdır. Yılmaz ve ekibi değişik algoritmalarla gerçekleştirilmiş takip çalışmalarının incelendiği bir literatür taraması yapmıştır [71].

---

<sup>12</sup> Açıklama: gözlemci pozisyonunun değişmesi ile nesnenin görünümünün ve pozisyonunun değişmesi

Daha önce anılan kaynaklardan da gözlemlenebileceği gibi gözetleme çalışmalarını gözlemcinin sabit olduğu gözetleme sistemleri ve gözlemcinin hareketli olduğu gözetleme sistemleri şeklinde iki ana gruba ayırabiliriz. Sabit kamera ile hareketli nesnenin takibinde genellikle hareketli bölgenin bulunmasından faydalanan yöntemler kullanılmaktadır [72-74]. Arka plan ve optik akış bilgilerinin kullanılması hareketli nesnelerin algılanmasında geçmişte yapılan çalışmalarda sıkça karşılaşılan yöntemlerdir [67, 68, 72-77]. Elgammal ve ekibi geliştirdikleri yöntemde arka plan ve ön plan sahnelerinin istatistiksel gösterimi ile parametrik olmayan çekirdek yoğunluk kestirimini kullanarak arka plan ve ön plan modellemesi gerçekleştirmiştir [68]. Lu ve ekibi yaptıkları çalışmada sabit kamerada hareket tespitinde başarıyı arttırabilmek için geliştirdikleri algoritmada zamansal fark alma, optik akış ve çift arka plan fark alma yöntemlerini birleştirip hızlı ve yüksek doğruluk oranına sahip bir sistem oluşturmuştur [75].

Sabit gözlemcilerden farklı olarak gözlemcinin de hareket ettiği durumlarda ardışık video görüntülerinde nesnenin hareketinin algılanması daha zordur, çünkü kamera hareketi nedeni ile nesnenin hareketi dışında bir de arka plan hareketi bulunmaktadır. Bu nedenle sabit gözlemci sistemlerinde kullanılan algoritmaların birçoğu hareketli gözlemci sistemlerinde çalışmayabilir. Kaâniche ve ekibi havadan alınan video görüntülerinde kenar-köşe bilgileri yardımıyla grafik gösterimi yöntemini kullanarak hareketli nesnenin hareketli bir gözlemciden takip edilmesi işlevini gerçekleştirmiştir [76]. Yapılan çalışmada ilk aşamada kenar bilgilerinden oluşan iki alt kümenin oluşturulması vardır; arka plana ait bilgiler ve hareketli nesne veya nesnelere ait bilgiler ve ikinci aşamada iki altküme ayrıştırma işleminin doğrulanması ile sonuca gidilmiştir [76]. Kaynak [77]'de sunulan üç aşamalı yapı ile hareketli bir gözlemciden –havadan alınmış video görüntüler- hareketli nesnenin algılanması ve takip edilmesi sağlanmıştır [77]. Geliştirilen yöntemde ilk olarak gözlemcinin hareketinin üstesinden gelmek adına görüntünün kararlılaştırılması üzerine çalışılmıştır, ikinci basamakta normal akış ve iki boyutlu çoklu-çerçeve hareket analizi ile hareketin bulunduğu bölgelerin tespit edilmesi gerçekleştirilmiştir ve son olarak da grafik boğum gösterim yardımıyla optimal yolun belirlenmesi ile takip işlemi başarılmıştır [77].

Hareketin algılanmasına dayalı takip çalışmaları takip edilmek istenen nesnenin hareketi yok ise başarısızlıkla sonuçlanabilir, çünkü takip edilmek istenen nesne ile arka plana ait hareket bilgileri benzer olacaktır. Bu eksikliğin üstesinden gelebilmek adına hareket bilgisine ihtiyaç duymayan ve başarılı takip işlevlerinin gerçekleşmesini sağlayan şablon eşleme yöntemi ele alınmıştır. Şablon eşleme yöntemi takip edilmesi istenen nesnenin hareketi olmasa bile nesneyi bulup takip etme konusunda güvenilir bir yöntemdir. Literatürde birçok şablon eşleme yöntemi ele alınmıştır [78-82]. Şablon eşleme yönteminin en basit ve hızlı kullanımı farkların kareleri toplamı ve normalize çapraz korelasyon değerlerinin eşleme yapılması istenen şablonlar için hesaplanması şeklindedir [78]. Bu yöntemler video görüntüleri üzerinde uygulanabilirlik açısından kolay ve çalışma hızı yüksek algoritmalar, fakat nesnenin dönüşüne ve boyutuna göre değişimsiz olmadığı gibi ek özelliklerle desteklenmedikçe görüntü üzerindeki gürültüye de gürbüz değillerdir. Bu nedenle Chen ve ekibi gürbüz bir hata ölçütü oluşturmak için farkların kareleri toplamı ve mutlak farklar toplamı yerine  $m$ -kestirici kullanarak gürbüz farkların toplamı metodunu geliştirmiştir [79]. Tang ve Tao ise şablon eşleme yöntemini şablonun kendisi yerine şablonun Haar'a benzer ikili özellikler<sup>13</sup> ile gösterimini kullanarak gerçekleştirmişlerdir [80]. Kaynak [82] ile belirtilen istatistiksel şablon eşleme yönteminde şablona ait ortalama, sapma ve standart sapma gibi istatistiksel özellikler hesaplanarak şablonların birbirine benzerliği belirlenmiştir [82]. Referanslardan da anlaşılacağı [80-82] gibi histogram, istatistiksel özellikler, dönüşümler ve olası birçok gösterim yöntemi şablon eşleme için kullanıldığında iyi sonuçlar elde edilebilmektedir.

## 1.6. Tezin İçeriği

Dönerkanat gibi İHA projeleri temelde iki çalışmayı kapsamaktadır. Birincisi otomatik ve uzaktan kontrol, ikincisi ise gözetlemedir. Gözetleme işlevlerinin en belirgin konusu ise video görüntüleri üzerinde yapılan çalışmalar olduğu görülmektedir. Bu işlemlere örnekler, hareketin algılanması, nesnenin görüntüden ayrıştırılması, nesnenin tespit edilmesi, nesnenin takip edilmesi, nesnenin

---

<sup>13</sup> İng. *Haar-like binary features*

özelliklerinin çıkarılması ve nesnenin sınıflandırılması çalışmalarıdır. Tezin içeriği de üst düzey görüntü işleme işlevlerinin video görüntüleri üzerinde gerçekleşmesidir.

Literatür taramasında anılan kaynaklarda görüldüğü üzere hareket algılama, nesne tespiti ve hareketli nesne takibi çalışmalarına gözetleme ile ilgili daha önceki çalışmalar referans oluşturmaktadır. Projenin yapısı bakımından iç ortam denemeleri düşünüldüğünden ilk olarak iç ortam yapısına uygun olarak çalışmalar yapılmıştır. Bu tez çalışması da dönerkanat projesine yönelik olarak uygulanabilecek iki ana çalışma üzerine yoğunlaşmıştır. Birincisi, iç ortamdaki havadan yeri gözetleyen kamera ile alınan görüntüdeki bir nesnenin ayrıştırılması ve araç olup olmadığının tespit edilmesidir. İkincisi ise, bir İHA üzerine yerleştirilmiş kamera ile havadan alınan görüntüde önceden belirlenmiş bir aracın takip edilmesi üzerine çalışılmıştır. İki çalışma da yapısı gereği İHA ile ilgili çalışmalardır ve bu nedenle dönerkanat tipindeki bir aracın gözetleme işlevlerine yöneliktir.

Bölüm 2’de dalgacık dönüşümü anlatılmıştır. Bölüm 3 ayrıştırma işlevlerinde kullanılabilecek bazı yöntemleri açıklamaktadır. Bölüm 4’te görüntüden özellik çıkarma yöntemleri üzerine durulmuştur. Bölüm 5’te kullanılan sınıflandırma teknikleri hakkında bilgiler verilmiştir. Bölüm 6’da tez kapsamında uygulanan iki farklı çalışma ele alınmıştır; birincisi ayrıştırma ve sınıflandırma ve diğeri ise nesne takibi çalışmasıdır.

## 2. DALGACIK DÖNÜŞÜMÜ

Dalgacık dönüşümü sinyallerin özellikleri tanımlanırken ve sinyaller analiz edilirken kullanılacak yöntemlerden biridir [23-27, 43-46, 57-60, 83-86]. Gürültü azaltma, görüntüyü sıkıştırma, kenar çıkarma, özellik çıkarma gibi birçok konuda da dalgacık dönüşümü kullanılmaktadır. Dalgacık dönüşümü verinin farklı yelpaze ve frekanslarda analizine olanak sağladığı için kullanışlı bir araçtır [83, 84]. Bu özelliğiyle dalgacık dönüşümü zamanda ve frekansta verinin incelenmesine imkân sağlar [83, 84]. Ayrıca dalgacık dönüşümünün önemli iki özelliği bulunur ve bunlar enerjinin korunumu ve enerjinin sıkıştırılması özellikleridir [83, 84].

Dalgacık dönüşümü sinyali iki alt sinyale ayırır [83, 84]. Alt sinyallerden biri sinyalin çözünürlüğü yarıya indirilmiş yaklaşık değeridir diğeri ise yine çözünürlüğü yarıya indirgenen detayları içeren alt sinyaldir [83, 84]. Bu ayrıştırma işlemi, sinyali alçak geçiren ve yüksek geçiren süzgeçlerden geçirdikten sonra elde edilen sinyallere alt örnekleme uygulanması sonucu oluşacak alt sinyalleri veren yapıya eş değerdir [83-85]. Bu ayrışım sinyalin farklı frekans gruplarında ve farklı çözünürlüklerde incelenmesine olanak sağlar [83-85]. Bir seviyeli ayrıştırma işlemi sonucunda sinyalin çözünürlüğü yarıya iner, fakat frekans analizi açısından bakıldığında frekans çözünürlüğü arttırılmış olunur [83-85]. Bu işlemin diğeri bir faydası da sinyali çözünürlük anlamında iki farklı yarıya indirgenmiş alt sinyale ayırarak bu alt sinyallerdeki frekans çözünürlüğünü arttırmış olmasıdır [83, 84].

Dalgacık analizinde birçok fonksiyon yapısı bulunmaktadır, fakat oluşturulan fonksiyonlar her zaman genişletilmiş ya da sıkıştırılmış temel fonksiyonu içerir [83-86]. Dalgacık fonksiyonu birçok şekilde seçilebilir; katsayıların seçimine göre frekans ve zaman çözünürlükleri ayarlanabilir [83-86]. Analiz yaparken unutmamak gerekir ki zaman ve frekans çözünürlükleri ters orantılıdır [83-86].

Dalgacık dönüşümü daha önce de belirtildiği gibi birçok alanda kullanılmaktadır. Görüntü işlemede dalgacık dönüşümü yaparken ayrık dalgacık dönüşümü ele alınmaktadır. Bu tezde dalgacık dönüşümü kullanılırken ayrık dalgacık dönüşümü incelenecektir. Öncelikli olarak tek boyutlu ayrık sinyaller üzerinde dönüşüm ele alınacaktır. Tek boyutlu dönüşüm görüntü işlemedeki iki boyutlu dalgacık

dönüşümünün temelini oluşturmaktadır. Tezin bu kısmında çalışmalarımızda da yapısal olarak deneyerek kullandığımız en basit iki dalgacık dönüşümü olan Haar dalgacıkları ve Daubechies dalgacıklarından Daub4 dalgacıkları açıklanacaktır.

## 2.1. Haar Dalgacık Dönüşümü

Haar dalgacıkları en basit yapıdaki dalgacık dönüşümü araçlarıdır ve bu dalgacıklar Haar dönüşümü olarak da adlandırılabilir [83]. Bütün dalgacık dönüşümlerinde olduğu gibi Haar dönüşümü de sinyali boyutları sinyalin yarısı olan iki alt sinyale ayırır [83]. Alt sinyallerden biri ortalama veya yaklaşık değer, diğeri ise fark veya detay bilgisini içerir [83, 85]. Haar dönüşümü ve oluşturduğu sinyaller Walker'ın da gösterdiği gibi ele alınacak olursa [83], elimizde  $N$  elemanlı tek boyutlu bir  $s$  sinyali için ortalama alt sinyali (2.1)'deki gibi hesaplanır [83].

$$\mathbf{a}_m = \frac{s_{2m-1} + s_{2m}}{\sqrt{2}} \quad m = 1, 2, \dots, \frac{N}{2} \quad (2.1)$$

burada  $\mathbf{a}_m$ ,  $s$  sinyalinden elde edilmiş ortalama alt sinyalidir. Aynı  $s$  sinyali için oluşturulacak detay sinyali ise (2.2) gibi hesaplanır [83].

$$\mathbf{d}_m = \frac{s_{2m-1} - s_{2m}}{\sqrt{2}} \quad m = 1, 2, \dots, \frac{N}{2} \quad (2.2)$$

burada  $\mathbf{d}_m$ ,  $s$  sinyalinden elde edilmiş detay alt sinyalidir.

Denklemler (2.1) ve (2.2)'deki gibi ortalama ve detay olarak iki alt sinyalin oluşturulması bir basamaklı bir Haar dönüşümüdür. Bir basamaklı Haar dönüşümü Walker'ın [83] da belirttiği şekilde (2.3)'deki gibi gösterilebilir.

$$\mathbf{s} \xrightarrow{\mathbf{H}_1} (\mathbf{a}^1 | \mathbf{d}^1) \quad (2.3)$$

burada  $\mathbf{H}_1$  birinci basamak dalgacık dönüşümü,  $\mathbf{a}^1$  birinci basamak ortalama alt sinyali  $\mathbf{d}^1$  birinci basamak detay alt sinyalidir. Görüldüğü üzere  $s$  sinyali aslında iki alt sinyal ile tamamen kayıpsız olarak (2.4) şeklinde tekrar oluşturulabilir [83].



$$\mathbf{s} = \left( \frac{\mathbf{a}_1 + \mathbf{d}_1}{\sqrt{2}}, \frac{\mathbf{a}_1 - \mathbf{d}_1}{\sqrt{2}}, \dots, \frac{\mathbf{a}_{N/2} + \mathbf{d}_{N/2}}{\sqrt{2}}, \frac{\mathbf{a}_{N/2} - \mathbf{d}_{N/2}}{\sqrt{2}} \right) \quad (2.4)$$

Dalgacık dönüşümünün önemli iki özelliği enerjinin korunumu ve enerjinin sıkıştırılmasıdır [83]. Enerjinin korunumu  $\mathbf{a}$  ve  $\mathbf{d}$  sinyallerinin enerjileri toplamının gerçek sinyalin enerjisine eşit olduğu anlamına gelir. Enerjinin sıkıştırılması ise  $\mathbf{a}$  sinyalinin enerjinin büyük bir kısmını içerdiğini ifade eder, yani bu sinyal gerçek sinyalin yaklaşığıdır [83].  $\mathbf{s}$  sinyali, onun yaklaşık ve detay alt sinyallerini (2.5)'deki gibi verilirse:

$$\mathbf{s} = (12, 4, 17, 11)$$

$$\mathbf{a} = \left( \frac{12+4}{\sqrt{2}}, \frac{17+11}{\sqrt{2}} \right) = (8\sqrt{2}, 14\sqrt{2}) \quad (2.5)$$

$$\mathbf{d} = \left( \frac{12-4}{\sqrt{2}}, \frac{17-11}{\sqrt{2}} \right) = (4\sqrt{2}, 3\sqrt{2})$$

$\mathbf{s}$  sinyalinin enerjisi (2.6)'daki gibi hesaplanır [83].

$$\xi_{\mathbf{s}} = (12^2 + 4^2 + 11^2 + 17^2) = 570 \quad (2.6)$$

$\xi_{\mathbf{s}}$ ,  $\mathbf{s}$  sinyalinin toplam enerjisi olarak hesaplanırsa,  $\mathbf{a}$  ve  $\mathbf{d}$  alt sinyallerinin enerjileri de denklem (2.7)'deki gibi hesaplanır [83].

$$\xi_{\mathbf{a}} = \left( (8\sqrt{2})^2 + (14\sqrt{2})^2 \right) = 520 \quad (2.7)$$

$$\xi_{\mathbf{d}} = \left( (4\sqrt{2})^2 + (3\sqrt{2})^2 \right) = 50$$

Denklemler (2.6) ve (2.7)'den da görüleceği gibi  $\mathbf{s}$  sinyalinin enerjisi  $\mathbf{a}$  ve  $\mathbf{d}$  alt sinyallerinin enerjilerinin toplamına eşittir (2.8) [83]. Bu da enerjinin korunduğuna dair bir örnektir.

$$\xi_s = \xi_a + \xi_d \quad (2.8)$$

Sinyallerin enerjilerine bakıldığı zaman **a** alt sinyali **s** sinyalinin enerjisinin yaklaşık %91.23'ünü kapsamaktadır, yani yaklaşık olarak **s** sinyalinin temsil edebilmektedir [83]. **a** alt sinyali oluşurken enerjinin sıkıştırıldığı görülmektedir. Kalan kayıp enerji de **d** alt sinyalinde saklanmaktadır, böylelikle ayrışım yapılırken enerjinin büyük kısmı **a** sinyalinde, kalan küçük kısmı da **d** sinyalinde kapsanarak enerjiye dayalı bir sıkıştırma yapılmış olmaktadır [83]. Denklem (2.1)-(2.4) ile belirtilen Haar dalgacık dönüşümününü gerçekleştiren birinci basamak Haar dalgacıkları Walter'ın [83] gösterdiği şekliyle (2.9)'da verilmektedir.

$$\begin{aligned} \psi_1^1 &= \left( \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}}, 0, 0, \dots, 0, 0 \right) \\ \psi_2^1 &= \left( 0, 0, \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}}, \dots, 0, 0 \right) \\ &\vdots \\ \psi_{N/2}^1 &= \left( 0, 0, 0, 0, \dots, \frac{1}{\sqrt{2}}, \frac{-1}{\sqrt{2}} \right) \end{aligned} \quad (2.9)$$

Denklem (2.2)'yi (2.9)'daki Haar dalgacıkları ile kullanarak gösterirsek birinci basamak Haar dönüşümü sonucu oluşan detay alt sinyalleri (2.10) denklemindeki gibi gösterilir [83].

$$\mathbf{d}_m = \mathbf{s} \cdot \psi_m^1, \quad m = 1, 2, \dots, N/2 \quad (2.10)$$

burada **d** detay alt sinyali, *m* alt sinyale ait elemanın indeksi, *N/2* alt sinyalin içerdiği eleman sayısı, **s** dalgacık dönüşümü uygulanacak sinyaldir ve denklem (2.10)'da gösterilen “.” işlemi skaler çarpımdır.

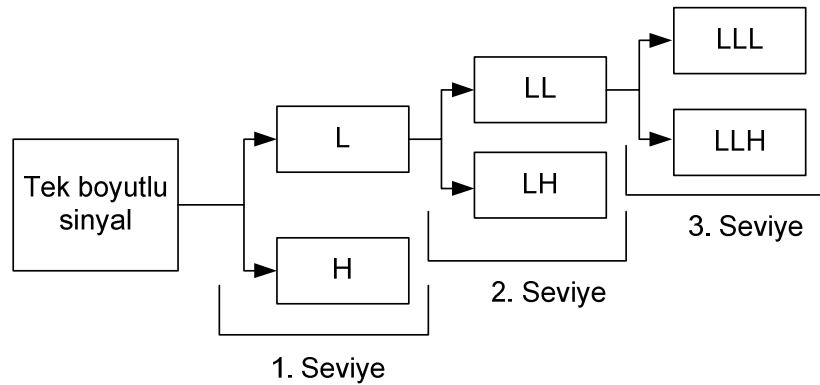
Detay alt sinyallerinin Haar dalgacıkları ile hesaplanması gibi birinci basamak sonucu elde edilen yaklaşık alt sinyalleri de (2.11)'de gösterilen birinci basamak ölçekleme sinyalleri ile bulunabilir [83].

Denklem (2.1)'i (2.11)'deki Haar dalgacıkları ile kullanarak gösterirsek birinci basamak Haar dönüşümü sonucu oluşan yaklaşık alt sinyalleri (2.12) denklemindeki gibi gösterilir [83].

$$\begin{aligned}
 v_1^1 &= \left( \frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}, 0, 0, \dots, 0, 0 \right) \\
 v_2^1 &= \left( 0, 0, \frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}, \dots, 0, 0 \right) \\
 &\vdots \\
 &\vdots \\
 v_{N/2}^1 &= \left( 0, 0, 0, 0, \dots, \frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)
 \end{aligned} \tag{2.11}$$

$$\mathbf{a}_m = \mathbf{s} \cdot v_m^1 \tag{2.12}$$

Daha üst seviyelerde Haar dalgacık dönüşümü yapabilmek için Haar dalgacık sinyallerini ve ölçekleme sinyallerini yapılarını koruyup boyutları yarıya indirecek şekilde bir önceki Haar dönüşümün oluşturduğu alt sinyale uygulamak yeterlidir. Birinci seviye Haar dalgacık dönüşümünden elde edilen yaklaşık alt sinyali kullanılarak ikinci seviye yaklaşık alt sinyali ve ikinci seviye detay alt sinyali elde edilebilir. Şekil 2.6 tek boyutlu bir sinyal için her seviyede yapının nasıl işlediği üzerine bir örnek teşkil etmektedir [83-86].



Şekil 2.1. Tek boyutlu sinyal için 3 seviyeli dalgacık dönüşümü

## 2.2. Daubechies Dalgacık Dönüşümü

Daubechies dalgacıkları da Haar dalgacıkları gibi tanımlanır, fakat Haar dalgacıklarından farklı olarak içeriği ile sinyalden daha fazla eleman kullanarak işlem yapılmasını sağlar [83]. Daubechies dalgacıklarının birçok çeşidi bulunmaktadır. Haar Dönüşüm ile Daubechies dönüşüm arasındaki fark ölçekleme sinyalleri ve dalgacıkların tanımlanmasıdır [83]. Tezin bu bölümünde Daub4 hakkında bilgi verilecektir Daub4 dalgacıkları ve Daub4 için kullanılan ölçekleme sinyalleri sırasıyla (2.13) ve (2.14)'de Walter'ın da belirttiği şekliyle verilmiştir [83].

$$\begin{aligned}
 \psi_1^1 &= \left( \frac{1-\sqrt{3}}{4\sqrt{2}}, \frac{\sqrt{3}-3}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{-1-\sqrt{3}}{4\sqrt{2}}, 0, 0, 0, 0, \dots, 0, 0, 0, 0 \right) \\
 \psi_2^1 &= \left( 0, 0, 0, 0, \frac{1-\sqrt{3}}{4\sqrt{2}}, \frac{\sqrt{3}-3}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{-1-\sqrt{3}}{4\sqrt{2}}, \dots, 0, 0, 0, 0 \right) \\
 &\vdots \\
 &\vdots \\
 \psi_{N/2}^1 &= \left( 0, 0, 0, 0, 0, 0, 0, 0, \dots, \frac{1-\sqrt{3}}{4\sqrt{2}}, \frac{\sqrt{3}-3}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{-1-\sqrt{3}}{4\sqrt{2}} \right)
 \end{aligned} \tag{2.13}$$


$$\begin{aligned}
 \nu_1^1 &= \left( \frac{1+\sqrt{3}}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{3-\sqrt{3}}{4\sqrt{2}}, \frac{1-\sqrt{3}}{4\sqrt{2}}, 0, 0, 0, 0, \dots, 0, 0, 0, 0 \right) \\
 \nu_2^1 &= \left( 0, 0, 0, 0, \frac{1+\sqrt{3}}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{3-\sqrt{3}}{4\sqrt{2}}, \frac{1-\sqrt{3}}{4\sqrt{2}}, \dots, 0, 0, 0, 0 \right) \\
 &\vdots \\
 &\vdots \\
 \nu_{N/2}^1 &= \left( 0, 0, 0, 0, 0, 0, 0, 0, \dots, \frac{1+\sqrt{3}}{4\sqrt{2}}, \frac{3+\sqrt{3}}{4\sqrt{2}}, \frac{3-\sqrt{3}}{4\sqrt{2}}, \frac{1-\sqrt{3}}{4\sqrt{2}} \right)
 \end{aligned} \tag{2.14}$$

Denklem (2.13) (2.10)'da ve (2.14) denklemi de (2.12)'de kullanılırsa Daub4 ile sırasıyla birinci basamak yaklaşık alt sinyali ve detay alt sinyali oluşturulur. Haar dalgacıklarının sahip olduğu enerjinin korunması ve enerjinin sıkıştırılması gibi özelliklere sahiptirler [83]. Ayrıca, enerjinin sıkıştırılması sırasında Haar dalgacıklarından farklı olarak ikiden çok sinyal eleman bilgisini kullanarak uygulanır. Böylece, oluşan alt sinyaller daha fazla bilgi içererek oluşturulur.

### 2.3. Görüntü İşlemede Haar ve Daubechies Dalgacık Dönüşümü

Dalgacık dönüşümü daha önce de belirtildiği gibi birçok alanda kullanılmaktadır. Bölüm 2.1 ve 2.2’de dalgacık dönüşümü tek boyutlu sinyaller için ele alınmıştır. Görüntü işlemede dalgacık dönüşümü yaparken yine tek boyuta indirgeyip dönüşüm alınabilir. Tek boyutlu dönüşüm için öncelikle görüntünün iki boyuttan tek boyuta indirgenmesi gerekmektedir. Bunun için çeşitli yöntemler bulunmaktadır. Görüntüdeki şekillerin özelliklerini çıkarırken görüntünün tanımlanmasında kullanılan bazı yöntemler [87] şekli iki boyuttan tek boyuta indirgeyebilir ve bu tek boyutlu veriler tek boyutlu dönüşümlerde kullanılabilir. Ayrıca görüntü üzerinde olduğu şekliyle de dalgacık dönüşümü uygulanabilir.

Uygulamalarımızda tek boyutlu sinyaller yerine, iki boyutlu veriler olan görüntüler üzerinde çalışılmıştır. İki boyutlu dalgacık dönüşümü de görüntü  $I(x,y)$  olarak tanımlanırsa, öncelikle  $I(x,y)$ 'nin  $x$  eksenine göre dalgacık dönüşümü alınır, böylece bir yaklaşık görüntü,  $L_x$ , bir de detay görüntü,  $H_x$ , elde edilir [43].  $L_x$  görüntüdeki bilginin büyük bir kısmını içerir,  $H_x$  ise detay bilgilerini içermektedir [43].  $L_x$  ve  $H_x$  için de bu işlemden sonra  $y$  eksenine göre aynı şekilde dönüşüm uygulanırsa görüntünün 2-D dalgacık dönüşümü alınmış olur ve sonuç olarak  $L_xL_x$ ,  $L_xH_x$ ,  $H_xL_x$ ,  $H_xH_x$  şeklinde dört adet alt görüntü elde edilir [43].



Şekil 2.2. İki boyutlu dalgacık dönüşümü




Şekil 2.3. Araba görüntüsü




Şekil 2.4. Araba görüntüsünün Haar dönüşümü



Şekil 2.5. Araba görüntüsünün Daub4 dönüşümü



Şekil 2.6. Araba görüntüsüne ait 3 seviye Haar dönüşümü



Şekil 2.7.. Araba görüntüsüne ait 3 seviye Daub4 dönüşümü

Şekil 2.2’de de görüldüğü üzere tek boyutlu sinyallerden farklı olarak iki boyutlu sinyallerde Haar ve Daub4 dalgacık dönüşümü sonucu dört adet alt sinyal oluşmaktadır. Şekil 2.3 ile verilen görüntü üzerinde birinci seviye Haar dönüşümü sonucu Şekil 2.4’teki alt görüntüler, birinci seviye Daub4 dönüşümü sonucu Şekil 2.5’teki alt görüntüler, üçüncü seviye Haar dönüşümü sonucu Şekil 2.6’daki alt görüntüler ve üçüncü seviye Daub4 dönüşümü sonucu da Şekil 2.7 alt görüntüleri elde edilmiştir.

#### 2.4. Gabor Dalgacıkları

Gabor dalgacıkları görüntü işlemede etkili yöntemlerden birisidir. Ayrıca, örüntü analizinde çok önemli bir araçtır. Gabor dalgacıkları örüntü ayrıştırma, yüz ve nesne tanıma ve yüz takip etme gibi literatürde birçok uygulamada kullanılmaktadır [26, 27, 88-93]. Gabor dalgacıkları sayesinde görüntünün uzamsal düzlemdeki yerel frekans ve oryantasyon bilgileri incelenebilir [94]. Gabor dalgacıkları görüntünün uzamsal yerelleştirme, oryantasyon seçimi ve frekans karakteristiğiyle gösterilmesine



olanak sağlar ve görüntüde gizli kalan bilgilerin görülmesine yardımcı olarak birçok uygulamada bu özellikleriyle faydalı bir araç olarak kullanılır [27].

Gabor dalgacıkları, Haar ve Daub4 dönüşümleri gibi görüntü üzerinde alt örnekleme sağlamaz, sadece görüntünün farklı frekans ve oryantasyon değerlerinde gösterimine yardımcı olur; boyutun yarıya indirgenmesi isteniyorsa ayrıca Gabor dönüşümünden sonra alt örnekleme yapılması gerekmektedir [88-94].

Güvenilir bir sistem oluşturabilmek için başarımı artırıp azaltabilecek Gabor dalgacıklarının parametre seçimi çok önemlidir, [91] ve [92] kaynaklarında örüntü ayrıştırma için optimal Gabor dalgacıklarının bulunmasını ele alınmıştır. Gabor dalgacıklarının analitik olarak gösterimi (2.15)'te verilmiştir [90,93, 27].

$$\psi_{\mu,\nu}(x,y) = \frac{\|k_{\mu,\nu}\|}{\sigma^2} e^{-\frac{\|k_{\mu,\nu}\|^2((x-x_c)^2+(y-y_c)^2)}{2\sigma^2}} \times \left[ e^{j(\operatorname{Re}(k_{\mu,\nu})(x-x_c)+\operatorname{Im}(k_{\mu,\nu})(y-y_c))} - e^{-\frac{\sigma^2}{2}} \right] \quad (2.15)$$

burada  $\mu$  oryantasyon parametresi,  $\nu$  Gabor dalgacıklarının frekansa ait ölçek parametresi,  $x_c$  ve  $y_c$  iki boyutlu Gabor dalgacık maskesinin merkez noktasının bilgileri,  $\sigma^2$  Gabor dalgacık varyans değeri,  $j = \sqrt{-1}$ ,  $\operatorname{Re}(k_{\mu,\nu})$   $k_{\mu,\nu}$  değişkeninin reel parçası,  $\operatorname{Im}(k_{\mu,\nu})$   $k_{\mu,\nu}$  değişkeninin sanal parçası ve  $\exp(-\sigma^2/2)$  ise sıfır ortalamayı sağlamak için kullanılan katsayıdır.

Denklem (2.15)  $\nu$  ve  $\mu$  değerleriyle farklı ölçek ve oryantasyonda Gabor dalgacıklarının maskelerini oluşturmak için kullanılan ana dalgacık denklemdir. Denklem (2.16) ile gösterilen  $k_{\mu,\nu}$  Gabor dalgacık maskelerinin ana dalgacık denkleminde farklı varyasyonlarla türetilmesini sağlayan  $\nu$  ve  $\mu$  parametrelerine bağlı dalga vektörüdür [90,93, 27].


$$k_{\mu,\nu} = k_\nu e^{j\phi_\mu} \quad (2.16)$$

burada  $k_v$  frekans ve  $\phi_\mu$  oryantasyon değeridir, sırasıyla (2.17) ve (2.18) denklemlerinde gösterilmektedirler [90,93, 27].

$$k_v = \frac{\alpha}{f^v} \quad (2.17)$$

$$\phi_\mu = \frac{\pi\mu}{8} \quad (2.18)$$

Denklem (2.17)'de,  $\alpha$  oluşturulacak Gabor dalgacıklarındaki maksimum frekans değeri,  $f$  ise frekans alanında ölçekleme faktörü  $v$  için aralama faktörüdür [90, 93, 27].




Şekil 2.8. Farklı ölçek ve oryantasyonlarda  $64 \times 64$  Gabor dalgacıkları


$v$  ve  $\mu$  değerlerinin değiştirilmesi ile oluşturulan Gabor dalgacıklarıyla görüntünün gösterimini elde etmek için (2.19)'deki gibi konvolüsyon işlemi uygulanır [90, 93, 27].

$$C_{\mu,v}(x,y) = I(x,y) * \psi_{\mu,v}(x,y) \quad (2.19)$$


burada  $*$  konvolüsyon operasyonu,  $I(x,y)$  orijinal görüntü ve  $C_{\mu,v}$  ise  $v$  ve  $\mu$  değerleri için konvolüsyon sonucu oluşan görüntünün gösterimidir.



Şekil 2.9.  $v = 0$  ve  $\mu = 0, 1, \dots, 8$  için  $24 \times 24$  Gabor dalgacıkları yüzeyleri



Şekil 2.10.  $v = 1$  ve  $\mu = 0, 1, \dots, 8$  için  $24 \times 24$  Gabor dalgacıkları yüzeyleri



Şekil 2.11.  $v = 2$  ve  $\mu = 0, 1, \dots, 8$  için  $24 \times 24$  Gabor dalgacıkları yüzeyleri

### 3. ARKA PLANDAN NESNENİN AYRIŞTIRILMASI

Nesnenin arka plandan ayrıştırılması işlemi video ve görüntü işleme uygulamalarında sıkça karşılaşılan bir problemdir. Önemli olan en gürbüz şekilde nesnenin ayrıştırılmasının sağlanmasıdır. Özellikle gerçek zamanlı video uygulamalarında gürbüzlük kadar sistemin başarımı da çok önemlidir. Bu nedenle çalışmalarda birden fazla yöntem denenerek sisteme gürbüzlük ve başarımlar bakımından en iyi cevabı verebilecek yöntemler araştırılmalıdır. Gözetleme çalışmalarında nesnenin takip edilmesini ve takip edilen nesnenin istenen sınıfa ait olup olmadığının anlaşılabilmesi için arka plandan ayırma işlemi önemli bir yer tutmaktadır. Arka plandan ayrılan görüntünün özellikleri kullanılarak görüntüde takip edilen nesnenin bir önceki görüntüdeki nesne ile benzerliği ve istenen sınıfa ait olup olmadığı gibi işlemler yapılabilir. Özelliklerin ayırt edici olması için kullanılan görüntünün de olabildiğince nesneyi ya da istenen görüntüyü temsil etmesi gerekmektedir. Örneğin, ayrıştırma işlemi sonucunda nesnenin bir kısmı da yok olursa takip işlemi sekteye uğrayabilir. Bu durum sınıflandırmanın sonucunu da etkileyecektir, bu nedenle arka plandan nesnenin ayrıştırılması bu tür çalışmaların başarımı için en önemli araçlardan biridir.

Bu bölümde arka plandan ayırma işlemleri için Çekirdekli Bölge Büyütme (ÇBB), Bulanık Bölge Büyütme (BBB) ve Gabor dalgacıkları yöntemleri üzerinde çalışılmıştır. ÇBB ve BBB yöntemlerini Gabor dalgacıklarından ayıran nokta, Gabor ayrıştırma yönteminin bütün görüntü üzerinde yapılabilmesidir. Fakat, ÇBB ve BBB arka plandan ayrıştırma işleminde, ayrıştırmada kullanılmak üzere belirleyici bir ya da birden fazla noktanın bilinmesi ya da seçilmesi gerekir. Bu yöntemler kullanıcının ayrılmasını istediği nesnenin kullanıcı tarafından seçildiği uygulamalarda kullanıcı-sistem etkileşimi ile nesneyi seçmesine olanak sağlamaktadır. Ayrıca, bu yöntemler arka planın karmaşıklığından bağımsız olarak başarımları yüksek sonuçlar verebilmektedir [6]. Gabor dalgacıkları arka planın karmaşık olduğu durumlarda ayırma işlemini istenilen şekilde tek bir nesne için yapamamaktadır. Görüntüdeki karmaşıklığa bağlı olarak arka plana ait bazı bölgeler de Gabor dalgacıklarıyla elde edilen ayrıştırma işleminin sonucuna katılabilir. ÇBB ve BBB'nin daha verimli kullanılabilmesi için optik akış ve Kalman ile olası noktalar tespit edilip, bu noktalarda uygulanacak ayrıştırma işlemlerinde en iyi sonucu veren görüntü takip

sistemi elde edilebilir. Bu yöntemle sınıflandırma, gözetleme ve takip işleminde iç ve dış ortamdaki bağımsız ışık değişimlerine ve gürültüye karşı en iyi sonucu veren yöntemin seçilmesi amaçlanmaktadır.

### 3.1. Bölge Büyütme

Literatürde bölge büyütme yöntemlerinden genellikle tıbbi görüntüleme çalışmalarında faydalanılmaktadır [6,95,96]. Bölge büyütme yöntemleri, nesnenin arka plandan ayrılması zor olan karmaşık yapıdaki görüntülerde kullanılması tercih edilmektedir. Önemli olan, yapılan uygulamada noktaların bölgeye ait olup olmadığının bilgisini veren üyelik fonksiyonunun olabildiğince gürbüz sonuç vermesini sağlamaktır [97]. Üyelik fonksiyonu seçilen görüntü ve nesneye göre ayrı seçilebilir. Bu şekilde daha iyi neticeler alınabilir. Bütün resimde nesne üzerindeki bütünselliğin ele alındığı genel bir üyelik fonksiyonu ile her nesnenin ayrıştırılması sağlanabilir. Burada da önemli husus bütünsellik değerinin ayırt edici olabilmesidir. Çok gürültülü veya ışık değişiminin fazla ve düzgün yayılım göstermediği resimlerde nesnenin tam olarak arka plandan ayrılması sağlanamayabilir. Ayrıca bölge büyütme yöntemlerindeki diğer önemli nokta, aynı nesneye ait bölgelerin birleştirilmesi işlemidir. Birleştirme işleminde kullanılan kıstas da sistemin doğru çalışmasını etkileyen bir faktördür.

Bölge büyütme yöntemi uygulama bakımından geniş bir alana yayılabilir. Önemli olan çalışılan sisteme en uygun yapının seçilmesidir. Üyelik fonksiyonlarının ve bölgelerin birleştirilmesi kıstaslarının seçimi düzgün yapılırsa çok iyi sonuçlar elde edilebilir. Bölge büyütme yöntemlerinin en önemli sorunu ise bütün resim üzerinde çalışıldığında hesaplama yükünün fazla olmasıdır. Bundan dolayı gerçek zamanlı uygulamalar için işlem başarımı bazında kullanılabilir bir yöntem değildir. Fakat ayrıştırılması istenen nesne biliniyorsa ve o nesne üzerinde seçili bir nokta ile başlanıyorsa gerçek zamanlı uygulamalarda da kullanılabilir; bu şekildeki bölge büyütme yöntemi literatürde Çekirdekli Bölge Büyütme olarak geçmektedir [5]. ÇBB yönteminin üyelik fonksiyonunun geleneksel haliyle eşik değeri ile belirlenmesi yerine bulanık bir yapıyla ele alındığı şekli Bulanık Bölge Büyütme yöntemi olarak bilinmektedir. Tezin bu bölümünde ayrıştırma işlemlerinde ÇBB ve BBB yöntemleri denenmiştir.

### 3.1.1. Çekirdekli Bölge Büyütme

ÇBB, bölge büyütme algoritmaları içerisinde en temel yöntemdir [5]. Bölge büyütme algoritması da bütün resimde ÇBB kullanılarak yapılabilmektedir. ÇBB için kullanılan üyelik fonksiyonu alt-üst eşik değeri ile noktanın bölgeye ait olup olmadığını belirlemektedir. Yapılan çalışmalarda sistemin başarımının ölçülmesi için görüntünün boyutu değiştirilmeden algoritma çalıştırılmıştır. İşlem süresinin uzun olmasından dolayı ÇBB algoritmasında başarım iyileştirme işlemine gidilmiştir. Bu süreçte üyelik fonksiyonundan geçen noktalar işaretlenerek tekrar sorgulanması engellenmiştir, ayrıca görüntünün boyutu küçültülerek daha da fazla zaman kazanılabilmektedir, böylece 6-8 saniye olan işlem zamanı sekizde biri ile otuz ikide birine kadar azalabilmektedir. Değişkenliğin sebebi nesnenin ve görüntünün boyutları ile alakalıdır. ÇBB'nin sözde kodu aşağıdaki gibidir [5]:

```
Nesne üzerinde bir noktanın belirlenmesi (ait nokta)
Ait nokta olmayana kadar her bir ait nokta için
  Her bir komşu nokta için
    Noktaların üyeliklerini belirle
    Eğer ait ise
      Bölgenin üyesi yap
    Değilse
      Bölge dışı nokta olarak belirle
```

Görüldüğü üzere ait olan noktalar tekrar sorgulanabilir, bunu önlemek için üyelik bilgileri belirlenen noktalar işaretlenerek bir daha sorgulanmamaları sağlanmıştır. Değiştirilmiş hali ile ÇBB'nin sözde kodu aşağıdaki gibidir [5].

```
Nesne üzerinde bir noktanın belirlenmesi (ait nokta)
Sorgulanmamış komşuluklarda ait nokta olmayana kadar her bir
ait nokta için
  Her bir sorgulanmamış komşu nokta için
    Noktayı uğranan nokta olarak işaretle
    Noktaların üyeliklerini belirle
    Eğer ait ise
      Bölgenin üyesi yap
    Değilse
      Bölge dışı nokta olarak belirle
```

Farklı alt-üst eşik değerlerine göre elde edilen ayrıştırmalara örnekler Şekil 3.2'den Şekil 3.6'ya kadar verilen şekillerde gösterilmiştir. Alt-üst eşik değerleri sırasıyla 19, 25, 30, 35, 40 olarak ele alınmıştır.


Şekil 3.2'den Şekil 3.6'ya kadar olan sonuçlardan da görüldüğü üzere alt-üst eşik değeri artırıldığında elde edilen nesne çok daha iyidir. Fakat, alt-üst eşik değerinin artırılması arka plandan bazı bölgelerin nesneye aitmiş gibi gözükmeye sebep olabilmektedir. Ayrıca arka plana kayma başladığında sorgulanacak nokta sayısı daha da artacağından işlem süresi de artmaktadır. Diğer bir sorun da ışık değişimin olduğu durumlarda eşik değeri aynı olan durumda bile nesne üzerinden seçilen nokta farklı ise ayrıştırma işleminin sonucu değişmektedir.

Görüldüğü üzere ÇBB yöntemi gerçek zamanlı ışık değişimi ve gürültülerin çok olduğu görüntü uygulamalarında sorun çıkarabilmektedir. Buna rağmen ÇBB ayrıştırma işlemi için kullanılması uygun ve başarımı iyi bir yöntemdir. Üzerinde yapılabilecek iyileştirme çalışmaları ile daha düzgün sonuçların elde edilmesi mümkündür. Aşağıda aynı eşik değerindeki (Eşik değeri = 19) farklı seçim noktaları için elde edilen sonuçlar Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da verilmiştir.




Şekil 3.1. Orijinal görüntü







Şekil 3.2. ÇBB için eşik değeri 19




Şekil 3.3. ÇBB için eşik değeri 25




Şekil 3.4. ÇBB için eşik değeri 30




Şekil 3.5. ÇBB için eşik değeri 35




Şekil 3.6. ÇBB için eşik değeri 40



Şekil 3.7. ÇBB için eşik değeri 19 ile seçilmiş nokta 1



Şekil 3.8. ÇBB için eşik değeri 19 ile seçilmiş nokta 2



Şekil 3.9. ÇBB için eşik değeri 19 ile seçilmiş nokta 3


### 3.1.2. Bulanık Bölge Büyütme

Literatürde BBB yöntemini kullanan birçok çalışma vardır [97-99]. BBB algoritmasında kullandığımız üyelik fonksiyonu, seçilen pikselin renk bilgisini ve seçilen pikselin belirlenmiş sınırlarda merkezinde olduğu örüntüye ait homojenlik bilgilerini kullanarak bulanık mantık yardımı ile üyelik bilgisini hesaplamaktadır [97-99]. Seçilen nesnenin ön tanımlı olduğu çalışmamızda bulanık sistemde renk bilgisine göre ilişkilendirme kurma işlemi başarıyla sonuç vermiştir. Sorgulanan nokta ÇBB' de alt-üst eşik değeri aralığında ise aittir, değilse ait değildir şeklinde tanımlanmakta iken, BBB mantığında ise bulanık yapı, noktanın bölgeye ne kadar ait olduğunun bilgisini vermektedir [97-99]. Matematiksel anlamda 0 ya da 1 almak yerine, bulanık mantıkta 0 ile 1 arasında üyelik derecesi elde edilmektedir. Bu sayede nesnenin de kendi içindeki bütünselliği de görülebilmektedir. BBB'nin sözde kodu aşağıdaki gibidir [5,97-99]:


```
Nesne üzerinde bir noktanın belirlenmesi (ait nokta)
Sorgulanmamış komşuluklarda ait nokta olmayana kadar her bir
ait nokta için
    Her bir sorgulanmamış komşu nokta için
        Noktayı uğranan nokta olarak işaretle
        Noktaların bulanık mantık yoluyla üyelik
        derecesini belirle
        Üyelik bilgisine göre bölgede işaretle
```

Yukarıdaki BBB algoritması kullanılarak elde edilen ayrıştırma sonuçlarına nesne üzerinden seçilen farklı noktalar ile örnekler Şekil 3.10 ve Şekil 3.11'de verilmiştir. Şekillerde de görüldüğü üzere BBB yöntemi nesne üzerinden seçilen farklı noktalara ayrıştırma işleminde iyi ve yaklaşık aynı sonucu vermiştir.

BBB yönteminin en önemli kısmı bulanık yapının ayarlanmasıdır. Bu uygulamada nesnenin rengi bilindiği için bu bilgiye uygun parametre seçimleri yapılmıştır. Aracın belirli bölgesindeki renk değeri seçilerek bulanık mantık yapısı oluşturulmuştur. ÇBB ile BBB karşılaştırıldığında ÇBB, uygulama kolaylığıyla öne çıkarken BBB ise ayrıştırmadaki başarımı ile avantaj sağlamaktadır.




Şekil 3.10. BBB yöntemi sonucu nokta 1



Şekil 3.11. BBB yöntemi sonucu nokta 2

### 3.2. Gabor Dalgacıkları ile Ayrıştırma

Arka planın düz ve basit olduğu durumlarda, ayrıştırma işlemi takip işlemi için başvurulabilir bir yöntemdir. Burada önemli olan görüntüdeki gürültüye ve ışık değişimlerine olan gürbüzlük sistemin başarımını belirlemektedir. Yapılan denemelerde eşik değeri ve yerel eşik değeri yöntemleri gürültü ve ışık değişimlerine istediğimiz düzeyde cevap verememiştir. Fakat, kullandığımız Gabor dalgacıkları yardımıyla yapılan ayrıştırma işlemi eşik değeri ve bölge büyütme yöntemlerine göre başarımlar bakımından daha iyi sonuçlar vermiştir ve nesne neredeyse tam olarak arka plandan ayrılabilmiştir.



Şekil 3.12. Gabor ayrıştırma sonuçları

Bölüm 2.2.3'te Gabor dalgacıkları ile genel bilgilendirme yapılmıştır. Bu bölümde ise Gabor dalgacıkları ile görüntünün gösterimi ile ayrıştırmanın nasıl yapıldığı açıklanacaktır. Arka plandan ayırma işlemi görüntünün her bir ölçek ve oryantasyondaki Gabor dalgacık gösterimleri toplanarak yapılmıştır [27]. Farklı ölçek ve oryantasyondaki Gabor dalgacıklarının toplamı sonucunda nesne arka planın yok olmasıyla görüntüden ayrılmıştır ve belirgin hale gelmiştir. Yapılan işlem aşağıdaki gibi ifade edilebilir [27]:

$$G(x,y) = \sum_{v=0}^K \sum_{\mu=0}^L \|C_{\mu,v}(x,y)\| \quad (6)$$

burada  $G$  görüntünün  $K$  adet ölçek ve  $L$  adet oryantasyonundan oluşan Gabor dalgacık gösterimi,  $C_{v,\mu}$   $v$  ölçeğinde ve  $\mu$  oryantasyonundaki gösterimidir.  $K=2$  ve  $L=4$  seçilerek Şekil 3.12 ile gösterilen sonuç elde edilmiştir.



## 4. ÖZELLİK ÇIKARMA

Özellik çıkarma yöntemleri görüntü işleme uygulamalarındaki bütün halindeki bir sistemin en önemli bileşenlerinden birisidir. Literatürde özellik çıkarma konusunda birçok yöntemi bulunmaktadır [30, 35, 40-46, 80-82]. Video tabanlı işlevlerin en iyi şekilde yapılabilmesi için örüntüden çıkarılan özelliklerin örüntüdeki temel nesnenin boyutundan, dönmesinden, birim dikliğinden ve ışık değişimlerinden bağımsız olması sağlanmalıdır. Ayrıca belirtilen bağımsız olma koşullarına ek olarak, gürültüye karşı gürbüzlüğü ve işlem karmaşıklığının az olması sistemin başarımını etkilemektedir. Bu nedenle kullanılan özellik çıkarma yöntemlerinin başarımlarının hem işlemsel karmaşıklığı hem de belirleyici olma özelliği göz önünde bulundurularak ele alınması gerekmektedir.

Tez çalışması süresince üzerinde çalışılan özellik çıkarma yöntemleri şunlardır: İstatistiksel özellik çıkarma metodu, dalgalık dönüşümü tabanlı özellik çıkarma metodu ve moment tabanlı özellik çıkarma metodudur. Tezin bu bölümünde üzerinde çalışılan bu metotların analitik altyapıları tanıtılacaktır.

### 4.1. İstatistiksel Özellikler

Belirli bir bölgedeki nesnenin özelliklerinin tespit edilebilmesi için kullanılan özellik çıkarma yöntemlerinden en temel yaklaşım olan istatistiksel özellik çıkarma yöntemlerinde, üç seviyede özellik çıkarma işlemi gerçekleştirilmektedir [4, 30]. Bu seviyeler alt orta ve üst seviye özellikler olarak tanımlanabilmektedir [4, 30]. Görüntü histogramına dayanan alt seviye özellikler şunlardır [4, 30]:

$$M = \tau = \sum_{i=1}^n ih(i) \quad (4.1)$$

$$STD = \sigma = \sum_{i=1}^n (i - \tau)^2 h(i) \quad (4.2)$$

$$TM = \sum_{i=1}^n (i - \tau)^3 h(i) \quad (4.3)$$

$$E_1 = -\sum_{i=1}^n h(i) \log(h(i)) \quad (4.4)$$

burada  $h$  iki boyutlu görüntü karesinin histogramını,  $M$  histogramın ortalamasını,  $STD$  histogramın standart sapmasını,  $TM$  üçüncü moment ve  $E_1$  birinci dereceden entropi değerini belirtmektedir. Orta seviye özellikler gri seviye birlikte oluşma matrisi<sup>14</sup> kullanılarak elde edilmektedir. Orta seviye özellikler de aşağıdaki gibi gösterilmektedir [30]:

$$H = \frac{1}{N_c^2} \sum_i \sum_j (M_c(i, j))^2 \quad (4.5)$$

$$M_c(i, j) = \sum_x \sum_y \{I(x, y) = i \ \& \ I(x + \Delta x, y + \Delta y) = j\}$$

$$Cont = \frac{1}{N_c(L-1)^2} \sum_{k=0}^{L-1} k^2 \sum_{|i-j|=k} M_c(i, j) \quad (4.6)$$

$$E_2 = 1 - \frac{1}{N_c(L-1)^2} \sum_i \sum_j M_c(i, j) \log(M_c(i, j)) \quad (4.7)$$

$$Corr = \frac{1}{N_c \sigma_x \sigma_y} \left| \sum_i \sum_j (i - m_x)(j - m_y) M_c(i, j) \right|$$

$$m_x = \frac{1}{N_c} \sum_i \sum_j i M_c(i, j)$$

$$m_y = \frac{1}{N_c} \sum_i \sum_j j M_c(i, j) \quad (4.8)$$

$$\sigma_x^2 = \frac{1}{N_c} \sum_i \sum_j (i - m_x)^2 M_c(i, j)$$

$$\sigma_y^2 = \frac{1}{N_c} \sum_i \sum_j (j - m_y)^2 M_c(i, j)$$

$$LH = \frac{1}{N_c} \sum_i \sum_j \frac{1}{1 + (i - j)^2} M_c(i, j) \quad (4.9)$$

$$Dg = \frac{1}{N_c} \sum_i M_c(i, i) \quad (4.10)$$

$$U = \frac{1}{N_c^2} \sum_i M_c(i, i)^2 \quad (4.11)$$

burada  $i$  ve  $j$  [100] ile belirtildiği gibi gri ton seviyeleri,  $\Delta x$  ve  $\Delta y$  [-1 0 1] değerlerini alan değişim miktarları [100]  $M_c$  birlikte oluşma matrisi [100],  $N_c$  ise  $M_c$ 'nin elemanlarının toplamı,  $H$  türdeşlik<sup>15</sup>,  $Cont$  kontrast,  $E_2$  ikinci derece entropi,  $Corr$

<sup>14</sup> İng. *co-occurrence matrix*

<sup>15</sup> İng. *homogeneity*

korelasyon,  $LH$  yerel türdeşlik,  $Dg$  yönlülük<sup>16</sup>,  $U$  ise eşbiçimlilik<sup>17</sup> değerleridir. Bu tez çalışmasında birinci ve ikinci seviye özellikler kullanılmıştır. Bu nedenle üst derece özellikler ele alınmayacaktır.

#### 4.2. Dalgacık Dönüşümü Tabanlı Özellik Çıkarma Yöntemi

Dalgacık dönüşümü farklı frekans çözünürlüğüne sahip bilgilerin elde edilmesi sayesinde özellik çıkarma yöntemi olarak kullanılmaktadır. Bhagavathy ve Chhabra'nın çalışmalarında kullandığı yöntem olan dalgacık tabanlı örüntü özellikleri çıkarma yöntemi, dalgacık dönüşümden gelen görüntülerin ağırlıklandırılmış standart sapmalarının hesaplanıp bir özellik vektörü oluşturulmasına dayanmaktadır [45]. Bhagavathy ve Chhabra'nın kullandığı yöntem aşağıdaki gibi uygulanır [45]:

- Öncelikle uygulanacak dalgacık dönüşümü için dalgacık seviyesi  $L$  belirlenir
- $L$  seviyesindeki dalgacık dönüşümleri uygulanır. Her seviyede daha önce de belirtildiği gibi dalgacık dönüşümü uygulanan görüntüye ait  $LH$ ,  $HL$ ,  $HH$  alt görüntüleri elde edilir, son seviyede  $LH$ ,  $HL$ ,  $HH$  ile beraber son seviyeye ait  $LL$  alt görüntüsü de elde edilir.
- Elde edilen her alt görüntüden ağırlıklandırılmış standart sapma değerleri ve son seviyedeki yaklaşık görüntüden ortalama değer hesaplanarak özellik vektörü oluşturulur.

Bhagavathy ve Chhabra'nın belirttiği gibi özellik vektörü aşağıdaki gibi gösterilir [45]:

$$\mathbf{x} = \left\{ \sigma_1^{LH}, \sigma_1^{HL}, \sigma_1^{HH}, \frac{1}{2} \sigma_2^{LH}, \frac{1}{2} \sigma_2^{HL}, \frac{1}{2} \sigma_2^{HH}, \dots, \frac{1}{2^{L-1}} \sigma_L^{LH}, \frac{1}{2^{L-1}} \sigma_L^{HL}, \frac{1}{2^{L-1}} \sigma_L^{HH}, \frac{1}{2^{L-1}} \sigma_L^{LL}, \tau^{LL} \right\} \quad (4.1)$$

Uygulamalarda bütün görüntü yerine ayrıştırılmış tanınması beklenen belirli bir şablonun olduğu örüntü üzerinde bu dönüşümler uygulanmaktadır. Bu tez

<sup>16</sup> İng. *directionality*

<sup>17</sup> İng. *uniformity*

çalışmasındaki uygulamalarda 1, 2 ve 3 seviye Haar ve Daub4 türü dalgacık dönüşümler denenmiştir.

### 4.3. Geometrik Momentler

Moment özellikleri görüntüye ait dönme ve konumdan değişimsiz özelliklerinin elde edilmesini sağlar. Boyut değişikliği ve açısal olarak dönmeden bağımsız olmayan momentler, Hu tarafından geometriden bağımsız hale getirilmiştir. Görüntü üzerinde ele alınan iki boyutlu momentler aşağıdaki formül ile elde edilmektedir [101]:

$$m_{pq} = \sum_{y=0}^{N-1} \sum_{x=0}^{M-1} x^p y^q g(x, y) \quad (4.2)$$

$$p, q = 0, 1, 2, 3, \dots$$

burada  $(x,y)$  görüntü koordinatları,  $g$  görüntü,  $m_{pq}$  ise  $p+q \leq n$  iken  $n$ . seviye moment ifadeleri, ve  $N$  ile  $M$  ise görüntünün boyutlarıdır. Momentlerin referans noktalarının merkeze taşınması durumunda moment ifadesi (4.3)'teki gibi olacaktır [4]. Bu durumda oluşan momentlere, merkez momentler adı verilmektedir [4]. Merkez momentler görüntünün normal momentlerinin görüntü merkezine ötelenmesi ile elde edilmektedir [4]. Bundan dolayı merkez momentler, görüntünün ötelenmesinden etkilenmemektedir. Normalizasyon işlemi denklem (4.4)'te gösterilmektedir [4].

$$\varphi_{pq} = \sum_{y=0}^{N-1} \sum_{x=0}^{M-1} (x - \bar{x})^p (y - \bar{y})^q g(x, y) \quad (4.3)$$

$$\bar{x} = \frac{m_{10}}{m_{00}}$$

$$\bar{y} = \frac{m_{01}}{m_{00}}$$

$$\eta_{pq} = \frac{\varphi_{pq}}{\varphi_{00}^\gamma}, \quad \gamma = \frac{(p+q+2)}{2}, \quad p+q = 2, 3, \dots \quad (4.4)$$

Hu tarafından ötelemeden bağımsız hale getirilen normalize merkez momentler aşağıda verilmiştir [4]:

$$\phi_1 = \eta_{20} + \eta_{02} \quad (4.5)$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (4.6)$$

$$\phi_3 = (\eta_{30} - \eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (4.7)$$

$$\phi_4 = (\eta_{30} - \eta_{12})^2 + (\eta_{21} - \eta_{03})^2 \quad (4.8)$$

$$\begin{aligned} \phi_5 = & (\eta_{30} - 3\eta_{12})(\eta_{30} - \eta_{12}) \left( (\eta_{30} - \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right) + \\ & (3\eta_{21} - \eta_{03})(\eta_{21} - \eta_{03}) \left( (\eta_{30} - \eta_{12})^2 - (\eta_{21} - \eta_{03})^2 \right) \end{aligned} \quad (4.9)$$

$$\begin{aligned} \phi_6 = & (\eta_{20} - \eta_{02}) \left( (\eta_{30} + \eta_{12})^2 - (\eta_{12} + \eta_{03})^2 \right) + \\ & 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \end{aligned} \quad (4.10)$$

$$\begin{aligned} \phi_7 = & (3\eta_{21} - \eta_{03})(\eta_{30} - \eta_{12})^2 \left( (\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right) + \\ & (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \left( 3(\eta_{30} + \eta_{12})^2 - (\eta_{12} + \eta_{03})^2 \right). \end{aligned} \quad (4.11)$$

#### 4.4. Tchebichef Momentleri

Tchebichef momentleri, doğrudan görüntü koordinat uzayı üzerinden hesaplanmaktadır ve moment kümesinde dikgenliğini korumaktadır [39, 102]. Tchebichef momentleri aşağıdaki gibi tanımlanmaktadır [39, 102].

$$T_{pq} = \frac{1}{\zeta(p, N)\zeta(q, M)} \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} t_p(x - x_0)t_q(y - y_0)g(x, y) \quad (4.12)$$

burada  $g(x, y)$  ( $N \times M$ ) boyutlarındaki görüntünün gri seviye yoğunluk fonksiyonu,  $(x_0, y_0)$  görüntünün merkez noktası ve  $t_n$  ise ölçeklenmiş tchebichef polinomlarıdır. Ölçeklenmiş tchebichef polinomları denklem (4.13)'te verilmiştir [39, 102, 103].

$$t_p(x) = \frac{(2p-1)t_1(x)t_{p-1} - (p-1)\left(1 - \frac{(p-1)^2}{N^2}\right)t_{p-2}(x)}{p} \quad (4.13)$$

burada  $p$  Tchebichef polinom derecesi olup  $p=2, 3, \dots, N-1$  değerlerini içerir.  $t_0$  ve  $t_1$  ise denklem (4.14) ile gösterilmektedir [39].

$$\begin{aligned} t_0(x) &= 1 \\ t_1(x) &= \frac{2x+1-N}{N} \end{aligned} \quad (4.14)$$

Denklem (4.12)'de Tchebichef momentlerinin hesabında kullanılan  $\zeta(p, N)$  denklem 4.15 ile gösterilmektedir ve

$$\zeta(p, N) = \sum_{x=0}^{N-1} |t_p(x)|^2 \quad (4.15)$$

şeklinde hesaplanmaktadır [39, 102, 103].

#### 4.5. Zernike Momentler

Khotanzad ve Hong tarafından geliştirilen Zernike momentleri, değişimsiz özellik çıkarma yöntemi olarak sunulmuştur [35]. Zernike momentleri hesabında kullanılan Zernike karmaşık polinom seti tamamen dikgen olan bir kümede  $x$  ve  $y$  uzunlukları belirtmek üzere  $x^2 + y^2 = 1$  olan bir eğri üzerinde geçerlidir [35] (Şekil 4.1).

Karesel bir şablonda elde edilen disk dışında kalan pikseller Zernike momentlerinin hesaplanmasında kullanılmayacaktır. Denklem (4.16)'daki gibi belirtilen Zernike polinomlarında,  $V_{pq}(x, y)$ ,  $p$  moment derecesini ve  $q$  moment tekrarlama derecesini belirtmektedir [35, 41, 104-106].

$$V_{pq}(x, y) = V_{pq}(\rho, \theta) = R_{pq}(\rho) \exp(jq\theta) \quad (4.16)$$

burada  $p$  tamsayı olup değeri  $p \geq 0$ 'dır,  $q$  moment tekrarlaması derecesi olup aldığı değerler  $p-q$ =çift tamsayı ve  $|q| \leq p$  şartlarını sağlamalıdır,  $\rho$  parametresi  $(x,y)$  noktasının Şekil 4.4'teki gibi şablonun merkezine olan uzaklığıdır,  $\theta$  değeri  $\rho$  vektörü ve  $x$  eksenini arasındaki saat yönü tersindeki açı değeridir (4.17) ve  $R_{pq}(\rho)$  radyal polinom fonksiyonu olup denklem 4.18 ile gösterilmektedir [35].

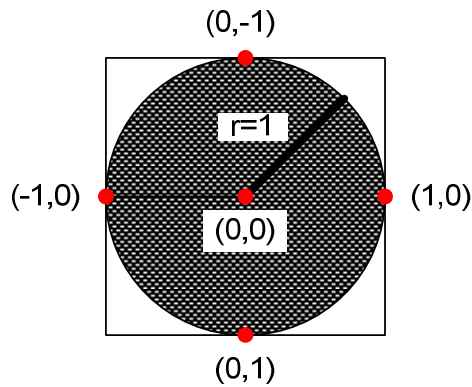
$$\theta = \arctan \frac{y}{x} \quad (4.17)$$

$$R_{pq}(\rho) = \sum_{s=0}^{p-\frac{|q|}{2}} (-1)^s \frac{(p-s)!}{s! \left(\frac{p+|q|}{2}-s\right)! \left(\frac{p-|q|}{2}-s\right)!} \rho^{p-2s} \quad (4.18)$$

Denklem (4.18)'den de çıkarılabileceği gibi  $R_{n,-m}(\rho) = R_{n,m}(\rho)$ 'dir.  $f(x,y)$ 'nin iki boyutlu görüntü karesini tasvir ettiği varsayımı altında Zernike momentleri görüntü işlemlerinde ayrı ayrı ele alınacağından aşağıdaki gibi gösterilebilir [35],

$$A_{pq} = \frac{p+1}{\pi} \sum_x \sum_y f(x,y) V'_{pq}(\rho, \theta) \quad (4.19)$$

burada  $V'_{pq}(x,y)$  ise  $V_{pq}(x,y)$ 'nin eşleniğidir ve  $A_{pq}$  ise  $p$  dereceli  $q$  tekrarlamalı Zernike momentleridir.



Şekil 4.1. Zernike moment için şablon yapısı

#### 4.6. Değiştirilmiş-Zernike Momentleri

Değiştirilmiş-Zernike momentleri de hesaplanması itibari ile Zernike momentlere benzer; birim çember içerisindeki noktalar için hesaplama yapılır [35, 42]. Değiştirilmiş-Zernike momentleri denklem (4.20)'daki gibi hesaplanır [35, 40].

$$Z_{pq} = \frac{p+1}{\pi} \sum_x \sum_y f(x, y) V'_{pq}(\rho, \theta) \quad (4.20)$$

burada  $Z_{pq}$   $p$  dereceli ve  $q$  tekrarlamalı değiştirilmiş-Zernike momentidir,  $V_{pq}(x, y)$  değiştirilmiş-Zernike polinomu olup denklem (4.16)'daki gibi gösterilir [35, 40]. Fakat farklı olan değiştirilmiş-Zernike momentlerde kullanılan  $R_{pq}(\rho)$  radyal polinomudur (4.21) [35, 40].

$$R_{pq}(\rho) = \sum_{s=0}^{p-|q|} (-1)^s \frac{(2p+1-s)!}{s!(p+|q|+1-s)!(p-|q|-s)!} \rho^{p-s} \quad (4.21)$$

burada  $0 \leq |q| \leq p$  ve  $p \geq 0$  şartları sağlanmalıdır ve Zernike momentlerde de değiştirilmiş -Zernike momentlerde de hesaplama yaparken  $x^2 + y^2 > 1$  ise  $V_{pq}(x, y) = 0$  sağlanmalıdır [35, 40].



## 5. YAPAY ZEKÂ UYGULAMALARI

Tezin bu bölümünde, projenin görüntü işleme safhasındaki nesne takibinde, hem takip edilecek nesnenin sınıflandırılması hem de takip edilen nesneye ait en benzer görüntünün bir sonraki video görüntüsünde bulunmasında kullanılacak yapay zekâ uygulamaları üzerinde çalışılmıştır. Tez çalışmasında en yakın komşu, en yakın  $k$  komşu, Bayes ve Yapay Sinir Ağları (YSA) üzerine sınıflandırmaya yönelik uygulamalar denenmiştir. Belirli sayıda ön tanımlı nesne için sınıflandırma çalışmaları başarıyla uygulanmıştır.


### 5.1. En Yakın Komşu

En yakın komşu tekniği, en basit sınıflandırma tekniğidir. Öncelikle nesnelerin sınıflandırılması için o nesneye ait olan ve farklı nesnelere ait olan özellikleri içeren eğitim verilerine ihtiyaç duyulmaktadır. Uzayda bu özelliklerin düzgün dağılmasıyla sonucun daha doğru olması sağlanacaktır [47]. Eğitim verisi olarak kullanılacak verilerin özellikleri ile test nesnesinin özellikleri karşılaştırılarak her test nesnesinin eğitim verilerindeki her nokta ile uzaydaki Euclid mesafesi hesaplanır ve bu mesafelerden en kısa olan mesafe seçilir [47]. Seçilen nokta hangi sınıfa ait ise test edilen nesne de o sınıfta kabul edilir. Euclid mesafesi şu şekilde hesaplanır [4, 47]:

$$D = \sqrt{(f_1 - j_1)^2 + (f_2 - j_2)^2 + \dots + (f_N - j_N)^2} \quad (5.1)$$

Burada  $f$  ve  $j$  eğitim ve test verisine ait özelliklerdir,  $N$  ise sınıflandırılacak nesnelerin tanımlanmasında kullanılacak özelliklerin sayısıdır; bir bakıma özellik uzayının boyutudur ve  $D$  ise iki nokta arasındaki Euclid mesafesidir.


İki özellikli iki nokta arasındaki mesafe için Şekil 5.1’de bir örnek verilmiştir.  $P_1$  ve  $P_2$  noktaları  $x_1$  ve  $x_2$  özelliklerine sahip iki nokta olsun, bu iki nokta arasındaki Euclid mesafesi  $d$  ile gösterilmiştir.



Şekil 5.1. İki özellikli uzayda iki nokta arasındaki Euclid mesafesi

Sınıflandırılmak istenen nesnelere çıkarılacak özellikler değerleri itibariyle çok farklılık gösterebilirler. Her boyut farklı ölçeklerde olabilir. Bu da en yakın komşunun hata yapmasına sebep olacaktır. Bu hatayı gidermek ve en iyi sonucu almak için bütün boyutları aynı ölçekte ele almak gerekir. Bunu sağlamak için her özelliğin kendi içinde normalize edilmesi gerekir [47]. Örneğin her boyuttaki değerler verilerin maksimum ve minimum değerlerine göre 1 ve -1 aralığına eşleştirilebilir. Özellikler normalize edilmeden en yakın komşu kullanılmamalıdır, buna göre iki özellikli 2 sınıflı bir uzayda en yakın komşu kuralına Şekil 5.2’de bir örnek verilmiştir. Sınıfının belirlenmesi beklenen nokta için ona en yakın nokta bulunarak karar verilmiştir.

Şekil 5.2’de de görüldüğü gibi test noktasına en yakın nokta, çember sınıfa ait bir noktadır. Bu durumda test edilen nokta da çember sınıfa ait bir nokta kabul edilir.




Şekil 5.2. İki özellikli uzayda iki sınıf için en yakın komşu

## 5.2. En Yakın $k$ Komşu

En yakın  $k$  komşu yapı itibariyle en yakın komşudan farklı değildir; sadece test noktası ile eğitim noktaları arasındaki mesafeler hesaplandıktan sonra, seçilen  $k$  değeri kadar en kısa mesafeler belirlenir [47]. Seçilen  $k$  nokta en çok hangi sınıfı içeriyorsa test noktasının sınıfı o kabul edilir. En yakın  $k$  komşu veride gürültülerin olduğu durumlarda çok kullanışlı bir yöntemdir [47]. En yakın komşunun yanlış karar verebileceği durumlarda en yakın  $k$  komşu doğru sınıflandırma yapılmasını sağlayabilir. Şekil 5.3'te bu duruma bir örnek gösterilmiştir.

Şekil 5.3'te görüldüğü üzere test noktasına en yakın komşu çember sınıfına ait bir noktadır. Aslında şekilden de anlaşılacağı gibi test noktasına en yakın nokta olan çember noktası sınıflandırma için bir gürültü verisi kabul edilebilir. En yakın komşuya göre aslında yanlış bir sınıflandırma yaptığımız varsayılabilir, çünkü grafiğe bakarak test noktasının aslında kare sınıfına ait olması beklenir. Burada örnek olarak  $k=3$  için en yakın  $k$  komşu kuralı uygulanırsa; test noktasına en yakın 3 noktanın 1 tanesi çember 2 tanesi kare sınıfına aittir. Bu durumda test noktası kare sınıfına ait bir nokta olarak sınıflandırılacaktır. Verilen örnek için en yakın 3 komşu ile sınıflandırma yapmak daha doğru bir sonuç alınmasını sağlayacaktır.



Şekil 5.3. İki özellikli uzayda iki sınıf için en yakın  $k$  komşu

En yakın komşu ve en yakın  $k$  komşu uygulaması çok kolay ve hızlı tekniklerdir, fakat bu tekniklerin düzgün bir şekilde çalışması için eğitim noktalarının özellik

uzayında düzgün dağılması çok önemlidir ve eğitim için kullanılacak nokta sayısının yeterli sayıda olması gerekir, ayrıca özelliklerin normalize edilmesi gerekmektedir [47].

### 5.3. Bayes Sınıflandırıcı

Bayes sınıflandırma yöntemi de çok yaygın ve temel bir sınıflandırma biçimidir. Eğitim verisinde bire bir kıyaslamadan ziyade bütün verilerin istatistiksel özelliklerinden faydalanılarak sınıflandırma yapılması sağlanır [48]. Tez süresince yapılan çalışmalarımda da kullanılan şekliyle, 2 sınıf üzerinden Bayes karar teorisi üzerinde durulacaktır.

Bayes karar teorisinin açıklamaları ve formülasyonları Theodoridis ve Koutroumbas [48] tarafından gösterildiği şekliyle kullanılmıştır. Theodoridis ve Koutroumbas'ın da tanımladığı gibi eğer  $w_1$  ve  $w_2$  iki farklı sınıf olarak ele alınırsa, bu iki sınıfın olasılıkları olan  $P(\omega_1)$  ve  $P(\omega_2)$  değerlerinin bilindiğini kabul edelim [48]. Eğitim verisindeki her nesne  $\mathbf{x}$  özellik vektörü ile betimlenmektedir [48]. Bilinmesi gereken diğer bir istatistiksel bilgi de özellik vektörlerinin sınıflardaki dağılımını gösteren  $N$  sınıflı sınıf-koşullu olasılık yoğunluk fonksiyonu  $p(\mathbf{x}|\omega_i)$ ,  $i = 1, 2, \dots, N$  olmalıdır [48]. Theodoridis ve Koutroumbas'ın belirttiği gibi özellik vektörleri  $l$ -boyutlu özellik uzayında herhangi bir değeri alabilirler [48]. Özellik vektörleri ayrık değerlere sahip olduğu durumlarda yoğunluk fonksiyonları,  $p(\mathbf{x}|\omega_i)$ , olasılıklar olur ve  $P(\mathbf{x}|\omega_i)$  şeklinde gösterilir [48]. Bu durumda koşullu olasılıkları hesaplamak için bütün istatistiksel bilgiler elde edilmiştir [48]. Bayes kuralına göre;

$$P(\omega_i | \mathbf{x}) = \frac{p(\mathbf{x} | \omega_i) P(\omega_i)}{p(\mathbf{x})} \quad (5.2)$$

burada  $p(\mathbf{x})$   $\mathbf{x}$  vektörüne ait olasılık yoğunluk fonksiyonudur [48].

$$p(\mathbf{x}) = \sum_{i=1}^2 p(\mathbf{x} | \omega_i) P(\omega_i) \quad (5.3)$$

2 sınıf üzerinden Bayes karar teorisinin açıklamaları ve formülasyonları Theodoridis ve Koutroumbas tarafından gösterildiği şekliyle ele alınmıştır. Theodoridis ve Koutroumbas'ın da belirttiği gibi Bayes sınıflandırma kuralı aşağıdaki gibi tanımlanabilir[48]:

Eğer  $P(\omega_1 | \mathbf{x}) > P(\omega_2 | \mathbf{x})$  ise  $\mathbf{x}$   $\omega_1$  sınıfına aittir

Eğer  $P(\omega_1 | \mathbf{x}) < P(\omega_2 | \mathbf{x})$  ise  $\mathbf{x}$   $\omega_2$  sınıfına aittir

Eşitlik durumu karar verme için sakıncalı bir durumdur ve tanımlanmak istenen örüntü iki sınıfa da ait gösterilebilir ve karar eşit bir şekilde aşağıdaki eşitsizliğe dayanmaktadır [48].

$$p(\mathbf{x} | \omega_1) P(\omega_1) \geq p(\mathbf{x} | \omega_2) P(\omega_2) \quad (5.4)$$

Eğer ilk olasılıklar eşitse,  $P(\omega_1) = P(\omega_2) = 1/2$ , denklem aşağıdaki gibi olur [48].

$$p(\mathbf{x} | \omega_1) \geq p(\mathbf{x} | \omega_2) \quad (5.5)$$

Böylece maksimum için arama  $\mathbf{x}$ 'deki koşullu olasılık yoğunluk fonksiyonuna dayanır [48].

Her sınıf için eşit olasılık varsayımı yapılırsa Bayes karar fonksiyonu aşağıdaki gibi verilebilir [48]:

$$p(\mathbf{x} | \omega_i) = \frac{1}{(2\pi)^{l/2} |\Sigma_i|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\tau}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\tau}_i)\right), i = 1, \dots, M \quad (5.6)$$

Burada  $\boldsymbol{\tau}_i = E[\mathbf{x}]$   $\omega_i$ 'ye ait beklenen değer,  $\Sigma_i$  kovaryans matrisi, ve  $|\Sigma_i|$  kovaryans matrisinin determinant değerini gösterir.  $\Sigma_i$  aşağıdaki gibi hesaplanır [48]:

$$\Sigma_i = E \left[ (\mathbf{x} - \boldsymbol{\tau}_i)(\mathbf{x} - \boldsymbol{\tau}_i)^T \right] \quad (5.7)$$

### 5.3.1. Minimum Uzaklık Sınıflandırıcısı

Theodoridis ve Koutroumbas'ın gösterdiği üzere aynı kovaryans matrisi olan ve eşit olasılıklarda olduğu varsayılan sınıflar için ayırıcı fonksiyon aşağıdaki gibi basitleştirilebilir [48].

$$\kappa_i(x) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\tau}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\tau}_i) \quad (5.8)$$

$\Sigma = \sigma^2 \mathbf{I}$  yapısındaki bir kovaryans matrisi için  $\kappa_i(x)$ 'nin maksimum değeri minimum Euclid mesafesiyle aynı anlama gelir ve Euclid mesafesi aşağıdaki gibi ifade edilebilir [48].

$$D_\epsilon = \|\mathbf{x} - \boldsymbol{\tau}_i\| \quad (5.9)$$

Buna göre özellik vektörleri ilgili oldukları noktaların ortalamasına olan uzaklıklarına bakılarak sınıflanır [48].

Diyagonal olmayan bir kovaryans matrisi içinse ayırıcı fonksiyonun maksimum değerini bulmak aslında minimum  $\Sigma^{-1}$  norm bulmaktır, bu da aslında Mahalanobis uzaklığı olarak bilinir ve aşağıdaki gibi gösterilir [48].

$$D_m = \left( (\mathbf{x} - \boldsymbol{\tau}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\tau}_i) \right)^{1/2} \quad (5.10)$$


Buradan anlaşılacağı gibi minimum Mahalanobis uzaklığını veren sınıf  $\mathbf{x}$  özellik vektörünün ait olduğu sınıf olarak belirlenir. Eşit olasılıklara sahip olduğu varsayılan sınıflar için kullanılabilir bir sınıflandırma biçimidir [48]. Mahalanobis uzaklığı ve

buna bağılı ayırıcı fonksiyon oluşturarak tez çalışmasında bu sınıflandırma yöntemi kullanılmıştır.

#### 5.4. Yapay Sinir Ağları

Sınıflandırma çalışmalarında iki sınıflı (bir tane tanımlı nesne / tanımlı olmayan nesne) ve çok sınıflı (birden fazla sayıda tanımlı nesne ile ilişkilendirme) sınıflandırma uygulamaları üzerine çalışılmıştır. Bu konuda başvurulan yöntemlerden biri olan YSA farklı değerlerle ağırlıklandırılmış şekilde birbirlerine bağlanmış birden çok nörondan oluşan matematiksel bir yapıdır. YSA öğrenme, ilişkilendirme, sınıflandırma, genelleme, tahmin, özellik belirleme ve optimizasyon amacıyla literatürde sıklıkla kullanılmaktadır. Örüntü tanıma uygulamalarında kullanılan özellik vektörleri neredeyse her zaman çok boyutlu olmaktadır bu nedenle uygulamalarda kullanılan YSA yapıları da çok girişli bir yapıya sahiptir. Sınıf sayısına göre YSA yapısı tek çıkışlı ve çok çıkışlı olabilmektedir.

Çok katmanlı YSA modelinin çalışma yapısını anlamak için öncelikle nöron modelinin yapısı anlaşılmalıdır. Şekil 5.6'da nöron yapısı [107] kaynağında da gösterildiği gibi verilmiştir.



Şekil 5.4. Nöron yapısı

Yukarıdaki sistemin verdiği çıkış cevabı (5.11) ve (5.12)'deki gibi hesaplanmaktadır [107].

$$S = \sum_{i=1}^N w_i u_i - b \quad (5.11)$$

burada  $\mathbf{u}$  özellik vektörü nöron modeline girdi olarak verilmiştir,  $\mathbf{w}$  her bir girdi elemanı için kullanılan ağırlık vektörü,  $b$  nöron için eşik değeri ve  $S$  toplayıcıya ait çıktıdır. Denklem (5.11) yardımıyla elde edilecek sistemin çıktısı (5.12) ile verilmiştir.

$$o = \xi(S) \quad (5.12)$$

burada  $\xi$  nörona ait aktivasyon fonksiyonu ve  $o$  ise sistemin çıkış değeridir [107].

Yapay sinir ağlarında çalışmalarda farklı aktivasyon fonksiyonları kullanılmaktadır, işaret fonksiyonunun türevinin her noktada tanımlı olmamasından dolayı çalışmalarda aktivasyon fonksiyonu olarak işaret fonksiyonu yerine daha yumuşak geçişler sağlaması için (5.13) ile verilen fonksiyon kullanılmıştır [107].

$$\xi(S) = \frac{2}{1 + e^{-2S}} - 1 \quad (5.13)$$

Tez çalışmalarında da kullanılan şekliyle iki sınıflı bir yapıyı ayırmak için önemli olan karar sınırının oluşturulmasıdır [107]. En küçük kareler yöntemi de en temel tekniklerden biridir ve yapay sinir ağlarının ağırlık vektörünün güncellenmesinde de başvurulmaktadır [107]. En küçük kareler yöntemi iki sınıflı bir yapı için eğitim düşümü yönteminde (5.14)'teki maliyet fonksiyonun hesaplanıp ve minimize edilmesinde kullanılmaktadır [107].

$$J_r = \frac{1}{2} e^2 \quad (5.14)$$

burada  $J_r$  maliyet fonksiyonu ve  $e$  hata değeri olup (5.15)'teki gibi hesaplanır [107].



$$e = d - y \quad (5.15)$$

burada  $d$  girdiler için nöron modelinin vermesini istediğimiz çıktı değeri ve  $y$  ise nöron modelinin çıktı değeridir.

Eğim düşümü yönteminde en küçük karesel hata değerine varmak için maliyet fonksiyonu kullanılarak parametre güncelleme denklemleri (5.16) ile verilmiştir [107].

$$\begin{aligned} \Delta w_1 &= -n \frac{\partial J_r}{\partial w_1} = ne \frac{\partial y}{\partial w_1} = ne \frac{\partial y}{\partial S} \frac{\partial S}{\partial w_1} = ne \frac{d\xi}{dS} u_1 \\ &\vdots \\ \Delta w_N &= -n \frac{\partial J_r}{\partial w_N} = ne \frac{\partial y}{\partial w_N} = ne \frac{\partial y}{\partial S} \frac{\partial S}{\partial w_N} = ne \frac{d\xi}{dS} u_N \\ \Delta b &= -n \frac{\partial J_r}{\partial b} = ne \frac{\partial y}{\partial b} = ne \frac{\partial y}{\partial S} \frac{\partial S}{\partial b} = ne \frac{d\xi}{dS} (\pm 1) \end{aligned} \quad (5.16)$$

Denklem (5.16)'daki güncelleme değerleriyle parametre güncellemeleri (5.17)'deki gibi yapılır [107].

$$\begin{aligned} w_1^{yeni} &= w_1^{eski} + \Delta w_1 \\ &\vdots \\ w_N^{yeni} &= w_N^{eski} + \Delta w_N \\ b^{yeni} &= b^{eski} + \Delta b \end{aligned} \quad (5.17)$$

Denklem (5.17)'deki yenileme işlemi bu şekilde hata minimize edilene kadar devam eder. Hatanın minimizasyonu sağlandığında elde edilen parametrelerle nöron yapısı kullanılarak sınıflandırma gerçekleştirilir.

YSA algoritma gereği yapılan hatayı minimize etmeye çalışmaktadır ve bu hatanın minimizasyonu sırasında çeşitli yöntemler kullanılmaktadır. Kullanılan yöntemler yapay sinir ağlarının yakınsama hızını ve hatayı minimize edebilme oranını etkilemektedir. Tez çalışmasında kullanılan YSA modeli çok katmanlı ileri sürümlü

sinir ağı yapısındadır ve parametre güncelleme metodu ikinci seviyeden türev bilgilerini içeren Levenberg-Marquardt (LM) minimizasyon tekniğidir. LM ile eğitilen yapay sinir ağlarındaki başarımlar yüksek seviyelerde elde edilebildiğinden dolayı yapılan çalışmalarda sıklıkla kullanılmaktadır [56,108,109]. YSA uygulamalarında çalışmalarımızda da LM kullanılarak sonuç elde edilmeye çalışılmıştır. Levenberg-Marquardt tekniğinde kullanılan masraf fonksiyonu [110] kaynağında da belirttiği şekliyle denklem (5.18) ile çok çıkışlı yapıda tanımlı bir hata ölçütü için (5.19)'daki gibi verilebilir [110].

$$\begin{aligned}
 e_k^p &= d_k^p - y_k^p \\
 k &= 1, \dots, K \\
 p &= 1, \dots, P
 \end{aligned} \tag{5.18}$$

$$J = \begin{bmatrix} \frac{\partial e_1^1}{\partial w_1} & \frac{\partial e_1^1}{\partial w_2} & \dots & \frac{\partial e_1^1}{\partial w_N} \\ \frac{\partial e_2^1}{\partial w_1} & \frac{\partial e_2^1}{\partial w_2} & \dots & \frac{\partial e_2^1}{\partial w_N} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_K^1}{\partial w_1} & \frac{\partial e_K^1}{\partial w_2} & \dots & \frac{\partial e_K^1}{\partial w_N} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_1^P}{\partial w_1} & \frac{\partial e_1^P}{\partial w_2} & \dots & \frac{\partial e_1^P}{\partial w_N} \\ \frac{\partial e_2^P}{\partial w_1} & \frac{\partial e_2^P}{\partial w_2} & \dots & \frac{\partial e_2^P}{\partial w_N} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_K^P}{\partial w_1} & \frac{\partial e_K^P}{\partial w_2} & \dots & \frac{\partial e_K^P}{\partial w_N} \end{bmatrix} \tag{5.19}$$

Burada  $e_k^p$  değişkeni  $p$  örüntüsünde  $k$  çıkış nöronuna ait hata ölçütü değeri,  $w_i$  ise  $i$ . nöronunun ağırlığıdır [110].


Hata fonksiyonu tekrarlı bir şekilde minimize edilmeye çalışılmaktadır. Yapay sinir ağlarında başlangıç noktası problemin çözümüne etki ettiğinden dolayı minimizasyon işleminin tekrarlanması gerekebilir [108]. Minimizasyon işlemi sırasında gerçekleşen maliyet fonksiyonu kullanılarak parametre güncellemesi denklem (5.20) ile verilmektedir [110].

$$\mathbf{w}^{yeni} = \mathbf{w}^{eski} - \left( J_{eski}^T J_{eski} + \chi_{eski} I \right)^{-1} J_{eski} \vartheta_{eski} \quad (5.20)$$

burada  $\mathbf{w}$  ağırlık parametrelerinin dizilmiş vektör halidir,  $\chi$  adım büyüklüğü ve  $\vartheta$  ise [110] ile gösterildiği gibi bütün örüntülere ait çıktıların olduğu (5.21)'de gösterilen hata vektörüdür [110].


$$\vartheta = \left[ e_1^1 \cdots e_K^1 \quad e_1^2 \cdots e_K^2 \quad \cdots \quad e_1^P \cdots e_K^P \right]^T \quad (5.21)$$

Çok katmanlı tek çıkışlı tek çıkışlı sınıflandırma gerektiren uygulamalarda kullanılan YSA modeli Şekil 5.5'deki gibidir.



Şekil 5.5. Çok girişli tek çıkışlı YSA

Literatürde çok nesneli sınıflandırma için genelde kullanılan çok çıkışlı YSA yapısı Şekil 5.6 ile verilmiştir.



Şekil 5.6. Çok girişli çok çıkışlı YSA

Şekil 5.5 ve Şekil 5.6 üzerinde belirtilen  $\mathbf{u}$  giriş vektörü,  $\mathbf{Y}$  girişlere ait hesaplanan çıkış değeri ve  $\zeta$  ifadesi de transfer fonksiyonudur.

## 6. UYGULAMALAR VE DENEYSEL SONUÇLAR

Bölüm 2'den itibaren bu bölüme kadar üzerinde çalışılmış yöntemler hakkında bilgiler sunulmuştur. Bölüm 1'de de belirtildiği üzere gözetleme işlevleri birçok çalışmayı bünyesinde barındırmaktadır. Tezin bu bölümünde bu işlevlerden ikisi ile yapılan uygulamalar ele alınacaktır. Bu uygulamalardan ilki dalgacık yöntemi ile ayrıştırma ve ayrıştırılan örüntünün sınıflandırılması üzerinedir. İkinci çalışma ise havadan alınmış bir görüntüde seçilen bir nesnenin akan görüntüler boyunca takip işlevi üzerinedir.

### 6.1. Ayrıştırma - Sınıflandırma Uygulaması ve Sonuçları


Bölüm 1'de ayrıştırma ve sınıflandırma üzerine literatürde yapılmış çalışmalar hakkında bilgiler verilmiştir. Verilen bilgiler ışığında ayrıştırma çalışmalarında dalgacık analizinden faydalanmanın iyi bir seçim olacağı görülmektedir. Buna ek olarak yine parametreleri güncellenebilen filtrelerin kullanımı ayrıştırma çalışması sürecinde denemelerin daha rahat yapılabilmesini sağlamaktadır. Bu sebeplerden dolayı yapılan ilk uygulamada ayrıştırma işlevini gerçeklemek için Bölüm 2.2.3'te açıklanan Gabor dalgacıkları kullanılmıştır. Ayrıştırma işlevi Gabor dalgacıkları Bölüm 3.2'de belirtildiği gibi gerçekleştirilmiştir. Bir sonraki adım ayrıştırılan örüntünün özelliklerinin çıkarılmasıdır. Çalışmanın bu kısmında ayrıştırılmış örüntüden özellik çıkarabilmek için Bölüm 4.1'de açıklanan birinci ve ikinci derece istatistiksel özellikler kullanılmıştır. Bir sonraki basamak ise elde edilen özelliklerin sınıflandırılmasıdır. Sınıflandırma işlevi için en yakın komşu, en yakın  $k$  komşu, Bayes ve yapay sinir ağı yöntemleri denenmiştir. Sınıflandırma işlevindeki amaç ayrıştırılan nesnenin araç olup olmadığını belirlenmesi olarak ele alınmıştır.

Uygulama daha önce de belirtildiği gibi görüntüdeki nesnenin iç ortamda basit arka plandan ayrıştırılması ve ayrıştırılan örüntüden elde edilecek birinci ve ikinci derece istatistiksel yöntemlerin yardımıyla farklı sınıflandırma çalışmalarının gerçekleştirilmesidir. Bu çalışmada dört farklı nesne kullanılmıştır. Bu nesnelere biri araba ve diğerleri araba olmayanlar sınıfına ait olması istenen üç farklı nesnedir. Üzerinde işlem yapılan nesnelere ait resimler Şekil 6.1 ile verilmiştir.




Şekil 6.1. Sınıflandırmada kullanılan nesne resimleri

Ayrıştırma işlemi Gabor dalgacıları, eşik değeri belirleme ve bazı görüntü işleme işlemleri ile desteklenerek gerçekleştirilmiştir. Gabor dalgacıları kullanılarak elde edilen ayrıştırma sonuçları dört nesne için de Şekil 6.2 ile gösterilmektedir.



Şekil 6.2. Gabor ayrıştırma görüntüleri

Gabor dalgacıkları ile elde edilen ön ayrıştırma işleminin ardından nesnelere içinde barındıran maskelerin elde edilmesi gerekmektedir. Bu aşamada maskelerle elde edilen örüntülerden istatistiksel özellikler çıkartılmaktadır. Maskeler belirli bir eşik değeri ve morfolojik işlemlerle ayrıştırma işleminin tamamlandığı ikili görüntüler sonucu elde edilmektedir. Ayrıştırma sonucu oluşan bölgeyi kapsayacak bir alan alınarak maskeler oluşturulmuştur. Maskelerin seçimiyle elde edilen örüntülere örnekler büyütülmüş haliyle Şekil 6.3 ile verilmiştir.



Şekil 6.3. Ayrıştırılmış nesnelere şablonları

Şekil 6.4'teki gibi elde edilen örüntüler üzerinden istatistiksel özellikler çıkartılarak nesnelere ait özelliklerin olduğu veriler oluşturulmaktadır. Her bir örüntü için (4.1)-(4.11) denklemlerinde belirtilen 11 özellik bulunduran vektörler oluşturulmuştur. Elde edilen bu özelliklerle sınıflandırma işleminin gerçekleşmesi sağlanmıştır. 100 tanesinin nesne olarak araba içerdiği ve 60 tanesinin diğer nesnelere içerdiği 160 adet eğitim verisi kullanılmıştır. Test işlemini gerçekleştirmek için ise 67 adet araba nesnesine ait ve 36 adet diğer nesnelere ait veriler kullanılmıştır. Bu bölümde ele alınan bütün sınıflandırma yöntemleri eğer test verisi araba ise +1 değilse -1 değeri verecek şekilde oluşturulmuştur. Kullanılan yöntemler ve sonuçları Çizelge 6.1 ile gösterilmiştir.

Sonuçlardan da görüldüğü üzere en yakın komşu ve en yakın  $k$  komşu yöntemleri Bayes ve LM-YSA modeline göre kötü sonuçlar vermektedir. En yakın komşu ve en yakın  $k$  komşu yöntemlerinin iyi sonuç vermesi isteniyorsa özellik uzayında yeterince düzgün dağılmış yeterli sayıda eğitim verisine ve özellik vektörlerinin iyi bir şekilde normalize edilmesine ihtiyaç vardır [47]. Bu sonuçlar yeterince sağlanmadıysa bu yöntemlerle yüksek doğruluk oranı elde etmek mümkün değildir.

Çizelge 6.1. Sınıflandırma sonuçları

	Doğru Sınıflandırma Sayısı	Yanlış Sınıflandırma Sayısı	Doğruluk Oranı %
En yakın komşu	85	18	82.52
En yakın 3 komşu	80	23	77.67
En yakın 5 komşu	83	20	80.58
LM-YSA	96	7	93.20
Bayes	100	3	97.09

LM-YSA yapısı ile elde edilen sınıflandırma %93.20 doğruluk oranı ile tatmin edici düzeyde ve en yakın komşu ile en yakın  $k$  komşu yöntemlerine göre çok daha iyidir, fakat bu yapı eğitim ve test işlemleri ele alındığında daha fazla karmaşıklığa sahiptir ve en iyi sonucu verecek yapının elde edilmesi deneme yanılma yoluna bağlıdır. Daha fazla eğitim denemesi yaparak burda elde edilen başarımın üstüne çıkılması gibi bir durumda olabilir.

Bayes sınıflandırıcı olarak denklem (5.10)'da belirtilen Mahalanobis uzaklığı kullanılmıştır. Eldeki verilerle yapılan sınıflandırmada Mahalanobis uzaklığı kullanılarak yapılan sınıflandırma işlemi %97.09'luk doğruluk oranı ile en iyi sonucu veren sınıflandırma yapısı olmuştur.

Bu uygulamaya ait sonuçlar göstermektedir ki iç ortam çalışmalarına yönelik olarak geliştirilen algoritma dönerkanat tipindeki bir İHA üzerine yerleştirilecek kamera ile elde edilecek görüntüdeki nesnenin araç olup olmadığının tespitinde kullanılarak analiz yapılmasına olanak sağlayacaktır.

## 6.2. Nesne Takibi Uygulaması ve Sonuçları

Bu bölümde anlatılacak çalışma orijinal görüntü yerine görüntünün gösterimi ile şablon eşleme yöntemi için örüntü özellikleri kullanılarak video üzerinde nesne takibi işlevinin başarıyla gerçekleştirilebileceğini göstermektedir. Çalışmadaki amaç videoda hareket edip park eden bir aracın akan görüntüler boyunca takibinin



sağlanmasıdır. Görüntünün gradient tabanlı Gabor dalgacık gösterimi üzerinde değiştirilmiş-Zernike ile şablon eşleme yöntemi algoritması geliştirilmiştir.


Geliştirilen takip sisteminin ilk aşaması Gabor dalgacıklarının birleşimi ile görüntünün gösterimidir. Gabor dalgacıkları ile görüntünün gösterimi elde edildikten sonra gösterim üzerinde iki boyutlu gradient işlemi uygulanarak  $x$  ve  $y$  eksenlerinde iki farklı görüntü gösterimi elde ederiz. Gradient işlemi sonucu elde edilen iki görüntünün büyüklüğü hesaplanarak görüntünün gösterimi için son aşama tamamlanmış olur.

Şablon eşleme yöntemi için kullanılacak şablon için ilk çerçevede nesnenin üzerinden bir nokta seçilir. Bu nokta ile sonraki çerçevelerde olası şablonlardan nesneyi bulmak için kullanılacak arabaya ait şablon oluşturulacaktır ve bu şablona en benzer şablon bir sonraki çerçevede bulunarak takip işlemi gerçekleştirilecektir. Geliştirilen sistem çalışmaya başlamadan önce arabanın üzerinde bir nokta seçili olarak girilmiştir. Araca ait şablon seçildikten sonra şablonun değiştirilmiş-Zernike momentleri çıkartılarak özellik vektörü oluşturulur. İki ardışık çerçeve arasındaki hareket farkının çok fazla olmadığını varsayarak bütün görüntü üzerinde en benzer şablonu aramak yerine bir önceki çerçevede araca ait nokta çevresinde belirli sınırlarda arama yaparak takip işlemi gerçekleştirilmiştir. Sistemin başarımını arttırmak için altıncı çerçeveden itibaren aracın  $x$  ve  $y$  eksenlerinde önceki üç hareket değişimini kullanarak beklenen değişim hesaplanmaktadır. Bulunan beklenen değişim değeri ile sonraki çerçevedeki en iyi şablonu arama noktası bulunmuştur. En benzer şablonun merkez noktası görüntüde takip edilen nesne olarak işaretlenmiştir.


### 6.2.1. Görüntünün Gösterimi

Takip algoritmasının ilk aşaması olan görüntünün gösterimi için de Gabor dalgacıklarından faydalanılmıştır. Bu uygulamada kullanılan Gabor dalgacıkları  $5 \times 5$  boyutunda seçilmiştir. Denklemler (2.18)-(2.21)'de kullanılan parametrelerden  $\nu = 2$ ,  $\mu = \{0,1,2,3,4\}$ ,  $\sigma = 2\pi$ ,  $\alpha = \pi/2$ , ve  $f = \sqrt{2}$  olarak seçilmiştir. Şekil 6.4 ve Şekil 6.5 ile seçilen parametrelerle oluşturulan Gabor dalgacıklarının reel kısmına ait yüzeyler ve


görüntüler sırasıyla verilmiştir. Şekil 6.6 ve Şekil 6.7’de Gabor dalgacıklarının sanal kısmına ait yüzeyler ve görüntüler sırasıyla verilmiştir.




Şekil 6.4. Gabor dalgacıklarının reel parçasının yüzey grafiği



Şekil 6.5. Gabor dalgacıklarının reel parçasının görüntüsü



Şekil 6.6. Gabor dalgacıklarının sanal parçasının yüzey grafiği



Şekil 6.7. Gabor dalgacıklarının sanal parçasının görüntüsü

Görüntünün gösteriminin ilk basamağında elde edilen Gabor dalgacıkları ile görüntü üzerinde konvolüsyon yapılmaktadır. Seçilen parametrelerle beş adet görüntü elde edilir. Gabor gösterimi seçilen parametreler için aşağıdaki gibi yapılır [27].

$$R^v(x,y) = \sum_{\mu=0}^4 \|C_{\mu,v}(x,y)\| \quad (6.1)$$

burada  $C_{\mu,v}$  (2.21)'de de belirtildiği gibi seçilen  $v=2$  ve  $\mu$  değerleri için konvolüsyon sonucu oluşan Gabor dalgacık gösterimidir. Gösterim işlevinin bir sonraki aşaması Gabor dalgacık gösterimin üzerinde gradient operasyonunun uygulanmasıdır. Bu işlem  $R^v$  görüntüsündeki değişimlerin hesaplanıp detayların elde edilmesini sağlamaktadır. Görüntü üzerinde uygulanacak gradient operasyonu denklem (6.2)'deki gibi tanımlanmaktadır [4]. Denklem (6.3) ile ayrık yapıda gradient operasyonu hesaplaması verilmiştir.

$$\nabla R^v := \begin{bmatrix} g_x \\ g_y \end{bmatrix} := \begin{bmatrix} \frac{\delta R^v}{\delta x} \\ \frac{\delta R^v}{\delta y} \end{bmatrix} \quad (6.2)$$

$$\nabla R^v(x,y) \equiv \begin{bmatrix} g_x(x,y) \\ g_y(x,y) \end{bmatrix} \equiv \begin{bmatrix} \frac{(R^v(x+1,y) - R^v(x-1,y))}{2} \\ \frac{(R^v(x,y+1) - R^v(x,y-1))}{2} \end{bmatrix} \quad (6.3)$$


Denklem (6.3)'de  $g_x(x,y)$   $(x,y)$  noktasında  $x$  eksenindeki değişim ve  $g_y(x,y)$   $(x,y)$  noktasında  $y$  eksenindeki değişimlerdir. Görüntünün gösterimi, elde edilen değişimlerin büyüklüğünün hesaplanması (6.4) [4] ile son bulmaktadır.

$$M(x,y) = \|\nabla R^v(x,y)\| = \sqrt{g_x(x,y)^2 + g_y(x,y)^2} \quad (6.4)$$


burada  $M(x,y)$  videodan alınan görüntünün gösterimidir. Takip algoritmasında sıradaki işlem elde edilen bu  $M$  görüntüsü üzerinden şablon seçerek değiştirilmiş Zernike momentlerinin hesaplanmasıdır. Şekil 6.8, Şekil 6.9, Şekil 6.10 ve Şekil 6.11 sırasıyla videodan alınan görüntü, görüntünün yükselteli grafiği, görüntünün Gabor dalgacık gösteriminin yükselteli grafiği ve son olarak görüntünün son gösteriminin yükselteli grafiğidir. Video görüntüsünün kaynağı [76,111] ile aynıdır.




Şekil 6.8. Videodan alınan görüntü



Şekil 6.9. Videodan alınan görüntünün yükselteli grafiği



Şekil 6.10 Görüntünün Gabor dalgacık gösteriminin yükselteli grafiği



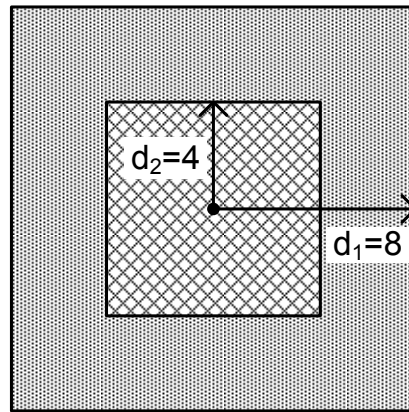
Şekil 6.11. Görüntünün amaçlanan gösteriminin yükselteli grafiği

### 6.2.2. Özellik Çıkarma

Özellik çıkarma geliştirilen algoritmada sistemin başarımında etkili ve önemli basamaklarından birisidir. Seçilecek özellik çıkarma yöntemi sistemin başarımını önemli ölçüde etkileyeceğinden uygulamaya en uygun yöntemin seçilmesi gerekmektedir.

Daha önce de belirtildiği üzere takip algoritmasında değişimsizlik özelliğinden ve ışık değişimlerine gürbüzlüğünden dolayı değiştirilmiş-Zernike momentleri seçilmiştir. Değiştirilmiş-Zernike momentlerin diğer momentlere göre başarımı daha iyidir [40-42] ve Zernike momentlere göre gürültülere karşı daha dayanıklı olmakla beraber örüntüyü daha iyi betimleme özelliğine sahiptir [40-42]. Değiştirilmiş-Zernike momentlerin hesaplanması Bölüm 2.6'daki gibi yapılmıştır.

Seçilen şablonun daha iyi betimlenmesini sağlamak adına şablondan iki pencere seçilmiştir. İlk pencere şablonun kendisi diğeri ise ilk pencere ile aynı merkezli fakat kenar uzunluğu bakımından yarısı büyüklüktedir. Şekil 6.12'te şablon üzerinde oluşan pencereler gösterilemektedir. İki pencere ile iki özellik vektörü elde edilmektedir. Şablonu betimlemek için bu iki özellik vektörü ardarda eklenerek tek bir özellik vektörüne dönüştürülerek özellik çıkarma işlevi gerçekleştirilmektedir.



Şekil 6.12. Şablona ait iki pencere seçimi

Şekil 6.12'te de görüldüğü gibi şablonun ve ilk pencerenin boyu  $17 \times 17$  ve ikinci pencerenin boyutları ise  $9 \times 9$ 'dur.

### 6.2.3. Şablon Eşleme ve Nesne Takibi

Seçilen şablon için özellik vektörünü oluşturduktan sonraki basamak araca ait şablona en benzeyen şablonu sonraki çerçevede bulmaktır. Sonraki çerçevedeki olası eşleşebilecek şablonlar, seçili şablonun merkez noktasının çevresindeki noktalar merkez alınarak oluşturulmaktadır. Olası şablonların merkezleri  $x$  ve  $y$  eksenlerinde seçili şablonun merkezine maksimum 8 piksel uzaklıktaki noktalardan oluşturulmuştur. Böylece şablon eşleme işlemi için seçili şablon ile karşılaştırılacak 289 şablon bulunmaktadır. En benzer şablonu bulmak için 289 şablonun özelliklerinden seçili şablona en yakın şablon bulunmaktadır ve bu işlem için farkların kareleri toplamı (6.5) kullanılmıştır.

$$D(x,y) = \lambda \times \left( (\mathbf{f} - \mathbf{t}(x,y))^T (\mathbf{f} - \mathbf{t}(x,y)) \right) \quad (6.5)$$

burada  $(x,y)$  olası şablonun merkez noktasıdır,  $D(x,y)$  seçili şablonun özellik vektörü  $\mathbf{f}$  ile merkez noktası  $(x,y)$  olan olası şablonun özellik vektörü arasındaki uzaklıktır ve  $\lambda$  değeri ise uzaklığı daha küçük değerlere ölçeklemek için kullanılmakta olup değeri  $10^{-4}$  olarak seçilmiştir. En benzer şablon  $D$  matrisindeki minimum değeri sağlayan  $(x,y)$  noktasının merkezi olduğu şablon olarak seçilir. Bu nokta takip edilmesi istenen araca ait nokta olarak işaretlenir.

Işık değişimlerine ve nesnenin dönme hareketlerinin yarattığı örüntü değişimlerine daha düzgün cevap alabilmek için özellik vektörünün güncellenmesi gerekmektedir. Fakat, baz alınacak özellik vektörünü her şablon eşlemede güncellemek yerine hata olasılığını da azaltmak için 7 çerçevede bir güncelleme yapılmıştır.

Sistemin takip işlevindeki çalışma başarımını arttırmak için altıncı çerçeveden itibaren araca ait beklenen sonraki noktanın yeri hesaplanmaktadır. Öncelikle  $x$  ve  $y$  eksenlerindeki beklenen değişim (6.6)'daki gibi bulunmaktadır ve beklenen değişim değerleri seçili şablonun merkez noktasının değerlerine eklenerek sonraki çerçevedeki arama noktası elde edilmektedir.



$$E\{X\} = \frac{\sum_{k=1}^3 kX_k}{\sum_{k=1}^3 k}, E\{Y\} = \frac{\sum_{k=1}^3 kY_k}{\sum_{k=1}^3 k} \quad (6.6)$$

Burada  $E\{X\}$  ve  $E\{Y\}$   $x$  ve  $y$  eksenlerindeki beklenen deęişim deęerleridir,  $X_k$  ve  $Y_k$  önceki çerçevelerdeki deęişim deęerleridir,  $k=1$  en eski çerçeve ve  $k=3$  ise en son alınan çerçevenin indeksleridir. Bulunan bu beklenen deęişim deęerleriyle arama noktası (6.7)'de gösterildięi gibi elde edilir.

$$S(x, y) = T(x_c + E\{X\}, y_c + E\{Y\}) \quad (6.7)$$

burada  $S(x, y)$  bulunan sonraki çerçevedeki arama noktası ve  $T(x_c, y_c)$  ise seçili şablonun merkez noktasıdır.

Sonraki basamak ise arama noktası çevresinde oluşturulacak uzaklık matrisini ağırlıklandırmaktır. Bu işlem ile minimum uzaklık sonucu seçilecek şablon için bulunan arama noktasına yakın noktlardaki eşlenen şablon olma ihtimalini yükseltip uzak noktalarda eşlenme ihtimali düşürülmektedir. Ağırlık fonksiyonu üstel bir fonksiyon olarak aşağıdaki gibi seçilmiştir.


$$h(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x-x_c)^2 + (y-y_c)^2}{2\sigma^2}} \quad (6.8)$$

Oluşturulan ağırlık fonksiyonu minimum noktası 1 olacak şekilde yeniden düzenlenmiştir buna göre yeni ağırlık fonksiyonu (6.9)'daki gibi olur.

$$l(x, y) = \frac{h(x, y)}{m(h)} \quad (6.9)$$

burada  $l$  kullanılacak ağırlık fonksiyonu ve  $m(h)$  ise (6.8)'deki  $h$  fonksiyonunun minimum deęeridir. Şekil 6.14 (6.9) ile belirtilen  $l$  ağırlık fonksiyonunu göstermektedir. Bu fonksiyon (6.5)'teki gibi hesaplanan uzaklık üzerinde kullanılarak yeni ağırlıklandırılmış uzaklıklar elde edilir (6.10).

$$W(x,y)=D(x,y)l(x,y) \quad (6.10)$$



Şekil 6.13. Ağırlıklandırma fonksiyonunun şablonu

Denklem (6.10) ile elde edilen ağırlıklandırılmış uzaklık değerlerinde minimum değere sahip nokta araca ait takip noktası olarak seçilir. Takip işlevi bu şekilde devam etmektedir.

#### 6.2.4 Nesne Takibi Uygulamasının Sonuçları

Gerçek zamanlı uygulamalardaki zorluk, iyi başarıma sahip olan algoritmalar geliştirirken hesaplama yükünü de minimum seviyede tutabilmektir. Geliştirilen algoritma saniyede 5-6 çerçevelik takip yapabilmektedir ki bu değerler gerçek zamanlı uygulamalar için kabul edilir ölçümlerdir. Şekil 6.14 geliştirilen algoritmanın çeşitli çerçevelerdeki takibini göstermektedir. Görüldüğü üzere geliştirilen algoritma başarılı bir takip işlevi gerçekleştirmiştir. Geliştirilen algoritmaya ek olarak normalize edilmiş çapraz korelasyon (NÇK) [78] ve iki durumlu şablon eşleme (İDŞE) [112] yöntemleri sisteme uyarlanıp aynı şablon ve arama boyutlarıyla denenmiştir. Bu şekilde 3 algoritma da hata tespit durumunda


başarısız takip yapma olasılığı çok yüksek olacaktır. NÇK hızlı ve ışık değişimlerine karşı gürbüz bir yöntem olmasına rağmen dönme hareketine göre değişimsiz değildir [78]. Bu yöntemin uygulanmasının sebebi dönme hareketine değişimsizliğin takip işlevlerinde ne kadar önemli olduğunu göstermektir. Şekil 6.15 NÇK yöntemi ile elde edilen takip sonuçlarından da anlaşılacağı gibi takip edilen nesnenin dönme hareketi ile takip başarısızlığa uğramıştır. İDŞE yöntemi ile takip işlevi, yöntemdeki vektör toplam hesabı frekans alanı yerine uzamsal alanda yapılmasına [112] rağmen saniyede 15 çerçeve gibi yüksek hızda başarıyla gerçekleştirilmiştir. Şekil 6.16, İDŞE yöntemi ile elde edilen takip sonuçlarını farklı çerçevelerde göstermektedir.

Belirtilen üç yöntemin incelenmesi takip edilen nesnenin video boyunca 5 çerçevede bir yaklaşık merkez noktasının seçilmesiyle yapılmıştır. Seçilen bu noktalara uzaklık, hata ölçütü olarak belirlenmiştir ve takip başarımları bu hata ölçütüne göre belirlenmiştir. Şekil 6.17 yöntemlerin hata grafiğini Çizelge 6.2 ise üç yöntem içinde ortalama hata ve varyans değerlerini vermektedir. Sonuçlar göstermektedir ki daha yavaş çalışmasına rağmen geliştirilen algoritma takip işlevinde en az hata ve en az varyans ile en iyi sonucu üretmektedir.

Çizelge 6.2. Yöntemlerin ortalama hata ve hata varyans değerleri

	<b>Ortalama</b>	<b>Varyans</b>
<b>NÇK</b>	67.3539	665.9475
<b>İDŞE</b>	9.1282	27.9134
<b>Sunulan Yöntem</b>	4.3690	2.0517


Dış ortama yönelik geliştirilen takip sisteminde sunulan algoritma kameranın yerleştirildiği araçtan bağımsız bir yapıda olduğundan dolayı projeye yönelik dönerkanat sistemi ve herhangi bir İHA için de kullanılabilir. Sonuç olarak dış ortamda havadan alınan görüntüdeki bir nesnenin kamerada takibi başarıyla sağlanmıştır.



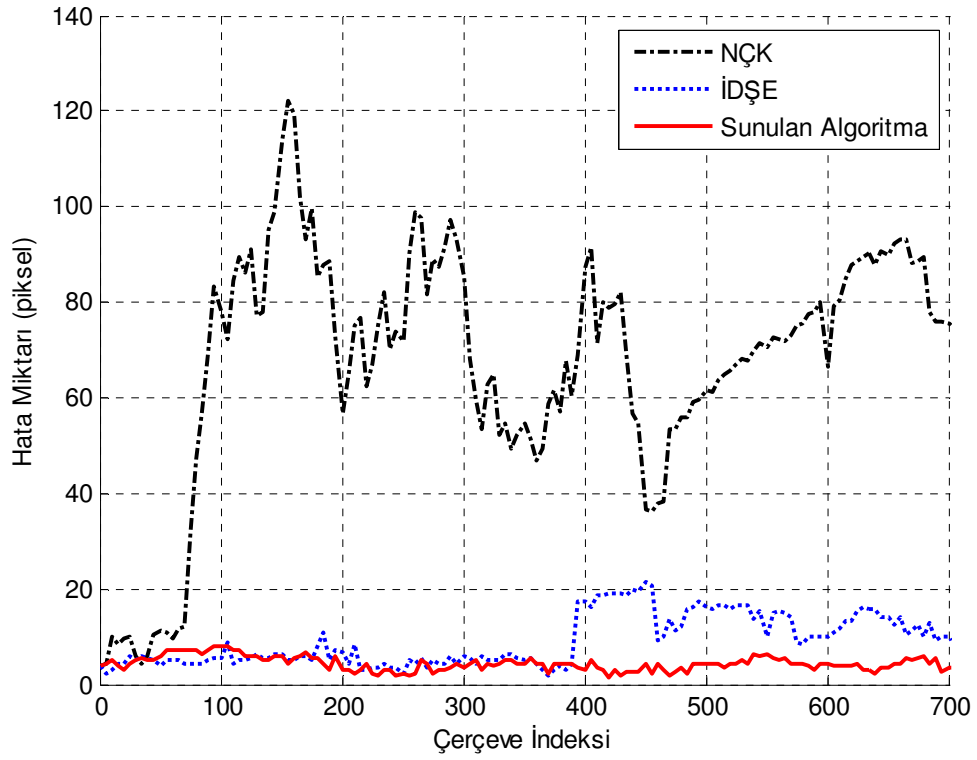
Şekil 6.14 Geliştirilen yöntemin takip sonuçları



Şekil 6.15 NÇK şablon eşleme yönteminin takip sonuçları



Şekil 6.16 İDŞE yönteminin takip sonuçları



Şekil 6.17 Yöntemlerin hata grafiği

### 6.3. Sonuç

Bu çalışmada gözetleme işlevlerinde kullanılacak iki farklı uygulama geliştirilmiştir. Dalgacık dönüşümü analizinin görüntü ve video işleme sistemlerinde farklı analiz imkânı sağlamasından dolayı dalgacık dönüşümü birçok konuda kullanılabilir. Bu nedenle geliştirilen iki uygulamada da dalgacık dönüşümünden faydalanılmıştır. İki çalışmanın sonucu olarak Gabor dalgacıklarının görüntünün gösterimi konusunda faydalı bir araç olduğu gözlemlenmiştir. Ayrıca Gabor dalgacıkları yardımıyla sınıflandırma ve takip çalışmaları başarıyla gerçekleştirilmiştir.

İlk çalışmada Gabor dalgacık gösterimi yardımıyla gerçekleştirilen ayrıştırma sonucunda elde edilen görüntülerin sınıflandırılması 5 farklı yöntem ele alınarak karşılaştırılmıştır. Bayes ve YSA %90'ının üzerinde gösterdikleri başarımla en yakın komşu, en yakın 3-komşu ve en yakın 5-komşu yöntemlerine göre çok daha güvenilir olduklarını göstermişlerdir. Bayes yöntemi ise karşılaştırılan yöntemler arasında en iyi sonucu vermiştir.

Gradient tabanlı Gabor dalgacık gösteriminin kullanıldığı şablon eşleme yöntemi ile gerçekleştirilen takip sistemi de video çerçeveleri boyunca nesnenin takibini başarmıştır. Ayrıca, sisteme uyarlanan NÇK takip işlevini gerçekleştirememiştir ve İDŞE yöntemi sunulan algoritmaya göre takip işlevini hızlı gerçekleştirmesine rağmen takip sırasındaki hata varyans değeri daha yüksek olmuştur. Sunulan algoritma düşük hata varyans ve ortalama değerine sahiptir. Geliştirilen yöntem daha yavaş çalışmasına rağmen daha düzgün bir takip işlevi gerçekleştirmiştir.

Belirtilen iki uygulamada da dönerkanat tipindeki bir İHA düşünülerek tasarlanmıştır. İki çalışmada da görüntüler havadan yeri gözetleyecek şekilde ele alınan görüntülerdir. İlk çalışmada iç ortam şartları ile gerçekleştirilmiştir, ikinci çalışmada ise dış ortamda bir İHA üzerindeki yeri gözetleyen kamera ile havadan alınmış görüntü kullanılarak nesne takip işlemi başarılmıştır. Geliştirilen iki yapı da dönerkanat tipindeki bir İHA sisteminde gözetleme işlevleri olarak kullanılabilir. İki uygulama ile tezin amacı olan dönerkanat aracına yönelik video işlevlerinin gerçekleştirilmesi sağlanmıştır.



## KAYNAKLAR

- [1] Sarris, Z., Survey of Uav Applications in Civil Markets, STN ATLAS-3Sigma AE ve Technical University of Crete DPEM, Haziran 2001.
- [2] Everaerts, J., The Use Of Unmanned Aerial Vehicles (Uavs) For Remote Sensing And Mapping, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, VXXXVII(B1), 1187-1192, 2008.
- [3] Puri, A., A Survey of Unmanned Aerial Vehicles (UAV) for Traffic Surveillance, Department of Computer Science and Engineering University of South Florida.
- [4] Gonzales, R. C., Woods, R. E., Digital Image Processing, *Prentice Hall*, Upper Saddle River, New Jersey, 2008.
- [5] Adams, R., Bischof, L., Seeded Region Growing, IEEE Trans. On Pattern Analysis and Machine Intelligence, 16(6), 641-647, Haziran 1994.
- [6] Hojjatoleslami, S. A., Kitler, J. Region Growing: A New Approach, IEEE Transactions on Image Processing, 7(7), 1079–1084, Temmuz 2008.
- [7] Feng, Y., Fang, H., Jiang, J., Region Growing with Automatic Seeding for Semantic Video Object Segmentation, LNCS, 3687, 542-549, 2005.
- [8] Gómez, O., González, J.A., Morales, E.F., Image Segmentation Using Automatic Region Growing and Instance-Based Learning, LNCS 4756, 192-201, 2007.
- [9] Wu, J., Poehlman, S., NoseWorthy, M.D., Kamath, M.V., Texture Feature based Automated Seeded Region Growing in Abdominal MRI Segmentation, International Conference on Biomedical Engineering and Informatics, 2, 263-267, Mayıs 2008.
- [10] Padros-Suárez, B., Sánchez, D., Chamoro-Martínez, On Significant Crisp REpresentatives of Fuzzy Regions in Colour Images, FUZZ-IEEE, 1909-1914, Temmuz 2007.
- [11] Kang, C.-C., Wang, W.-J., Fuzzy Based Seeded Region Growing for Image Segmentation, The 28th NAFIPS Annual Conference, Ohio, USA, Haziran 2009.
- [12] Philipp-Foliguet, S., Gony, J., Gosselin, P-H., FReBIR: An Image Retrieval System Based on Fuzzy Region Matching, Computer Vision and Image Understanding, 113(6), 693-707, Haziran 2009.
- [13] Veloz, A., Chabert, S., Salas, R., Orellana, A., Vielma, J., Fuzzy Spatial Growing for Glioblastoma Multiforme Segmentation on Brain Magnetic Resonance Imaging, LNCS, 4756, 861-870, 2007.
- [14] Deniz, U., 2004, Ardışık Görüntülerde Hareket Analizi, *Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü*, Antakya.
- [15] Horn, B.K.P., Schunk, B.G., Determining Optical Flow, Artificial Intelligence, 17, 185-203, 1981.
- [16] Wedel, A., Pock, T., Zach, C. Bischof, H., Cremers, D., An Improved Algorithm for TV-L<sup>1</sup> Optical Flow, LCNS 5604, 23-45, 2009.
- [17] Altunbaşak, Y., Eren, P.E., Tekalp, A.M., Region-Based Parametric Motion Segmentation Using Color Information, Graphical Models and Image Processing, 60(1), 13-23, Ocak 1998.
- [18] Schoenemann, T. Cremers, D., Near Real-Time Motion Segmentation Using Graph Cuts, LNCS, 4174, 455-464, 2006.

- [19] Chen, T.-W., Chen, Y.-L., Chien, S.-Y., Fast Image Segmentation Based on K-MEans Clustering with Histograms in HSV Color Space, IEEE 10th Workshop on Multimedia Signal Processing, 322-325, 2008.
- [20] Chen, C.W., Luo, J., Parker, K.J, Image Segmentation via Adaptive K-Mean Clustering and Knowledge-Based Morphological Operations with Biomedical Applications, IEEE Trans. On Image Processing, 7(12), 1673-1683, 1998.
- [21] Li, Q., Mitianoudis, N., Stathaki, T., Spatial Kernel K-Harmonic Means Clustering for Multi-spectral Image Segmentation, IET Image Processing, 1(2), 156-167, 2007.
- [22] Chuang, K.-S., Tzeng, H.-L., Chen, S., Wu, J., Chen, T.-J., Fuzzy c-Means Clustering with Spatial Information for Image Segmentation, Computerized Medical Imaging and Graphics, 30, 9-15, 2006.
- [23] Liu, H., Chen, Z., Chen, X., Chen, Y., Multiresolution Medical Image Segmentation Based on Wavelet Transform, IEEE Proc. on 27th Annual Conference Engineering in Medicine and Biology, 7, 3418-3421, Shangai, China, Eylül, 2005.
- [24] Li, Y., Zhang, Y., Jiang, X., Zhao, R., Xing, M., Segmentation of Images Using Wavelet Packet Based Feature Set and Clustering Algorithm, International Journal of Information Technology, 11(7), 112-121, 2005.
- [25] Deschénes, S., de Guise, J., Wavelet-based Automatic Segmentation of the Vertebral Bodies in Digital Radiographs, International Conference on Acoustics, Speech, and Signal Processing, IV, 3868-3871, Florida, USA, Mayıs 2002.
- [26] Wiskott, L., Segmentation from Motion: Combining Gabor and Mallat Wavelets to Overcome the Aperture and Correspondence Problems, 32, 1751-1766, 1999.
- [27] Wei, H., Bartels, M., Unsupervised Segmentation Using Gabor Wavelets and Statistical Features in LIDAR Data Analysis, 18th International Conf. on Pattern Recognition, 1, 667-670, 2006.
- [28] Nixon, M.S., Aguado, A.S., Feature Extraction & Image Processing, *Elsevier*, Theobald's Road, London, 2008.
- [29] Kumar, S.V.B., Ramaswamy, S., A texture Analysis Approach for Automatic Flaw Detection in Pipelines, International Conf. on Signal Processing & Communications, 320-323, 2004.
- [30] Borchani, M., Stamon, G., Use of Texture Features for Image Classification and Retrieval, In Proc. SPIE Conference on Storage and Retrieval for Image and Video Databases III, 3229, 401-406, 1997.
- [31] Antani, S., Kasturi, R. Jain, R., A Survey on the Use of Pattern Recognition Methods for Abstraction, Indexing, and Retrieval of Images and Video, Pattern REcognition, 35, 945-965, 2002.
- [32] Newsam, S., KAmath, C., Comapring Shape and Texture Features for Pattern Recognition in Simulation Data, Image Processing: Algorithms and Systems IV, SPIE Electronic Imaging, UCRL-CONF-208568, Ocak 2005.
- [33] Hu, M. K., Visual Pattern Recognition by Moment Invariants, IEEE Trans. on Information Theory, 8(2), 179-187, 1962.
- [34] Yang, L., Albregtsen, F., Fast Computation of Invariant Geometric Moments: A New Method Giving Correct Results, International Conf. on Pattern Recognition, 201-204, Jerusalem, Israel, 2004.

- [35] Khotanzad, A., Hong, Y. H., Invariant Image Recognition by Zernike Moments, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 12, 489-497, 1990.
- [36] Mukundan, R., Ramakrishnan, Fast Computation of Legendre and Zernike Moments, *Pattern Recognition*, 28(9), 1433-1442, 1995.
- [37] Gu, J., Shu, H.Z., Toumoulin, C., Luo, L.M., A Novel Algorithm for Fast Computation of Zernike moments, *Pattern Recognition*, 35, 2905-2911, 2002.
- [38] Belkasim, S.O., Ahmadi, M., Shridhar, M., Efficient Algorithm for Fast Computation of Zernike Moments, *Circuits and Systems, IEEE 39th Midwest Symposium 3*, 1401-1404, 1996.
- [39] Mukundan, R., Ong, S. H., Lee, P.A., Image analysis by Tchebichef Moments, *IEEE Trans. on Image Processing*, 10, 1357-1364, 2001.
- [40] Chong, C. W., Mukundan, R., Raveendran, P., An Efficient Algorithm for Fast Computation of pseudo-Zernike Moments, *International Journal of Pattern Recognition and Artificial Intelligence*, 17(6), 1011-1023, 2003.
- [41] Prokorp, R. J., and Reeves, A. P., A Survey of Moment-Based Techniques for Unoccluded Object Representation and Recognition, *CVGIP: Graphical Models and Image Processing*, 54, 438-460, 1992.
- [42] Teh, C.-H., Chin, R. T., On Image Analysis by the Methods of Moments, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 10(4), 496-513, Temmuz 1988.
- [43] Sarlashkar, M.N., Bodruzzaman, M., Malkani, M.J., Feature Extraction Using Wavelet Transform for Neural Network Based Image Classification, *Proc. of the 13th Southeastern Symposium on System Theory*, 412-416, 1998.
- [44] Zhang, S.-Y., Xue, X., Zhang, X., Feature Extraction and Classification with Wavelet Transform and Support Vector Machines, *In Proc. IEEE International Symposium Geosciences and Remote Sensing*, 6, 3795-3798, 2005.
- [45] Bhagavathy, S., Chhabra, K., A Wavelet-based Image Retrieval System”, *Project Report, University of California*, Department of Electrical and Computer Engineering, Santa Barbara.
- [46] Liang, K.-C., and Jay Kuo, C.-C., WaveGuide: A Joint Wavelet-Based Image Representation and Description System, *IEEE Trans. on Image Processing*, 8(11), 1619-1629, 1999.
- [47] Russel, S., Norvig, *Artificial Intelligence: A Modern Approach*, *Prentice Hall*, Upper Saddle River, New Jersey, 2003.
- [48] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, *Academic Press Elsevier*, San Diego, CA, 2006.
- [49] Cover, T.M., Hart, P.E., Nearest Neighbor Pattern Classification, *IEEE Trans. On Information Theory*, 13(1), 21-27, Ocak 1967.
- [50] Tsymbal, A., Puuronen, S., Pechenizkiy, M., Baumgarten, M., Patterson, D., Eigenvector-based Feature Extraction for Classification, *In Proc. of the 15th International Florida Artificial Intelligence Research Society Conference*, 354-358, Florida, USA, Mayıs 2002.
- [51] Mahar, J.A., Mahar, M.H., Khan, M.K., Comparative Study on Feature Extraction Methods with  $K$ -NN for Off-Line Signature Verification, *IEEE 2nd International Conf. on Emerging Technologies*, 115-120, Peshawar, Pakistan, Kasım 2006.
- [52] Seltzer, M.L., Raj, B., Stern, R.M., A Bayesian Classifier for Spectrographic Mask Estimation for Missing Feature Speech Recognition, *Speech Communication*, 43, 379-393, 2004.

- [53] Patridge, M., Jabri, M., Hierarchical Feature Extraction for Image Recognition, *Journal of VLSI Signal Processing*, 32, 157-167, 2002.
- [54] Masip, D., Bressan, M., Vitriá, J., Feature Extraction Methods for Real-Time Face Detection and Classification, *EURASIP Journal on Applied Signal Processing*, 13, 2061-2071, 2005.
- [55] Kato, N., Suzuki, M., Omachi, S., Aso, H., Nemoto, Y., A Handwritten Character Recognition System Using Directional Element Feature and Asymmetric Mahalanobis Distance, *IEEE Trans. On Pattern Analysis and Machine Intelligence*, 21(3), 258-262, Mart 1999.
- [56] Zhang, G.P., Neural Networks for Classification, *IEEE Trans. on Systems, Man, and Cybernetics – Part C: Applications and Reviews*, 30(4), Kasım 2000.
- [57] Rowley, H.A., Baluja, S., Kanade, T., Neural Network-Based Face Detection, *IEEE Trans. on PAMI*, 20(1), 23-28, 1998.
- [58] Correia, S.E.N., de Carvalho, J.M., Sabourin, R., On the Performance of Wavelets for Handwritten Numerals Recognition, *Procs. of 16th International Conference on Pattern Recognition*, 3, 127-130, 2002.
- [59] Gonzalez, A.C., Sossa, J.H., Felipe, E.M., Pogrebnyak, O., Wavelet Transforms and Neural Networks Applied to Image Retrieval, *The 18th International Conference on Pattern Recognition*, 2, 909-912, 2006.
- [60] Sahoolizadeh, H., Sarikhanimoghadam, D., Denghani, H., Face Dtection Using Gabor Wavelets and Neural Networks, *World Academy of Science, Engineering, and Technology*, 45, 552-554, 2008.
- [61] Hu, W., Tan, T., Wang, L., Maybank, S., A Survey on Visual Surveillance of Object Motion Behaviors, *IEEE Transactions On Systems, Man, and Cybernetics Part C: Applications and Reviews*, 34(3), 334-352, Ağustos 2004.
- [62] Kontitsis, M., Valavanis, K.P., Tsourveloudis, N., A UAV Vision System for Airborne Surveillance, *IEEE International Conference on Robotics and Automation*, 77-83, Nisan 2004.
- [63] Kumar, R., Sawhney, H., Samarasekera, S., Hsu, S., Tao, H., Guo, Y., Pope, A., Hanna, K., Wildes, R., Hirvonen, D., Hansen, M., Burt, P., Aerial Video Surveillance and Exploitation, *Proc. of the IEEE*, 89(10), 1518-1539, Ekim 2001.
- [64] Cohen, I., Medioni, G., Detecting and Tracking Moving Objects for Video Surveillance, *IEEE Proc. on Computer Vision and Pattern Recognition*, 319-325, Haziran 1999.
- [65] Kang, J., Cohen, I., Medioni, G., Yuan, C., Detection and Tracking of Moving Objects from a Moving Platform in Presence of Strong Parallax, *Proc. of the IEEE International Conference on Computer Vision*, 1, 10-17, Ekim 2005.
- [66] Tao, H., Sawhney, H., Kumar, R., Dynamic Layer Representation with Applications to Tracking, *IEEE Proc. on Computer Vision and Pattern Recognition*, 2, 134-141, Haziran 2000.
- [67] KaewTraKulPong, P. and Bowden, R., An Improved Adaptive Background Mixture Model for Real-time Tracking with Shadow Detection, In. *Proc. 2<sup>nd</sup> European Workshop on Advanced Video Based Surveillance Systems, AVBS01*, 2001.
- [68] Elgammal, A., Duraiswami, R., Harwood, D., and Davis, L.S., Background and Foreground Modelling Using Nonparametric Kernel Density Estimation for Visual Surveillance, In *Proc. the IEEE*, 9(7), 1151-1163, 2002.

- [69] Amiri, M., Rabiee, H.R., Behazin, F., and Khansari, M., A new Wavelet Domain Block Matching Algorithm for Real-time Object Tracking, In Proc. of International Conference on Image Processing, 3, 961-964, 2003.
- [70] Comaniciu, D., Bayesian Kernel Tracking, In Proc. 24<sup>th</sup> DAGM Symposium on Pattern Recognition, Lecture Notes In Computer Science, 2449, 438-445, Springer-Verlag, 2002.
- [71] Yilmaz, A., Javed, O., Shah, M., Object Tracking: A Survey, ACM Computing Surveys, 38(4), Article 13, Aralık 2006.
- [72] Zivkovic, Z., Improved Adaptive Gaussian Mixture Model for Background Subtraction, In Proc. 17th International Conference on Pattern Recognition, 2, 28-31, 2004.
- [73] Wang, Y., Doherty, J.F., Van Dyck, R.E., Moving Object Tracking in Video, In Proc. 29th Applied Imagery Pattern Recognition Workshop, 95-101, 2000.
- [74] Koller, D., Weber, J., Huang, T., Malik, J., Ogasawara, G., Rao, B., Russell, S., Towards Robust Automatic Traffic Scene Analysis in Real-time, In Proc. 33<sup>rd</sup> IEEE Conference on Decision and Control, 4, 3776-3781, 1994.
- [75] Lu, N., Wang, J., Wu, Q.H., and Yang, L., An Improved Motion Detection Method for Real-time Surveillance, IAENG International Journal of Computer Science, 35(1), 1-10, 2008.
- [76] K. Kaâniche, B. Champion, C. Pégard, and P. Vasseur, “A Vision Algorithm for Dynamic Detection of Moving Vehicles with a UAV”, In Proc. of the IEEE International Conference on Robotics and Automation, 1878-1883, Nisan 2005.
- [77] Medioni, G., Nevatia, R., and Cohen, I., Event Detection and Analysis from Video Streams, IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(8), 873-889, 2001.
- [78] Lewis, J.P., Fast Template Matching, Vision Interface, 120-123, 1995.
- [79] Chen, J.-H., Chen, C.-S., and Chen, Y.-S., Fast Algorithm for Robust Template Matching with M-Estimator, IEEE Trans. on Signal Processing, 51(1), 230-243, 2003.
- [80] Tang, F., and Tao, H., Fast Multi-scale Template Matching using Binary Features, IEEE Workshop on Application of Computer Vision, Article 36, 2007.
- [81] Marimon, D., and Ebrahimi, T., Efficient Rotation-discriminative Template Matching, In Proc. 12<sup>th</sup> Iberoamerican Congress on Pattern Recognition, Lecture Notes in Computer Science, Springer, 4756, 221–230, 2007.
- [82] Sibiryakov, A., Statistical Template Matching under Geometric Transformations, Lecture Notes in Computer Science, Springer, 4992, 225-237, 2008.
- [83] Walker, J.S., A Primer on Wavelets and their Scientific Applications, *Chapman & Hall/CRC*, Boca Raton, 1999.
- [84] Semmlow, J.L., Biosignal and Biomedical Image Processing: Matlab Based Applications, *Marcel Dekker Inc*, New York, 2004.
- [85] Koçyiğit, Y., Korukürek, M. EMG İşaretlerini Dalgacık Dönüşümü ve Bulanık Mantık Sınıflayıcı Kullanarak Sınıflama, itüdergisi/d mühendislik 4(3), 25-31 Haziran 2005.
- [86] Skorpil, V., Stastny, Wavelet Transform for Image Analysis, IEEE Siberian Conference on Control and Communications, 50-55, Ekim 2003.
- [87] Bui, T.D., Chen, G., Invariant Fourier-Wavelet Descriptor For Pattern Recognition, Pattern Recognition, 32, 1083-1088, 1999.

- [88] Lee, T. S., Image Representation Using 2D Gabor Wavelets, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 18(10), 959-971, Ekim 1996.
- [89] He, C., Zheng, Y. F., Ahalt, S. C., Object Tracking Using the Gabor Wavelet Transform and the Golden Section Algorithm, *IEEE Trans. on Multimedia*, 4(4), 528-538, Aralık 2002.
- [90] Liu, C., Gabor-based Kernel PCA with Fractional Power Polynomial Models for Face Recognition, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 26(5), 572-581, Mayıs 2004.
- [91] Tsai, D.-M., Wu, S.-K., Chen, M.-C., Optimal Gabor Filter Design for Texture Segmentation Using Stochastic Optimization, *Image and Vision Computing*, 19(5), 299-316, Nisan 2001.
- [92] Dunn, D., Higgins, W. E., Optimal Gabor Filters for Texture Segmentation, *IEEE Trans. on Image Processing*, 4(7), 947-964, Temmuz 1995.
- [93] Jones, J. P. and Palmer, L. A., An Evaluation of the Two-Dimensional Gabor Filter Model of Simple Receptive Fields in Cat Striate Cortex, *Journal of Neurophysiology*, 58(6), 1233-1258, Aralık 1987.
- [94] Loy, G., Fast Computation of the Gabor Wavelet Transform, *Digital Image Computing Techniques and Applications*, 279-284, Jan 2002.
- [95] Hao, X., Bruce, C., Pislaru, C., Greenleaf, J.F., A novel region growing method for segmenting ultrasound images, *IEEE Ultrasonics Symposium*, 2, 1717-1720, 2000.
- [96] Xu, W., Cumming, I., A region-growing algorithm for InSAR phase unwrapping, *IEEE Transactions on Geoscience and Remote Sensing*, 37(1), 124-134, Ocak 1999.
- [97] Ong, H.P., Rajapakse, J.C., Fuzzy-Region-Segmentation, *Proc. on International Joint Conference on Neural Networks*, 2, 1374-1379, 2001.
- [98] Maeda, J., Novianto, S., Saga, S., Suzuki, Y., Segmentation of Natural Images using Fuzzy Region-Growing Algorithm, *Memoirs of the Muroran Institute of Technology*, (50), 47-53, 2000.
- [99] Moghaddamzadeh, A., Bourbakis, N., A Fuzzy Region Growing Approach for Segmentation of Color Images, *Pattern Recognition*, 30(6), 867-881, 1997.
- [100] Mokji, M.M., Abu Bakar, S.A.R., Gray Level Co-Occurrence Matrix Computation Based On Haar Wavelet, *Proceedings of the Computer Graphics, Imaging and Visualisation*, 273-279, Ağustos, 2007.
- [101] Tuceryan, M., Moment Based Texture Segmentation, *Appeared in Pattern Recognition Letters*, 15, 659-668, Temmuz 1994.
- [102] Zhu, H., Shu, H., Xia, T., Luo, L., Coatrieux, J.L., Translation and Scale Invariants of Tchebichef Moments, *Pattern Recognition*, (9), 2530-2542, Eylül 2007.
- [103] Rani, J.S., Devaraj, D., Sukanesh, R., A Novel Feature Extraction Technique for Face Recognition, *International Conf. on Computational Intelligence and Multimedia Applications*, 2, 428-435, 2007.
- [104] Liao, S.X., Image Analysis with Zernike Moment Descriptors, *IEEE Canadian Conference on Electrical and Computer Engineering*, 2, 700-703, 1997.
- [105] Lin, T.W., Chou, Y.F., A Comparative Study of Zernike Moments, *Proc. of IEEE/WIC International Conf. on Web Intelligence*, 516-519, Halifax, Canada, 2003.
- [106] Maaoui, C., Rosenberger, C., Emile, B., Robust Color Object Detection and Recognition, *13th European Signal Processing Conference*, 2005.

- [107] Efe, M.Ö., Kaynak, O., Yapay Sinir Ağları ve Uygulamaları, *Boğaziçi Üniversitesi*, Bebek, İstanbul, 2004.
- [108] Haykin, S., Neural Networks: A Comprehensive Foundation, *Pearson, Prentice Hall*, Upper Saddle River, New Jersey, 1999.
- [109] Jamarani, S.M.H., Moradi, M.H., Behnam, H., Rezai Rad, G.A., Intelligent System for Breast Cancer Prognosis using Multiwavelet Packets and Neural Network, *Proceedings of World Academy of Science, Engineering and Technology*, 7, 451-456, 2005.
- [110] Efe, M.Ö., Artificial Neural Networks, *Lecture Notes, TOBB University of Economics and Technology*, Department of Electrical and Electronics Engineering, Ankara.
- [111] “COMETS Project Perception Tools” <http://www.comets-uavs.org/results/perception.shtml>, erişim tarihi:18 Şubat 2010.
- [112] Kim, H. Y. and de Araújo S. A., Grayscale Template-Matching Invariant to Rotation, Scale, Translation, Brightness and Contrast, *Lecture Notes in Computer Science Advances in Image and Video Technology*, 4872, 100-113, Aralık 2007.

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : İmamoğlu, Nevrez  
Uyruğu : T.C.  
Doğum tarihi ve yeri : 12.04.1981 Ankara  
Medeni hali : Bekâr  
Telefon : 0 (505) 702 38 73  
Faks : 0 (312) 292 41 80  
e-mail : nimamoglu@etu.edu.tr

### Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Çankaya Üniversitesi Elektronik ve Haberleşme Mühendisliği (Çift Anadal)	2007
Lisans	Çankaya Üniversitesi Bilgisayar Mühendisliği	2007

### İş Deneyimi

Yıl	Yer	Görev
2009-2010	TOBB ETÜ İnsansız Hava Araçları Lab.	Proje Öğrencisi
2009	Simsoft Bilgisayar Teknolojileri Ltd.Şti	Yazılım Mühendisi
2007-2009	TOBB ETÜ İnsansız Hava Araçları Lab.	Proje Öğrencisi
2007-2008	TOBB ETÜ Elektrik Elektronik Müh.	Asistan Öğrenci
2007	ARF Bilgi Teknolojileri	Yazılım Geliştirici
2005 - 2006	TRT İktisatçı TV Programı	Teknik ve Yazılım
2001 - 2002	Koç Üniversitesi Polimer Kimya Lab.	Lab. Asistanı
2000 - 2001	Koc University Yüzey Kimya Lab.	Lab. Asistanı

### Yabancı Dil

İngilizce (iyi)  
Almanca (başlangıç)  
Japonca (başlangıç)



## **Yayınlar**

İmamoğlu, N., Eresen, A., Efe, M.Ö., Adaptive Fuzzy Weighted Template Matching Using Invariant Features for a Tracking Application, ALCOSP 2010 (Mart 2010’da sunuldu, değerlendirme aşamasında).

İmamoğlu, N., Eresen, A., Efe, M.Ö., Gradient-Based Gabor Wavelet Represented Double-Window Template Matching Using Texture Descriptor in a Real-Time Tracking Application, Journal of Digital Signal Processing (Elsevier) (Ocak 2010’da sunuldu, değerlendirme aşamasında).

İmamoğlu, N., Eresen, A., Efe, M.Ö., “Döner Ters Sarkaç Sisteminin Pekiştirmeli Öğrenme Algoritmaları ile Kontrolü”, Otomatik Kontrol Ulusal Toplantısı (TOK’09), Yıldız Teknik Üniversitesi, İstanbul, Türkiye, Ekim 2009.

Efe, M.Ö., Önkol, M., İmamoğlu, N., Eresen, A., Kaynak, Ü., Dönerkanat Tipinde Bir İnsansız Hava Aracının Anatomisi, Otomatik Kontrol Ulusal Toplantısı (TOK’09), Yıldız Teknik Üniversitesi, İstanbul, Türkiye, Ekim 2009.

İmamoğlu, N., Eresen, A., Özbayoğlu, A.M., Performance Analysis of Moments in Invariant Object Classification, 19th Annual Int. Conf. on Artificial Neural Networks in Engineering (ANNIE 2009), Missouri University of Science and Technology, St. Louis, USA, 2009.

Eresen, A., İmamoğlu, N., Efe, M.Ö., “Motion Detection and Tracking of Classified Objects with Intelligent Systems,” The 2nd IFAC Int. Conf. on Intelligent Control Systems and Signal Processing (ICONS’09), İstanbul, Türkiye, Ekim 2009.

İmamoğlu, N., Eresen, A., Efe, M.Ö., Wavelet based Segmentation of an Object and Classification with Intelligent Systems, International Symposium on Innovations in Intelligent Systems and Applications (INISTA 2009), Trabzon, Türkiye, 29 Haziran-1 Temmuz 2009.

Eresen, A., İmamoğlu, N., Efe, M.Ö., “Bir Sarkaç Sisteminde Video Geri Beslemesi ile Gerçek Zamanlı Denetim,” Otomatik Kontrol Ulusal Toplantısı (TOK’08), İstanbul Teknik Üniversitesi, İstanbul, Türkiye, Kasım 2008.