

KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK ANABİLİM DALI
YÜKSEK LİSANS TEZİ

ORTALAMA KAYMA ALGORİTMASININ GELİŞTİRİLEREK GÖRÜNTÜ
DİZİLERİNDE HAREKETLİ NESNE TAKİBİ VE GÖRÜNTÜ KESİMLEME
AMAÇLI KULLANILMASI

MUSTAFA ÖZDEN

ŞUBAT 2005

Fen Bilimleri Enstitü Müdürünün onayı.



Prof. Dr. Yakup ARICA
Müdür

Bu tezin Yüksek Lisans tezi olarak Elektrik Elektronik Anabilim Dalı standartlarına uygun olduğunu onaylarım.


Prof. Dr. Bilal TOKLU

Anabilim Dalı Başkanı

Bu tezi okuduğumuzu ve Yüksek Lisans tezi olarak bütün gerekliliklerini yerine getirdiğini onaylarız.


Yrd. Doç. Dr. Ediz POLAT

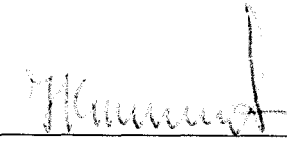


Danışman

Jüri Üyeleri

Prof. Dr. İlhan KOCAARSLAN

Doç. Dr. Şerafettin EREL

Yrd. Doç. Dr. Ediz POLAT

ÖZET

ORTALAMA KAYMA ALGORİTMASININ GELİŞTİRİLEREK GÖRÜNTÜ DİZİLERİNDE HAREKETLİ NESNE TAKİBİ VE GÖRÜNTÜ KESİMLEME AMAÇLI KULLANILMASI

ÖZDEN, Mustafa

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Anabilim Dalı, Yüksek Lisans Tezi

Danışman : Yrd. Doç. Dr. Ediz Polat

Şubat 2005, 103 sayfa

Bilgisayarların oldukça geliştiği günümüzde görüntü işleme ve bilgisayarlı görü uygulamaları da hızla gelişerek fabrika otomasyonu, tıbbi ve askeri uygulamalar, akıllı arabirimler ve güvenlik sistemleri gibi bir çok alanda yerini almıştır. Bu tezde, bilgisayarlı görüdeki önemli alanlardan olan görüntü kesimleme ve nesne takibi amaçlı kullanılan ortalama kayma yönteminin geliştirilmesi amaçlanmıştır.

Bu tezde sunulan görüntü kesimleme yöntemi düşük seviyeden bilgiler olan renk ve doku niteliklerine dayanmaktadır. Renkli görüntü kesimlemede ortalama kayma ile filtreleme yöntemi genelde iyi sonuçlar vermesine rağmen bu yöntemin kullandığı renk ve uzaysal bilgiler bazı durumlarda yeterli olmamaktadır. Sunulan yöntemde görüntüdeki dokuların uzaysal hareketten bağımsız olarak analizini

sağlayan dalgacık çerçeveleri kullanılmıştır. Ortalama kayma ile kesimlemede klasik renk ve konum uzayına ilave bir nitelik olarak doku karakteristiği de eklenerek daha üst seviyeli bir uzayda daha güvenilir bir kesimleme yöntemi geliştirilmiştir. Çeşitli görüntüler üzerinde uygulanan yöntem başarılı sonuçlar vermiştir.

Bu tezde sunulan nesne takibi çalışması da, nesnenin istatistiksel renk dağılımını kullanan parametrik olmayan bir yöntem olan ortalama kayma algoritmasına dayalıdır. Nesne ve arka plan renklerinin oldukça benzer olduğu ortamlarda nesnelere takip etmek değinilmesi gereken bir problemdir. Nesne ve arka plan renk dağılımlarının oldukça yakın olduğu bazı durumlarda yalnızca renk dağılımı bilgisini kullanmak nesneyi güvenilir bir şekilde takip etmek için yeterli olmaz. Bu problemi gidermek için sunulan çalışmada kernel yoğunluk tahmini yöntemi ile elde edilen hareket bilgisi kullanılarak nesne ve arka plan modellenmiştir. Renk dağılımına ilave olarak hareket dağılım bilgisi de, daha güvenilir bir nesne takibi çalışması gerçekleştirmek için klasik ortalama kayma algoritmasına eklenmiştir. Çalışmanın performansı ve sayısal sonuçları yapay ve gerçek görüntü dizileri üzerinde yapılan testlerle sunulmuş ve karşılaştırma yapılmıştır.

ANAHTAR KELİMELER : Ortalama Kayma Algoritması, Görüntü Kesimleme, Nesne Takibi.

ABSTRACT

IMPROVING MEAN-SHIFT ALGORITHM FOR OBJECT TRACKING AND IMAGE SEGMENTATION

ÖZDEN, Mustafa

Kırıkkale University

Graduate School Of Natural and Applied Sciences

Department of Electrical and Electronics Eng., M.Sc. Thesis

Supervisor: Asst. Prof. Dr. Ediz Polat

February 2005, 103 pages

Due to the advances in computer technology, image processing and computer vision applications have developed rapidly and found applications in many areas including factory automation, medical and military applications, intelligent interfaces and surveillance systems. The goal of the thesis is to improve the mean shift algorithm which can be used for image segmentation and object tracking in image sequences.

This thesis describes a new color image segmentation method based on low-level features including color and texture. The mean-shift algorithm with color and spatial information in color image segmentation is in general successful, however, in some cases, the color and spatial information are not sufficient for superior segmentation. Recently, the discrete wavelet transform (DWT) has become a popular

approach for texture characterization. The proposed method uses wavelet frames that provide translation invariant texture analysis. The method also integrates an additional texture feature to the traditional mean shift segmentation algorithm with color and spatial space. Experimental results show that the algorithm gives satisfactory results.

This thesis also presents an object tracking framework based on the mean-shift algorithm, which is a nonparametric technique that uses statistical color distribution of objects. Tracking objects through highly similar-colored background is one of the problems that need to be addressed. In various cases where object and background color distributions are very similar, the color distribution alone is not sufficient to track objects reliably. To deal with this problem, the proposed algorithm utilizes a statistical background and foreground modeling to detect the motion using kernel density estimation techniques. In addition to color distribution, this statistical motion representation is integrated into a modified mean-shift algorithm to create more robust object tracking framework. The superior performance with quantitative results of the framework has been validated using experiments on synthetic and real sequence of images.

KEYWORDS: Mean Shift Algorithm, Image Segmentation, Object Tracking.

TEŐEKKÜR

Bana bu konuyu öneren ve tez alıŐması sırasında bilgisini ve imkanlarını paylaşmaktan ekinmeyen danıŐmanım Yrd. Do. Dr. Ediz POLAT'a teŐekkürlerimi sunarım. Tez savunması sırasında faydalı gürüŐlerini belirten jüri üyeleri Prof. Dr. İlhan KOCAARSLAN, Do. Dr. Őerafettin EREL, Yrd Do. Dr. Eyüp TUNA ve Yrd. Do. Dr. Ata SEVİN'e teŐekkürlerimi sunarım. Tezde kullanılan gürüntülerin ekiminde yardımı gürdüėüm arkadaŐım ArŐ Gör. Serkan ATEŐ'e ve her zaman desteklerini gürdüėüm bütün mesai arkadaŐlarıma da teŐekkür ederim.

Tüm öğrenim hayatım boyunca maddi ve manevi desteklerini esirgemeyen annem Zülfiye ÖZDEN ve ağabeyim Bülent ÖZDEN'e Őükranlarımı sunarım.

İÇİNDEKİLER

| | |
|--|-----|
| ÖZET | i |
| ABSTRACT | iii |
| TEŞEKKÜR | v |
| İÇİNDEKİLER | vi |
| ÇİZELGELER DİZİNİ | ix |
| ŞEKİLLER DİZİNİ | x |
| | |
| 1. GİRİŞ | 1 |
| 1.1. Görüntü Kesimleme | 3 |
| 1.1.1. Literatürdeki Kesimleme Yöntemleri | 5 |
| 1.1.1.1.Eşikleme | 6 |
| 1.1.1.2.Kenar Kesimleme | 6 |
| 1.1.1.2.1.Hough Dönüşümü | 7 |
| 1.1.1.3.Bölgeye Dayalı Kesimleme | 8 |
| 1.1.1.4.Eşleştirme | 8 |
| 1.1.1.5.Dokuya Dayalı Kesimleme | 9 |
| 1.1.1.5.1. İstatistiksel Doku Analizi Yöntemleri | 11 |
| 1.1.1.5.2. Dizimsel Doku Tanımlama Yöntemleri | 15 |
| 1.1.1.6.Doku Analizi Uygulamaları | 16 |
| 1.2. Nesne Takibi | 17 |
| 1.2.1. Literatürdeki Nesne Takibi Yöntemleri | 19 |
| 1.2.1.1.Tekli ve Çoklu Nesne Takibi | 19 |

| | |
|---|----|
| 1.2.1.2.Nitelik ve Modele Dayalı Nesne Takibi | 20 |
| 1.2.1.3.Niteliğe Dayalı Takip | 21 |
| 1.2.1.4.Modele Dayalı Takip | 21 |
| 1.2.1.5.İnsan Hareketlerinin Analizi Açısından Nesne Takibi | 22 |
| 1.3. Çalışmanın Amacı | 24 |
| 2. MATERYAL VE YÖNTEM | 26 |
| 2.1. Ortalama Kayma Yöntemi ile Renkli Görüntü Kesimleme | 26 |
| 2.1.1. Giriş | 26 |
| 2.1.2. Ortalama Kayma Prosedürü | 29 |
| 2.1.3. Ortalama Kayma ile Görüntü Kesimleme | 32 |
| 2.2. Dalgacık Dönüşümü | 37 |
| 2.2.1. Sürekli Dalgacık Dönüşümü | 38 |
| 2.2.2. Kesikli Dalgacıklar | 39 |
| 2.2.2.1.Ölçekleme Fonksiyonu | 41 |
| 2.2.3. Alt Bant Kodlama | 42 |
| 2.2.4. Kesikli Dalgacık Dönüşümü | 43 |
| 2.2.5. İki Boyutlu Kesikli Dalgacık Dönüşümü ile Görüntü İşleme | 43 |
| 2.3. K-means ile Öbekleme | 46 |
| 2.4. Kesikli Uzayda Olasılık | 48 |
| 2.4.1. Olasılık Fonksiyonu P | 49 |
| 2.4.2. Şartlı Olasılık | 49 |
| 2.4.3. Histogram | 50 |
| 2.5. Kernel Yoğunluk Tahminini | 51 |
| 2.6. Ortalama Kayma Yöntemi ile Nesne Takibi | 52 |

| | |
|---|----|
| 3. ARAŞTIRMA BULGULARI | 55 |
| 3.1. Geliştirilen Renkli Görüntü Kesimleme Yöntemi | 55 |
| 3.1.1. Giriş | 56 |
| 3.1.2. Doku Niteliğinin Çıkarımı | 57 |
| 3.1.3. Nitelik Uzayının Ortalama Kayma Yöntemi ile Analizi | 62 |
| 3.2. Geliştirilen Nesne Takibi Yöntemi | 65 |
| 3.2.1. Giriş | 66 |
| 3.2.2. Başlangıç ve İstatistiksel Model Geliştirme | 66 |
| 3.2.3. Örnek Ağırlık Görüntüsünün Oluşturulması | 67 |
| 3.2.4. Birleştirilmiş Ağırlık Görüntüsü ve Ortalama Kayma Yöntemi ile Nesne Takibi | 69 |
| 4. TARTIŞMA VE SONUÇ | 70 |
| 4.1. Geliştirilen Kesimleme Yöntemi | 70 |
| 4.1.1. Tartışma | 70 |
| 4.1.2. Sonuç | 71 |
| 4.2. Geliştirilen Nesne Takipçisi | 81 |
| 4.2.1. Tartışma | 81 |
| 4.2.2. Sonuç | 92 |
| KAYNAKLAR | 93 |

ÇİZELGELER DİZİNİ

ÇİZELGE

- 4.1. Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının yapay görüntü dizisi için sayısal analizi85
- 4.2. Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının gerçek görüntü dizisi için sayısal analizi 88
- 4.3. Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının el takibi görüntüsü için sayısal analizi 91



ŞEKİLLER DİZİNİ

ŞEKİL

| | |
|---|----|
| 1.1. Kesimleme işlemi (a) Orijinal resim (b) Kesimlenmiş resim | 4 |
| 1.2. Kısmi kesimleme (a) Orjinal resim (b) Renk kesimleme (c)Hareket kesimleme | 5 |
| 1.3. Brodatz albümünden çeşitli doku örnekleri | 9 |
| 1.4. Nesne temsili noktasal, kenar tabanlı ya da model tabanlı olarak temsil edilebilirler. Her temsilin de uygulamanın çeşidine göre avantaj ve dezavantajı vardır | 18 |
| 2.1. Nitelik uzayına bir örnek (a) 400x276 boyutlarında renkli bir resim (b) 110400 veri noktası olarak $L*u*v*$ renk uzayında gösterimi | 28 |
| 2.2. Kameraman resmi (a) Orijinal resim (b) $h_s=8$, $h_r=4$ için ortalama kayma yöntemi ile filtreleme sonucu | 35 |
| 2.3. Göl resmi (a) Orijinal resim (b) $h_s=16$, $h_r=7$ ve $M=40$ için ortalama kayma yöntemi ile kesimleme sonucu | 37 |
| 2.4. Sonsuz sayıdaki dalgacıklar kümesi bir ölçekleme fonksiyonu ile değiştirilebilir | 42 |
| 2.5. Filtre bankası kullanarak sinyal spektrumunun parçalanması | 42 |
| 2.6. İndirgenmiş dönüşüm | 44 |
| 2.7. Piramit biçiminde ayrıştırma, $j=2$ | 45 |
| 2.8. Ağaç yapısında görüntü ayrıştırma (a) orijinal resim (b) Seçilen ağaç yapısı (c)Ayrıştırma sonucu | 45 |
| 3.1. Sunulan kesimleme yöntemi | 56 |
| 3.2. (a) Orijinal görüntü (b) Yatay dokuya sahip bölgeler siyah yumuşak dokulu yerler beyaz renklidir (c) Düşey dokuya sahip bölgeler beyaz yumuşak dokuya sahip bölgeler ise siyah renktedir (d) Elde edilen 4 doku sınıfı farklı gri tonlarla gösterilmiştir | 63 |
| 3.3. Geliştirilen Nesne Takibi Algoritması | 66 |

- 4.1. (a) Orijinal resim (b) $hs=8, hr=20$ için ortalama kayma ile filtreleme (c) öbek sayısı= 5 için kesimleme sonucu (d) Ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 8×8) (e) öbek sayısı= 5 için kesimleme sonucu72
- 4.2. (a) Orijinal resim (b) $hs=8, hr=20$ için ortalama kayma ile filtreleme (c) Öbek sayısı= 5 için kesimleme sonucu (d) Ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 8×8) (e) öbek sayısı= 5 için kesimleme sonucu73
- 4.3. (a) Orijinal resim (b) $hs=6, hr=20$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 10×10) (c) Öbek sayısı = 6 için kesimleme sonucu74
- 4.4. (a) Orijinal resim (b) $hs=8, hr=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 10×10) (c) Öbek sayısı = 6 için kesimleme sonucu75
- 4.5. (a) Orijinal resim (b) $hs=8, hr=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 21×21) (c) Öbek sayısı = 5 için kesimleme sonucu76
- 4.6. (a) Orijinal resim (b) $hs=8, hr=16$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 20×20) (c) Öbek sayısı = 5 için kesimleme sonucu77
- 4.7. (a) Orijinal resim (b) $hs=6, hr=10$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 7×7) (c) Öbek sayısı = 4 için kesimleme sonucu78
- 4.8. (a) Orijinal resim (b) $hs=8, hr=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 55×55) (c) Öbek sayısı = 3 için kesimleme sonucu79
- 4.9. (a) Orijinal resim (b) $hs=8, hr=16$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 20×20) (c) Öbek sayısı = 5 için kesimleme sonucu80

- 4.10. $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen araç Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir 82
- 4.11. $\alpha=0.5$ ve $\beta=0.5$ için sunulan yöntemle ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen araç Alt satır: Her görüntü karesi için ağırlık görüntüleri. (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir 83
- 4.12. Yapay video görüntüsü için iki yöntemle ait X ve Y yönündeki hataların karşılaştırılması 85
- 4.13. $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen fincan (Dikkat edilirse 20. kareden itibaren takip edilememiştir) Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir 86
- 4.14. $\alpha=0.5$ ve $\beta=0.5$ için sunulan yöntemle ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen fincan, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir 87
- 4.15. Fincan görüntüsü için iki yöntemle ait X ve Y yönündeki hataların karşılaştırılması 88
- 4.16. $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi),(Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir 89

| | |
|---|----|
| 4.17. $\alpha=0.5$ ve $\beta=0.5$ için sunulan yönteme ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir | 90 |
| 4.18. HCI uygulaması için iki yönteme ait X ve Y yönündeki hataların karşılaştırılması | 91 |



1. GİRİŞ

Sayısal bir resim (görüntü), nesnelere tarafından yansıtılan ışık enerjisinin (analog sinyal) bir algılayıcı tarafından öngörülen elektromanyetik aralıkta algılanarak sayısal sinyal haline dönüştürülmesi ile oluşur. Bir görüntünün temel bileşeni pikseldir. Sayısal bir görüntü $m \times n$ boyutlu piksellerden oluşan bir matris ile ifade edilir. Gri tonlu görüntülerde, görüntü farklı gri ton değerlerinden oluşur. Gri değer aralıkları $\{0,1,2,\dots,255\}$ şeklinde ifade edilir. Bunun anlamı, bir gri tonlu görüntüde 256 tane farklı gri ton değeri daha doğrusu gri değeri bulunabilir. Sıfır gri değeri kural olarak siyah renge, 255 gri değeri ise beyaza karşılık gelir. Bu değerler arasında ise gri tonlar oluşur. Elektromanyetik spektrumda $0,4-0,5 \mu\text{m}$ dalga boyu mavi renge; $0,5-0,6 \mu\text{m}$ dalga boyu yeşil renge; $0,6-0,7 \mu\text{m}$ dalga boyu kırmızı renge karşılık gelir. Bu dalga boylarında elde edilmiş üç gri düzeyli görüntü bilgisayar ekranında sırası ile kırmızı-yeşil-mavi (RGB) kombinasyonunda üst üste düşürülecek olursa renkli görüntü elde edilmiş olur.

Video kamera ve tarayıcı gibi görüntü yakalayıcı cihazlarla alınarak sayısallaştırılan görüntülerin geliştirilen yöntemlerle işlenip analiz edilerek görüntülerden bilgi elde edilmesi ve bu bilgilerin yorumlanması, görüntü işleme ile bilgisayarlı görü alanlarının temel amaçlarından biridir. Görüntü işleme uygulamalarına örnek olarak fabrika otomasyon uygulamalarından endüstriyel kalite/üretim kontrolleri, tıbbi uygulamalardan kan hücrelerinin sayımı, bilgi işlem uygulamalarından karakter tanıma, güvenlik amaçlı uygulamalardan yüz tanıma, askeri uygulamalardan akıllı silahlar üretimi gibi örnekler verilebilir. Dolayısıyla

gelişen teknoloji ile önceden çok pahalıya mal edilen sistemlerin yaptığı işler görüntü işleme sistemleri ile daha hızlı, ekonomik ve hassas bir şekilde yerine getirilebilir.

Bilgisayarlı görü uygulamalarının amacı aktif dünyayı algılama ve yorumlama yeteneğine sahip sistemleri görmeye dayalı olarak geliştirmektir. Bu sistemlerde kamera ile görüntü dış ortamdan alınır, görüntü işleme teknikleri ile işlenir, yorumlanır ve yapılması gereken işleme karar verilir. Bu tip uygulamalara örnek olarak, askeri uygulamalar, güvenlik uygulamaları, akıllı otomasyon sistemlerinin geliştirilmesi, etkileşimli multimedya sistemleri verilebilir. Örneğin bilgisayarlı görü ile yapılan bir güvenlik sistemi zamandan ve yerden tasarruf sağlar.

Bu tezde, bilgisayarlı görü alanındaki temel branşlardan olan kesimleme (segmentasyon) ve nesne takibinde karşılaşılan problemlerin çözümüne yönelik yöntemlerin geliştirilmesi amaçlanmıştır. Kesimleme, görüntüyü aralarında benzerlik gösteren belirli bölgelere ayırma işlemi olup, bir çok bilgisayarlı görü ve görüntü işleme uygulamalarının temelini oluşturur. Bu tezin temelini oluşturan Ortalama kayma kesimleme yöntemi parametrik olmayan ve gerçek zamanlı uygulamalara olanak veren hızlı bir kesimleme yöntemidir. Bu yöntem görüntülerdeki piksellerin renk ve koordinat bilgilerini nitelik olarak kullanır. Ancak bu bilgiler bazı durumlarda güvenilir bir kesimleme yapmak için yeterli olmayabilir. Sunulan çalışmada görüntülerden elde edilen doku (texture) bilgisi de ortalama kayma yönteminin nitelik uzayına eklenerek daha üst seviyeli bir uzayda daha güvenilir bir kesimleme yöntemi geliştirilmiştir.

Nesne takibi de bilgisayarlı görü uygulamalarındaki önemli konulardan biridir ve çoğu uygulamada gereklidir. Nesne takibi, video görüntülerinde, ilgilenilen nesnenin veya kişilerin görüntü düzlemindeki konum bilgisini bulmayı ve bu


bilgilerin zamana göre deęişiminin takip edilmesini amaçlar. Ortalama kayma algoritması ile gerçekleştirilmiş nesne takibi yöntemi de gerçek zamanlı çalışabilen, olasılığa dayalı hızlı bir takip yöntemidir. Yöntem, takip edilecek nesnenin ve nesnenin bulunduğu ortamın renklerinin birbirine yakın olduğu durumlarda güvenilir sonuçlar vermemektedir. Bu tezde sunulan nesne takibi yönteminde, standart ortalama kayma takip yönteminde kullanılan renk dağılım fonksiyonuna ek olarak, kernel yoğunluk tahmini yöntemi ile elde edilen hareket dağılım fonksiyonu da kullanılmış ve daha iyi sonuç veren bir yöntem geliştirilmiştir.

Tezdeki bölümler şu şekilde düzenlenmiştir. 1. kısımda temel kesimleme tekniklerine ve nesne takibi yöntemlerine ait tanımlamalar ve daha önce yapılmış çalışmalar özet olarak verilmiştir. 2. kısımda tezde geliştirilen yöntemde kullanılan, ortalama kayma algoritması ile görüntü kesimleme, dalgacık dönüşümü ve k-means öbekleme yöntemi ile ilgili temel bilgiler, kernel yoğunluk tahmini ve ortalama kayma ile nesne takibi algoritmaları orijinal şekilleriyle, ayrıntılarıyla anlatılmıştır. 3. kısımda geliştirilen kesimleme yöntemi ve nesne takibi yöntemi detaylarıyla açıklanmıştır. 4. kısımda ise her iki yöntemle ait sonuçlar verilmiş ve daha önceki yöntemlerle kıyaslamaları yapılmıştır.

1.1. Görüntü Kesimleme


Görüntü kesimleme işlemi, görüntüyü aralarında benzerlik gösteren belirli bölgelere ayırmak için kullanılan, işlenmiş görüntü verilerinin analizi için gerekli olan en önemli adımlardan biridir⁽¹⁾. Askeri, medikal ve multimedya uygulamalarından veri depolamaya kadar çeşitlilik gösteren, gerçek zamanlı bilgisayarlı görme uygulamalarında da ilgilenilen nesnelerin tanınması için görüntü

kesimleme alt seviyeden bir işlem olarak şarttır. Çünkü bu tip uygulamalarda ön işlemde görüntünün içerdiği binlerce detayla ilgilenilmez. Önemli olan resimdeki alanlardır. Daha sonraki adımlarda ise (üst seviyeden işlemlerde) ilgilenilen alanın detaylarına inilerek işleme devam edilir.



Şekil 1.1 Kesimleme işlemi (a) Orijinal resim (b) Kesimlenmiş resim

Uygulamaya bağlı olarak tam kesimleme ya da kısmi kesimleme gerekebilir. Tam kesimlemede, kesimlenecek nesnenin rengi ile zemin rengi arasında belirli bir karşıtlık olup renkler fazla çeşitli değildir ve basit kesimleme yöntemleriyle nesne zeminden kolaylıkla ayrılabilir. Şekil 1.1’de kesimleme işlemine bir örnek görülmektedir. Bu tip uygulamalara örnek olarak kan hücrelerinin sayımı, yazı karakterlerinin tanınması ve bazı robotik montaj uygulamaları verilebilir. Kısmi kesimlemede ise görüntü seçilen parametreye, örneğin parlaklık, renk, yansıma, şekil, doku, hareket gibi, göre homojen olan bölgelere ayrılır. Şekil 1.2’de kısmi kesimlemeye örnek verilmiştir. Eğer karmaşık bir manzara içeren görüntü işleniyorsa, örneğin bir şehrin havadan çekilen fotoğrafı gibi, bir grup üst üste binmiş homojen alanların ortaya çıkacağı görülmektedir. Bu yüzden kısmi kesimlenmiş görüntü sonraki aşamadaki işlemlere bağımlıdır ve nihai görüntü kesimleme üst seviyeden bilgilerin de kullanılmasıyla elde edilir.



Şekil 1.2 Kısmi kesimleme (a) Orijinal resim (b) Renk kesimleme (c)Hareket kesimleme

Veri hacminin yeterince azaltılması ihtiyacı, giderek önem kazanmasına rağmen karmaşık manzaraların tamamen doğru ve tam kesimlemesi genellikle elde edilememiştir⁽¹⁾. Bu sebeple kısmi kesimleme yüksek seviyedeki işlemler için bir giriş olarak kullanılmaktadır.

1.1.1. Literatürdeki Kesimleme Yöntemleri

Görüntü verilerinin belirsiz olması sıkça bilgi kaybıyla beraber gelen temel kesimleme problemlerinden biridir. Uygulamada kullanılan temel niteliklerine göre kesimleme yöntemleri üç ana grupta incelenebilir. Birinci gruptakiler, görüntü veya görüntü parçası hakkında global bilgi edinmeye dayanan yöntemlerdir. Bu yöntemlerde bilgi edinme genellikle görüntü niteliklerinin histogramını hesaplama şeklindedir. Kenar bulmaya dayalı kesimleme yöntemi ikinci gruba girer ve bölge bulmaya dayalı kesimleme üçüncü grupta yer alır. Kenar kesimleme ya da bölge büyütme dayalı kesimlemede görüntüye ait birçok farklı karakteristikteki nitelikler kullanılabilir. Örneğin parlaklık, doku, harekete sahip alanlar bu niteliklerdendir. İkinci ve üçüncü gruptaki yöntemler ortak bir problemi çözerler. Her bölge kendisini çevreleyen sınırlar ile belirlenebilir ve her kapalı sınır bir bölgeyi belirler. Bu iki

yaklaşım bir arada kullanılarak çeşitli kesimleme yöntemleri de, örneğin bölge yakınlık grafiği yöntemi gibi, geliştirilmiştir.

1.1.1.1. Eşikleme

Eşikleme yöntemi bilinen en basit kesimleme yöntemidir. Gri tonlu veya tek kanallı görüntülerde genellikle nesne ve artalan renkleri arasındaki belirli bir kontrast farkından belirlenen bir eşik değerine göre kesimleme yapılır. Eşik değerinin doğru seçilmesi bu yöntemde çok önemlidir ve bu konuda bir çok çalışma yapılmıştır⁽¹⁻⁶⁾.

Çok kanallı görüntülerde ise, örneğin renkli resimler üç uzaysal kanallı iken meteorolojik uydulardan alınan görüntüler ise daha çok uzaysal kanala sahiptirler, her kanal birbirinden bağımsız şekilde eşikleme işlemine tabi tutulur ve sonra bu eşiklenmiş kanallar birleştirilerek kesimlenmiş görüntü elde edilir⁽⁷⁻⁹⁾. Düşük işlem süresi ile görüntülere gerçek zamanlı olarak uygulanabilirliğinden dolayı eşikleme, görüntü kesimlemede popüler bir araç olma özelliğini hala sürdürmektedir ve gerçek zamanlı eşik belirleme yöntemleri halen araştırmaya açık bir çalışmadır^(10,11).

1.1.1.2. Kenar Kesimleme

Kenar belirlemeye dayalı görüntü kesimleme yöntemi de ilk kesimleme yöntemlerinden olup, çeşitli kenar belirleme operatörleri ile görüntüdeki farklı bölgelerin sınırlarını bulma esasına dayanan ve halen de önemini koruyan bir yöntemdir⁽¹⁾. Görüntüdeki sınırlar farklı nitelikteki bölgeler arasındaki geçişlerden, örneğin renk ve doku, ya da görüntüdeki süreksizliklerden kaynaklanır. Sınırların belirlenmesinde belirli bir eşik değerinin kullanılması da mümkündür^(1,12). En çok

kullanılan kenar filtreleme operatörleri Sobel, Prewitt ve Canny'dir. Sobel ve Prewitt operatörleri temelde görüntünün basit bir filtreden geçirilmesine dayanırken Canny⁽¹³⁾ prosedürel hesaplamalar gerektiren bir yöntemdir. Kenar kesimleme yönteminde kullanılan diğer yaklaşımlar kenar gevşetme⁽¹⁴⁻¹⁷⁾ ve sınır kopyalamadır⁽¹⁸⁻²¹⁾.

1.1.1.2.1. Hough Dönüşümü

Eğer bir görüntü, şekilleri ve boyutları bilinen nesnelere içeriyorsa kesimleme bu nesnelere bulunması işlemine döner. Tipik uygulamalar baskı devre kartlarındaki yuvarlak deliklerin bulunması ya da uydudan alınan görüntüler içerisinde belirli bir nesnenin aranması olabilir. Arama işlemi uygun maskenin seçilerek görüntünün taranması sırasında bulunan ilişki katsayısına bakılarak yapılabilir. Ne yazık ki görüntüdeki şekil bozuklukları, dönüş açısı değişiklikleri nedeniyle maske yoluyla arama çok iyi sonuç vermez. Bu problemi çözmek için gürültülü görüntülerde bile başarılı sonuç veren Hough dönüşümü uygulanmaktadır.

Hough dönüşümü ilk kez görüntüdeki belirli bir matematiksel fonksiyona sahip düz çizgileri tespit etmek için geliştirilmiştir ve kullanıcının parametre girmesini gerektirir⁽²²⁾. Geliştirilmiş Hough dönüşümleriyle ise parametrelerin de görüntüye göre otomatik olarak seçilmesi ve matematiksel fonksiyona sahip olmayan şekillerin de tespit edilmesi verimli bir şekilde sağlanmıştır⁽²³⁾.

1.1.1.3. Bölgeye Dayalı Kesimleme


Önceki kısımlarda değinilen kesimleme yöntemleri farklı bölgeler arasındaki sınırları belirlemeye dayanıyordu. Bu yöntemde ise amaç doğrudan bu bölgeleri belirlemektir. Bu tip yöntemler ise; bölge birleştirme, bölge ayırma, ayırma ve birleştirme ve Watershed kesimleme yöntemleridir. Kenar bulma ve bölge genişletme yöntemleri aynı sonuçları vermez ve bu iki yöntemi birleştirmek genellikle daha iyi sonuç verir. Homojenlik bölgeleri tanımlamada en önemli bilgidir ve bölge genişletme yöntemindeki ana kesimleme kriteridir. Bölge genişletme yönteminde ana fikir görüntüyü maksimum homojenliğe sahip alanlarına ayırmaktır. Alanların homojenliği için gerekli kriterler gri tonlar, renk, doku, ve şekle dayalı modeller olabilir⁽²⁴⁻³²⁾.

1.1.1.4. Eşleştirme

Eşleştirme de görüntü içerisinde aranılan nesnenin bilinmesi halinde kullanılabilir olan temel kesimleme yöntemlerinden biridir. Bu yöntemde, en basit anlamda, bir görüntüdeki nesneyi ya da örüntüyü bulmak için görüntü, her yönde ve açıda, baştan sona taranarak aynı örüntüye sahip (eşleştirme sonucu pozitif) bölgeler belirlenir. Eşleştirilecek olan örüntü çok küçük yada nesnenin tamamını içeriyor olabilir. Bazı durumlarda eşleştirme görüntü dönüşümlerinden bağımsız olabilir. En iyi eşleştirme nesne özellikleri ve nesne ilişkilerine bağlı olan bazı uygunluk kriterlerine dayanır. Bu uygunluk kriterleri de basit ilişki hesaplamalarından çizge eşleştirme gibi karmaşık yaklaşımlara kadar uzanabilir^(21,33).

1.1.1.5. Dokuya Dayalı Kesimleme

Doku bir yüzeyi ya da nesneyi tanımlayan bir özelliktir ve sezgisel olarak algılanabilir. Fakat dünya üzerindeki doku çeşitliliğinin çok olmasından dolayı kesin bir kalıba konarak tanımı yapılamamaktadır. Doku karşılıklı ilişkili elemanları içeren bir kavram olarak tanımlanabilir. Bu yüzden bir piksel grubunu (doku primitifleri veya doku elemanları) göz önüne almak gerekir ve doku niteliği bu göz önüne alınan grup sayısı ile (doku ölçeği) tanımlanabilir⁽³⁴⁾. Şekil 1.3'te Brodatz⁽³⁵⁾ albümünden bazı doku örnekleri verilmiştir.



Şekil 1.3 Brodatz albümünden çeşitli doku örnekleri

Doku genel olarak texel ismiyle adlandırılan doku primitifleri veya doku elemanlarını içermektedir. Çimen veya köpek tüylerindeki primitifler birkaç piksel kümesi ile temsil edilir ve bunlar bir yığın ya da uzun çizgilere karşılık gelir. Bir mantar tıpa dokusu üzerindeki primitifler şekil ve boyut olarak değişen piksel grupları ile temsil edilir. Dokuyu tanımlamadaki önemli bir problem de dokunun

ölçeğidir. Çünkü doku tanımlaması ölçeğe bağımlı olup belirli bir ölçekte (frekansta) tekrar eden niteliklerle ifade edilir. Bilgisayarlı görü uygulamalarında kullanımına imkan sağlamak için bazı özel niteliklerin de belirlenmesi ihtiyacı da var olmakla birlikte, doku genellikle hassas, kaba, taneli ve pürüzsüz olarak sınıflara ayrılmıştır. Bu nitelikler dokuyu oluşturan tonsal ve yapısal nitelikler olarak belirtilebilir⁽³⁴⁾. Ton primitifteki piksel parlaklık özelliği ile ilgili iken yapı primitiflerdeki konumsal ilişkiye bağlıdır.

Her piksel konum ve ton özellikleri ile karakterize edilebilir. Bir doku primitifi bazı tonsal ve bölgesel özellikleri ile sürekli bir piksel kümesidir ve ortalama parlaklığı, maksimum ya da minimum parlaklığı, boyutu ve şekli ile belirlenebilir. Primitiflerin konumsal bağlantısı gelişigüzel, kısmi bağlantılı olabilir ya da bazı primitifler ortak olarak bağlantılı olabilir. Bu durumda görüntüdeki doku primitiflerin sayısı ve çeşidi ile konumsal ilişkileri de göz önüne alınarak tanımlanabilir. Eğer doku primitifleri küçük ve komşu primitifler arasındaki tonsal farklar büyük ise hassas bir doku (yüksek uzaysal frekanslı) oluşur. Eğer doku primitifleri daha büyük ve birkaç pikselden oluşuyorsa kaba bir doku (düşük uzaysal frekanslı) oluşur. Buradan da anlaşılacağı gibi hassas ve kaba doku karakteristikleri ölçeğe bağımlıdır.

Doku karakteristiklerini karşılaştırmada dokunun zayıf ya da güçlü olması da bir ölçüttür. Zayıf dokuda primitifler arasında küçük uzaysal girişimler vardır ve yeterli olarak primitif çeşidinin bazı komşuluklarda belirme frekansıyla belirlenir. Güçlü dokuda ise primitifler arasındaki uzaysal bağlantılar genellikle düzenlidir ya da düzenli olmaya yakındır ve primitif çiftlerinin frekansıyla tanımlanması yeterlidir.

Güçlü bir doku tanıma işlemi genellikle primitifler arasındaki uzaysal ilişki ve primitiflerin tamamen tanımlanması ile birlikte yerine getirilmiştir^(36,37).

Sabit doku belirli bir bölgedeki özellikleri sabit, az değişimli ya da yaklaşık olarak periyodik olan primitiflerden oluşmuştur⁽³⁸⁾. Sabit doku ile kaplı büyük bir alanı göz önüne alacak olursak bu alanın gittikçe küçülen parçalarındaki doku parçaları sabit bir çözünürlükte dijitize edilirse doku karakteristiği sabit kalır. Dolayısıyla görüntü çözünürlüğü doku tanımlaması için önemli bir özelliktir.

Temel olarak iki çeşit doku analizi yöntemi vardır. İstatistiksel ve dizimsel⁽³⁴⁾. İstatistiksel yöntemler farklı özellikleri hesaplarlar ve doku primitiflerinin boyutlarının piksel tabanlı olarak karşılaştırılabildiği durumlarda çok uygun bir yöntemdir. Dizimsel ve karma yöntemler (istatistiksel ve dizimsel yöntemlerin bir arada kullanıldığı yöntemler) dokunun primitif tiplerine göre etiketlendirilebildiği doku analizlerinde yani dokunun sadece tonal özelliklerine göre değil daha farklı özelliklerine (örneğin şekil gibi) göre tanımlanabildiği uygulamalarda daha kullanışlıdır. Bu konuda yapılan ilk çalışmalarda çoğunlukla textonlardan (çizgiler, dörtgenler, elipsler, çarpı ve artı sembolleri vb. geometrik şekiller) oluşan dokuların insanlar tarafından hızlı bir şekilde algılanabildiği görülmüştür^(39,40). Daha sonraki çalışmalarda ise texton algılama ve texton yoğunluğu hesaplamaya dayalı yöntemler geliştirilmiştir^(41,42).

1.1.1.5.1. İstatistiksel Doku Analizi Yöntemleri

İstatistiksel doku analizi yöntemleri, dokuyu istatistiksel örüntü tanımaya uygun bir şekilde analiz eden yöntemlerdir. Her bir doku kendisini çok boyutlu nitelik uzayındaki bir nokta olarak temsil eden özelliklerin nitelik vektörü ile

tanımlanır. Asıl amaç dokuyu sınıflandırmada kullanılacak olan deterministik ya da olasılığa dayalı kuralı tespit etmektir.

Uzaysal frekans hesaplamasına dayalı doku analizi yöntemleri otokorelasyon fonksiyonu, optik görüntü dönüşümü ve kesikli görüntü dönüşümüdür. Otokorelasyon modelinde tek bir piksel bir doku primitifi olarak ele alınır ve primitifin tonsel özelliği “gri ton” dur. Dokunun uzaysal organizasyonu primitifler arasındaki doğrusal-uzaysal ilişkileri belirten korelasyon katsayıları ile tanımlanır. Alternatif olarak otokorelasyon fonksiyonu görüntü güç spektrumundan frekans domeninde belirlenebilir⁽⁴³⁾. Optik görüntü dönüşümü yönteminde ise Fourier dönüşümü kullanılarak, görüntü uzaysal frekansları ile tanımlanmış, Fourier spektrum halkaları ve ortalama enerji değerleri dokuyu karakterize etmede kullanılmıştır⁽⁴⁴⁾.

Kesikli görüntü dönüşümü yönteminde dokuya sahip görüntü küçük alt bölgelere ayrılarak bu bölgelerdeki piksel kümelerinin Fourier, Hadamart, kesikli cosinüs ve diğer kesikli görüntü dönüşüm yöntemleriyle analizi sonucu doku karakterize edilir^(45,46).

Doku tanımlamasında kullanılan co-occurrence matrisi yöntemi dokudaki bazı gri ton konfigürasyonlarının tekrarlı bir şekilde belirmelerine dayanır⁽⁴⁷⁾. Bu yöntem ikinci mertebeden görüntü istatistiğini ifade eder ve geniş çapta değişiklikler gösteren dokularla da iyi çalışır. Ancak doku primitifinin şeklini ifade edemez ve büyük primitiflerle iyi çalışamaz. Bu yöntem, her ne kadar zor bir hesaplama gerektirse de bu konuda bir çok çalışma yapılmıştır⁽⁴⁸⁾ ve bu çalışmalardan bazıları da yöntemin pratik ve hızlı olarak hesaplanmasının sağlanması yolundadır^(49,50).

Kenar frekansı yönteminde dokudaki kenar frekansına bakılarak doku karakterizasyonu yapılır. Primitif çeşidine göre küçük kenarlar ve büyük kenarlar uygun kenar bulma operatörleri ile bulunur⁽⁵¹⁾. Daha sonra kenarların hassaslık, karşıtlık, gelişigüzelik, yönelme, periyodiklik ve boyut özelliklerine göre doku karakterize edilir⁽⁵²⁻⁵⁶⁾.

Primitif uzunluğunun kodlanması da doku tanımlama için kullanılan yöntemler arasına girmiştir^(57,58). Bu yöntemde de kısa primitifler, uzun primitifler, gri ton düzgünlüğü (tek düzeliği), primitif uzunluğunun düzgünlüğü ve primitif yüzdesini ifade eden formüller geliştirilmiştir.

Laws kendi adıyla anılan doku enerjisi ölçümünü geliştirmiştir⁽⁵⁹⁾. Doku ölçütü, ortalama alma, kenar bulma ve ikinci dereceden kenar bulmaya (spotları belirleme) dayalı üç basit maskeden elde edilen vektörler ve bunların konvolusyonundan elde edilen matris ile belirlenmiştir⁽⁶⁰⁾.

Fractal tabanlı doku analizi, doku kabalığı, fractal boyut ve doku tanecikliliği ile tanecik boşlukları arasındaki ilişkilerin belirlenmesine yönelik olasılığa dayalı bir yaklaşımdır⁽⁶⁰⁻⁶⁵⁾. Bu yöntemde karmaşık hesaplamalar gerektirir ve pratik hesaplamaların bulunmasına ilişkin çalışmalar yapılmıştır⁽⁶⁶⁻⁶⁸⁾.

Matematiksel morfoloji yaklaşımı yapı primitifleri kullanılarak ikili görüntüdeki şekillerin uzaysal tekrarlılığını bulmaya dayanır. Daha büyük ve karmaşık yapı elemanları kullanılarak primitifler arasındaki genel korelasyon değerlendirilebilir. İkili görüntü (siyah beyaz) veya doku bu yapısal elemanlar ile erozyon işlemine tabi tutularak doku niteliği karakterize edilir⁽⁶⁹⁾. Bu yöntem genellikle taneciklerden oluşmuş doku tiplerine uygulanır ve eşikleme uygulanarak doku kesimleme yapılır.

Doku dönüşümü yönteminde^(70,71) görüntüdeki her bir doku tipi farklı bir gri ton ile ifade edilir ve dokuların yönelimi ve büyüklükleri dokudan nitelik çıkarımında ve bu niteliklerin sınıflandırılmasında kullanılmıştır.

Dokuyu oluşturan piksellerdeki gri tonların doğrusal tahmini de dokuyu tanımlamada kullanılmıştır⁽⁷²⁾ ve pikselin sahip olduğu gri ton komşuluğunda bulunduğu piksellerdeki gri tonlardan otoregresyon doku modeliyle tahmin edilir. Otoregresyon modeli ikinci mertebeden uzaysal istatistik yöntemi ile karşılaştırılmış, iki yöntemin sonuçları arasında fark görülmemiş ancak uzaysal istatistik yönteminin daha hızlı ve güvenli olarak uygulanabildiği vurgulanmıştır⁽⁷³⁾.

Tepe ve Vadi yöntemi ise görüntüdeki parlaklık fonksiyonunun yatay ve dikey olarak taranması sonucu yerel sınırlarının bulunmasına dayanan bir yöntemdir^(74,75). Kaba hatlı dokularda sayı olarak daha az olan daha büyük boyutlu sınırlar (daha yüksek tepeler ve daha derin vadiler) ile temsil edilirken hassas dokular daha çok sayıdaki küçük boyutlu sınırlar ile temsil edilir.

Doku üretiminde de kullanılan Markov zinciri⁽⁷⁶⁾ belirli bir mertebeden zincir temsilindeki piksel gri tonlarının geçiş olasılıkları ile ifade edilir ve doku karakterizasyonunda da kullanılmıştır⁽⁷⁷⁾. Yang ve Liu⁽⁷⁸⁾'nin yaptığı çalışmada doku karakterizasyonu için Markov alanları kullanılmış, farklı dokudaki bölgeler arasındaki sınırları belirlemek için ise histograma dayalı ortalama kayma yaklaşımı kullanılmıştır.

Doku tanımlaması ölçeğe (çözünürlüğe) oldukça bağlıdır. Ölçeğe bağlı hassasiyeti azaltmak için doku birden fazla çözünürlüklerle tanımlanabilir ve uygun bir ölçek maksimum doku farklılığını algılamak için seçilebilir⁽⁷⁹⁾. Gabor dönüşümü ve dalgacıklar çok ölçekli doku karakterizasyonunda verimli bir şekilde

uygulanmıştır⁽⁸⁰⁻⁸³⁾. İki yaklaşımda çok ölçekli uzaysal–uzaysal frekans filtreleme yaklaşımlarını sunar. Önceleri Gabor dönüşümü çok ölçekli analizde popüler bir yöntem olmuş ise de dalgacıkların kullanımı⁽⁸¹⁾ bu yöntemi gölgede bırakmıştır. Dalgacık dönüşümünün de piramit ya da ağaç yapılı olmak üzere tamamlanmış, tamamlanmamış veya paket-çerçeve (packed-frame) şeklindeki versiyonları doku analizinde kullanılmıştır⁽⁸³⁻⁸⁸⁾ ve geleneksel doku sınıflandırması çalışmalarından, hem güvenilirlik hem de kolay hesaplama açısından daha üstün olduğu anlaşılmıştır. Unser'in yaptığı çalışmada tamamlanmamış kesikli dalgacık çerçevelerinin kullanımının standart kritik olarak örneklenen dalgacık doku nitelik çıkarımı için daha uygun olduğu görülmüştür. Gabor ve dalgacık dönüşümlerinin doku sınıflandırmadaki performanslarına ait bir karşılaştırma Vautrot tarafından yapılmıştır⁽⁸⁹⁾. Eğer doku kesimleme asıl amaç ise kabadan-hassasa doğru çok çözünürlüklü yaklaşım stratejisi sıkça kullanılmıştır^(90,91), dokulu alanların yaklaşık sınırları ise düşük çözünürlükteki ilk görüntüden elde edilmiştir.

İstatistiksel doku analizi yöntemlerindeki en yeni ve insan algısıyla da tutarlı çalışma ise Portilla ve Simoncelli⁽⁹²⁾ tarafından yapılmıştır.

1.1.1.5.2. Dizimsel Doku Tanımlama Yöntemleri

Dizimsel ve karma doku belirleme yöntemleri istatistiksel yöntemler kadar yaygın kullanılmamışlardır⁽⁹³⁾. Dizimsel doku tanımlaması doku primitifinin uzaysal ilişkileri ile biçimsel bir dil yapısı arasındaki analoginin kurulmasına dayanır. Görüntüdeki dokuyu betimlemek için dokuları temsil eden kelimelerle bir gramer dizilimi yapılır.

Şekil zinciri grameri doku analizi için en basit dizimsel yöntemdir. Bu yöntemde doku bir başlangıç sembolü ve onu izleyen şekil kuralları tarafından elde edilen gramer ile tanımlanır⁽¹⁾.

Grafik grameri, primitif yerleşiminin düzlemsel grafiğini oluşturmakta kullanılan bir yaklaşımdır. Bunun için primitif sınıfları ve primitif uzaysal ilişkileri mutlaka bilinmelidir. Neticede doku sınıflandırma sorunu grafik tanımlama problemine dönüşür⁽⁹⁴⁻⁹⁶⁾.

Primitif gruplama yönteminde bazı özel örüntülerden (pattern) oluşan düşük seviyedeki primitifler gruplanarak üst seviyede tanımlama için kullanılmışlardır⁽⁵²⁾.

1.1.1.6. Doku Analizi Uygulamaları

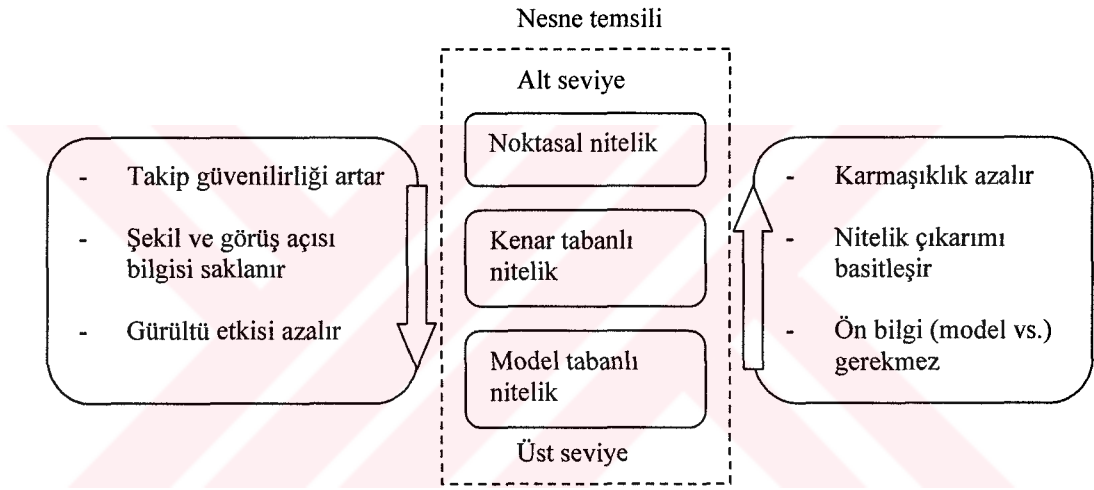
Doku tanımlama uygulamalarına mahsül miktarının tahmini, uydu görüntülerinden seyrek ormanların konumlarını belirleme, X-ray görüntülerinden otomatik olarak ciğer hastalıklarını belirleme, meteorolojik uydu verilerinden bulut tiplerinin tanımlanması örnek olarak verilebilir. Bunlar dünyadaki neredeyse sınırsız olabilecek uygulamalardan yalnızca birkaçıdır. Endüstriyel ve biyomedikal alanlarının hemen hemen her dalında, motor ya da tekstil endüstrilerinde kalite araştırması⁽⁹⁷⁻⁹⁹⁾, iş tabanlı yüzey görüntüleme⁽¹⁰⁰⁾, yol yüzeylerinin patinaj tahmini^(101,102), mikroelektronik⁽¹⁰³⁾, uzaktan algılama^(104,105), mamografi⁽¹⁰⁶⁾, MR beyin görüntüleme^(107,108), üç boyutlu doku görüntüleri⁽¹⁰⁹⁾, görüntü veritabanından içerik tabanlı veri ayıklama⁽¹¹⁰⁾ gibi örnekler vermek mümkündür.

1.2. Nesne Takibi

Nesne takibi (object tracking) ya da hedef takibi bilgisayarlı görü (computer vision) alanındaki temel problemlerden biridir. Ayrıca gerçek dünyadaki dinamik ortamlarla ilişki kurmak ve görsel olarak algılamak için önemli bir işlemdir. Nesne takibi çok geniş uygulama yelpazesine sahip olup bir çok gerçek dünya senaryosunda gereklidir. Örneğin insanların takibi görüntüleme sistemleri için, görüntü dizilerindeki insan aktivitelerinin yorumlanması da kapalı devre izleme sistemleri için önemlidir. İnsan vücut parçalarının takibi ise gelişmiş insan hareket analizi ve insan bilgisayar etkileşimi için gereklidir. Tek parça nesnelerin konumlarının belirlenmesi ve takibi ise endüstriyel otomasyon sistemleri için gereklidir. Bir fabrika ortamında nesnenin konumunun belirlenmesi ve takip edilmesi makine parçalarının ya da tek parça üretimlerin montaj, demontaj, taşıma veya paketleme işlemleri için gereklidir.

Güvenilir ve verimli bir takip çalışması geliştirmek açısından farklı uygulama alanları için nesneyi en iyi şekilde temsil edecek modelin seçilmesi gerekir. Takip uygulaması için nesne temsili, takip edilecek parametreler hakkındaki bilgiyi taşıdığı için önemlidir. Örneğin bir nesne sadece 2 boyutlu uzaydaki konumunu belirten bir nokta (x,y) olarak temsil edilebilir. Bu temsil basit, kısa, elde edilmesi nispeten kolay ve hedef takibi gibi bir çok uygulama için yeterliken, gürültüye karşı çok duyarlıdır ve takip edilecek olan nesnenin görünüşü ve şekli hakkında bilgi içermez. Görüntü dizilerinde 3 boyutlu modeller oluşturmak gibi bir çok uygulamada ise ilgilenilen nesnenin sadece konumu değil bunun yanında daha fazla bilgi içerecek şekilde temsil edilmesi gerekir. Bu durumda şekil ve görüş açısı bilgileri de gereklidir. Şekil 1.4'te takip açısından basit ve kompleks nesne temsillerinin karşılaştırılması görülmektedir.

Noktasal nitelikler gibi basit nesne temsilleri görüntüden kolay elde edilebilirlikleri yönünden avantajlara sahiptir. Bununla birlikte bu temsil gürültüye oldukça duyarlıdır ve takibi zorlaştırarak daha karmaşık takip algoritmalarının kullanılmasını gerektirir. Kenar tabanlı nitelikler gibi daha karmaşık temsillerin ise nispeten takibi kolaydır ve gürültüye karşı o kadar duyarlı değildir. Diğer taraftan sunulan nitelikler karmaşıklaştıkça nitelik çıkarımı oldukça zorlaşır ve yoğun hesaplamalar gerektirir.



Şekil 1.4 Nesne temsili noktasal, kenar tabanlı ya da model tabanlı olarak temsil edilebilirler. Her temsilin de uygulamanın çeşidine göre avantaj ve dezavantajı vardır

1.2.1. Literatürdeki Nesne Takibi Yöntemleri

Aşağıdaki kısımlarda literatürde mevcut bulunan değişik nesne takibi yöntemleri açıklanmaktadır.

1.2.1.1. Tekli ve Çoklu Nesne Takibi

Bilgisayar sistemleri ile beraber bir ya da daha çok sensör (video kamera) kullanan çoğu görü tabanlı sistemin ihtiyaç duyduğu bilgi çıkarımı ve çevreyi yorumlamak için nesne takibi temel bir gerekliliktir. Tipik sensör sistemleri ilgilenilen nesneyi , arka planı ya da iç gürültü kaynaklarını içeren ortama ilişkin ölçümleri (gözlemleri) sunarlar. Nesne takibinin amacı ise ilgilenilen nesnelere ilişkin ortamdan alınan sensör verilerini toplayarak bu sensör verilerini nesnenin ortamdaki sonraki konumunu ve hızını tahmin etmek için kullanmaktır. Bir nesnenin kapalı döngü takibini yapmak için tasarlanmış olan tekli nesne takibi ve çoklu nesne takibi sistemleri arasında temel bir fark vardır. Tekli nesne takibi sisteminde gözlenen veri doğrudan dinamik sistemin aktif durumunu tahmin eden takip filtresine, örn. Kalman filtresi, doğrudan giriş olarak verilir. Sensör sadece tek nesne takibi için kullanıldığından, veri işleme için Çok Hipotezli Takip (Multiple Hypothesis Tracking) gibi karmaşık yöntemler kullanmaya gerek yoktur. Tekli nesne takibi algoritmasının genişletilmiş şekli olan çoklu nesne takibi algoritmalarında ilgilenilen nesneye ait gözlemleri kategorize etmek için karmaşık veri işleme sistemlerine ihtiyaç vardır. Alınan gözlemler doğrudan takip filtresine verilmez ve bir çok ön işlemden, örneğin Çok Hipotezli Takip algoritmasındaki çürük hipotezlerin azaltılması, geçirilir.

Görsel takipte, nesnelere genellikle çok boyutlu uzaydaki parametreler kümesi ya da bir nokta olarak tanımlanabilen nitelikler ile temsil edilirler. Bu nitelikler bazen filtrelenmesi gereken gürültülere sahip olan yoğunluk, şekil, renk ve doku bilgilerinden elde edilir. Görsel takipteki en belirgin özellik durumun olasılık yoğunluğunu ya da şeklin belirsizliğini modellemeye dayanır. Algoritmaların çoğu Kalman filtresine dayalı durum uzayı tanımını kullanır⁽¹¹¹⁾. Kalman filtresi gürültülü gözlem bilgisi ile önceki duruma bağlı olarak yapılan tahmini birleştiren bir mekanizmaya sahiptir. Kalman filtresi gözlemler ve durumların kovaryans matrisleri ile durum belirsizliğini giderir ve gürültü gaussian dağılımlı olduğunda iyi çalışır. Eğer sistem çok dağılımlı ve görüntüde bazı engeller varsa Kalman filtreleme algoritması kullanılamaz. Başka bir nesne takibi yöntemi olan Condensation algoritması da bir simülasyon yöntemidir ve görüntüde büyük görsel engeller olduğunda da iyi çalışır⁽¹¹²⁾. Çoklu hedef takibi geniş çapta çalışılmış bir konudur ve bir çok algoritma geliştirilmiştir⁽¹¹³⁻¹¹⁶⁾. Bu algoritmaların çoğu çoklu hedef takibi söz konusu olduğunda Çok Hipotezli Takip algoritmasını kullanır⁽¹¹⁷⁻¹²⁰⁾.

1.2.1.2. Nitelik ve Modele Dayalı Nesne Takibi

Literatürde temel olarak iki ana yaklaşım vardır. İlk yaklaşım görüntü dizisindeki optik akış alanlarını (optical flow field) ya da yoğun hareket alanlarını belirleyerek, görüntüdeki nesnelere için yapıyı anlamak amacıyla bu akış veya hareket alanlarını ya da her ikisini de analiz eder. İkinci yaklaşım bir görüntüdeki bir nesneye ait kesikli niteliklerin sonraki görüntüdeki niteliklere benzerliğine dayanır⁽¹²¹⁾. Bu yaklaşımda genellikle görüntüdeki niteliklerin konumları şablon eşleme (template

matching) ya da diğler arama yöntemleri kullanılarak aranır. Uygun eşleşme bulunduğu zaman nesne hareketi bu benzerliklerden belirlenir.

1.2.1.3. Niteliğe Dayalı takip

Nitelik takibindeki asıl amaç ardışık görüntülerdeki niteliklerin görüntüdeki konumlarını tahmin etmeyi sağlamaktır. En çok kullanılan ortak nitelikler kenarlar, köşeler ve fazla karşılaştırılmış görsel bölgelerdir (high visual contrasted regions)⁽¹²²⁻¹²⁴⁾. Buna ek olarak aynı özelliklere sahip piksel grupları (blobs) da nitelik olarak kullanılabilir. Son yıllarda nitelik takibi için değişmezlerin nitelik olarak kullanımını mümkün kılmak üzere yeni değişmezlerin hesaplanmasına başlanmıştır. Köşeler ve hatlar gibi standart niteliklerin yerine projektif değişmezler (projective invariants) kullanılmışlardır^(125,126). Projektif değişmezler kamera pozisyonundan bağımsız olan görüntü nitelikleridir.

1.2.1.4. Modele Dayalı Takip

Modele dayalı takip yaklaşımlarının çoğunda ön bir bilgi olarak modelin bulunduğu varsayılır. Amaç model ve görüntü nitelikleri arasındaki maliyet fonksiyonunu minimize eden uygun bir eşleştirme yapmaktır. Eklemlı nesnelerin modele dayalı takibine ait yeni bir çalışma sunulmuştur⁽¹²¹⁾. Nesnenin önceki konfigürasyonunun bilgisi ve görüntüden alınan gözlemler Genişletilmiş Kalman filtresi ile nesnenin yeni konfigürasyonunu tahmin etmek için birleştirilmiştir. Diğler bir yeni çalışma ise çok yüzlü nesnelerin 2-3 boyutlu modellerini kullanmıştır⁽¹²⁷⁾. Önemli bir problem olan kısmen engelli görülebilen nesnelerin model tabanlı

takibine ilişkin bir çalışma da sunulmuştur⁽¹²⁸⁾. Bu yaklaşım, görüntüde nesne takibi yerine takip açısından nesne tanımaya dayanır.

1.2.1.5. İnsan Hareketlerinin Analizi Açısından Nesne Takibi

İnsan hareketlerinin bilgisayarla analizi geniş olarak incelenmiş bir konudur⁽¹²⁹⁻¹³¹⁾. Vücut parçalarının takibine dayalı insan hareketinin analizinde modele dayalı ve görünüme dayalı olmak üzere iki çeşit yaklaşım vardır. Modele dayalı yaklaşımda küçük figürler, ya da 2 boyutlu kenarlar ya da hacimsel şekiller olarak temsil edilen insan vücut parçalarının modelleri kullanılır. Görünüme dayalı yaklaşımda insan hareketi çoğunlukla alt seviye ve 2 boyutlu nitelikler kullanılarak tanımlanır. Nitelik çıkarımından sonra görüntü kareleri arasındaki nitelik benzerlikleri, pozisyon, hız, şekil, doku ve renge dayalı, örneğin Kalman filtresi gibi istatistiksel tahminciler kullanılarak elde edilir.

Kapalı devre izleme uygulamaları gibi örneklerde ise vücudun tamamının takip edilmesi bağımsız vücut parçalarının takip edilmesine göre daha verimli bir şekilde yapılmıştır. Burada takip edilecek olan nitelikler, noktalar, 2 boyutlu öbekler, piksel grupları ya da hacimler olarak temsil edilmişlerdir. Pfunder isimli çalışmada bölge tabanlı yaklaşım ve piksel kümeleri insan vücudunu modellemek ve takip etmek için kullanılmıştır⁽¹³²⁾. Her piksel grubu, grup üzerindeki piksellerin konum ve renklerinin gaussian dağılımı ile temsil edilmişlerdir. Piksel grupları kişinin baş, el ve ayaklarına karşılık gelir. Bunların takibi ise sonraki görüntüde kişinin görünüşünü tahmin etmeyi, piksel grubuna ya da arka plan modellerine ait pikseller arasındaki benzerliği belirlemeyi, bu modellerden birisi ile ilişkilendirmeyi ve istatistiksel modelleri güncellemeyi gerektirir. Ancak bu çalışma bir kişiyi takip etmekle sınırlı

kalmıştır. Başka bir çalışmada W4 ile isimlendirilen bir sistem insanların vücut parçalarını sürekli takip etmek üzere geliştirilmiştir⁽¹³³⁾. Sistem istatistiksel olarak arka planı modeller ve ön plandaki nesnelere algılayarak insan takibi için şekil ile periyodik hareket bilgisini kullanır. Bu sistem de vücut parçalarını, vücut hizası dışında iken takip edebilmekle sınırlıdır.

Ortalama kayma algoritması örnek dağılım noktası için en yakın modu aramayı sağlayan parametrik olmayan istatistiksel bir yöntemdir^(134,135). Algoritma son zamanlarda, görünüme dayalı, piksel gruplarının takibi için adapte edilmiştir. Bu piksel gruplarının takibi senaryosunda, örnek noktalar, o noktadaki örnek ağırlıkları olacak olan piksel değerleri, görüntü koordinatları boyunca düzgün olarak dağıtılmışlardır. Bu ağırlıklar, nesneye ait olanların yüksek, arka plana ait olanların ise düşük değerlerde olacak şekilde histograma dayalı tekniklerle seçilirler.

Bilinen ortalama kayma ile nesne takibinde sadece renk bilgisi kullanılmaktadır. Ancak çoğu uygulama için bu yeterli olmamıştır ve yöntemi geliştirmek için bir çok çalışma yapılmıştır. Örneğin Yılmaz'ın⁽¹³⁶⁾ çalışmasında görüntüdeki hareketlilikten dolayı ortalama kayma takipçinin eksikliğini gidermek için tüm görüntüde hareket uyumlandırma yöntemi kullanılmıştır. Porikli'nin⁽¹³⁷⁾ yaptığı çalışmada ise, takip edilecek nesneyi otomatik olarak belirlemek için hareket algılama yöntemi kullanılmış ve ortalama kayma ile takip işlemi gerçekleştirilmiştir.

Ortalama kayma hızlı bir takip yöntemi olduğundan hem tekli hem de çoklu nesne takibinde kullanılmıştır. Bu uygulamalar kimi zaman eğitim ve eğlence amaçlı alanlara da yönelmiştir. Öyle ki Alman İşaret Dili'ne ait 152 kelimeyi tanıyabilen, el takibine ve yorumlanmasına dayalı algoritmalar geliştirilmiştir⁽¹³⁸⁾. Bradski⁽¹³⁹⁾ geliştirdiği insan bilgisayar etkileşimi uygulamasında ortalama kayma yöntemini

adaptif pencere (kernel) boyutları ile kullanmış ve yöntemi CAMSHIFT (Continuously Adaptive Mean Shift) olarak adlandırmıştır. Yöntemde kullanıcı yüzünün takip edilmesi ile sanal gerçeklik ve video oyunu kumandaları gerçekleştirilmiştir. Adaptif pencere büyüklüğünün nasıl gerçekleştirileceğine dair de örnekler sunulmuştur. Ancak takip esnasında boyutu değişen nesnelere için pencere boyutlarının nasıl adapte edileceğine ilişkin en ciddi çalışma Collins⁽¹⁴⁰⁾ tarafından yapılmıştır. Collins adaptif pencere boyutu için Lindeberg teorisini⁽¹⁴¹⁾ pencere boyutu fonksiyonuna uygulamış aynı zamanda standart ortalama kayma takip algoritmasında kullanılmayan negatif piksel ağırlıklarını da kullanılabilir hale getirmiştir.

1.3. Çalışmanın Amacı

Renkli görüntü kesimlemede ortalama kayma filtreleme yöntemi genelde iyi sonuçlar vermesine rağmen bu yöntemin kullandığı renk ve uzaysal bilgiler bazı durumlarda yeterli olmamaktadır. Bu nedenle sunulan çalışmada görüntülerdeki doku bilgisinin de ortalama kayma ile filtreleme algoritması ile birlikte kullanılabilmesi düşünülmüştür. Son yıllarda doku karakterizasyonu için kullanılan popüler bir yaklaşım da kesikli dalgacık dönüşümüdür (Discrete Wavelet Transform). Tezde sunulan yöntemde görüntüdeki dokuların uzaysal hareketten bağımsız olarak analizini sağlayan dalgacık çerçeveleri (Wavelet Frames) kullanılmıştır. Ortalama kayma ile görüntü kesimlemede klasik renk ve koordinat uzayına ilave bir nitelik olarak doku karakteristiği de eklenmiştir. Sunulan çalışmada görüntülerden elde edilen doku bilgisi de ortalama kayma algoritmasının nitelik uzayına eklenerek daha üst seviyeli bir uzayda daha güvenilir bir kesimleme yöntemi geliştirilmiştir.

Ortalama kayma ile nesne takibi algoritmasının deęişik versiyonları nesne ve ortam renkleri farklı iken güvenilir bir yöntem olarak kullanılsa da nesne ve nesnenin bulunduğu ortamı temsil eden benzer olasılık dağılımları ortaya çıktığında yetersiz ve sınırlı kalmaktadır. Bu tezde iki ayrı metodu yani ortalama kayma ve kernel yoğunluk tahmini (kernel density estimation) tekniğine dayanan hareket algılama (motion detection) yöntemlerini birleştiren bir nesne takibi metodu sunulmaktadır. Sunulan nesne takibi yönteminde, standart ortalama kayma takip yönteminde kullanılan renk dağılım fonksiyonuna ek olarak, kernel yoğunluk tahmini yöntemi ile elde edilen hareket dağılım fonksiyonu da kullanılmış ve daha iyi sonuç veren bir yöntem geliştirilmiştir. Bunu yapmaktaki amaç, nesne ve ortam arasındaki yakın görüntü özelliklerinin dolayısıyla benzer olasılık dağılımlarının neden olduğu nesne takibi problemlerini çözebilen daha güvenilir bir takip algoritması geliştirmektir.

2. MATERYAL VE YÖNTEM

2.1. Ortalama Kayma Yöntemi ile Renkli Görüntü Kesimleme

Ortalama kayma ile kesimleme yöntemi parametrik olmayan bir kesimleme yöntemidir ve külfetli hesaplamalar gerektirmez. Bu yüzden alt seviden bir işlem olarak kolaylıkla kullanılabilir. Ancak literatürdeki ortalama kayma kesimleme yöntemi yalnızca görüntüdeki piksellerin koordinat ve renk bilgilerinden türetilen nitelik uzayını kullanmıştır. Böyle bir nitelik çıkarımı ise her bilgiyi barındıran bir temsil değildir. Nitelik uzayındaki özellikler ne kadar çok olursa o kadar güvenli bir işlem yapılmış olacağı da açıktır. Ortalama kayma hızlı iteratif bir algoritma olduğundan nitelik uzayının boyutu arttığında bile iyi sonuç vermektedir.

2.1.1. Giriş

Düşük seviyeli bilgisayarlı görme uygulamaları yanıltıcı şekilde zordur. Kullanılan tekniklerin çoğu, kullanıcının uygun değerleri tahmin etmesine bağlı olduğundan yanlış sonuçlar kolaylıkla elde edilmektedir. Performans artışı sağlayabilmek için, düşük seviyedeki işlemler bağımsız yüksek seviyeli bilgilerle desteklenmelidir. Böyle bir yaklaşımda, düşük seviye aşamasında bile giriş bilgisinin güvenilir bir temsilini sağlamalı ve nitelik çıkarma işleminin çok az sayıdaki giriş parametresiyle kontrol edilir olması gerekir.

Görüntülerin nitelik uzayı tabanlı analizi yukarıda açıklanan amaçlara ulaşılmasını sağlayabilecek bir örnektir. Bir nitelik uzayı, verinin, herhangi bir zamanda küçük gruplar olarak işlenmesi sırasında elde edilen bilgilerin

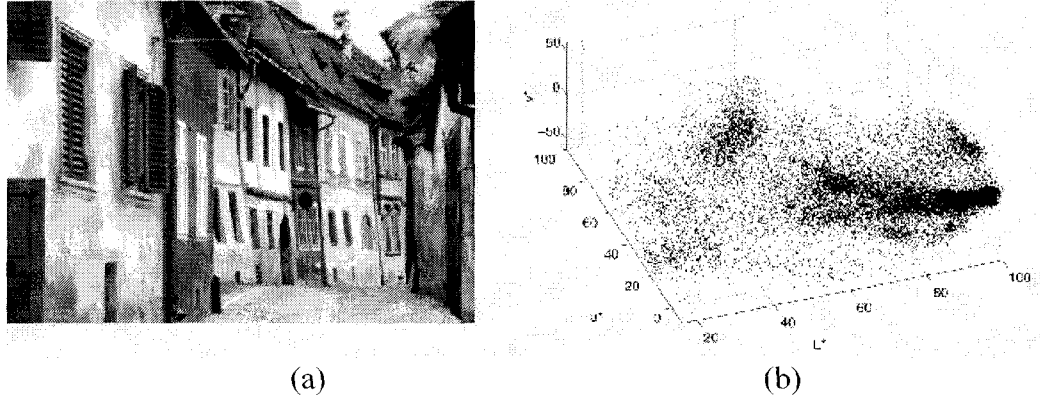
haritalanmasından oluşur. Her bir grup için, ilgili niteliğin parametrik temsili elde edilir ve sonuç çok boyutlu parametre uzayındaki bir noktayla ilişkilendirilir. Giriş verisinin tamamı işlendikten sonra nitelik uzayındaki daha yoğun bölgeler önemli niteliklere karşılık gelir, örn. öbekler, ve analizin amacı bu öbekleri birbirinden ayırmaktır.

Nitelik uzayının doğası uygulamaya bağlıdır. Haritalamada kullanılan alt gruplar tek başlarına birer piksel olabileceği gibi, -bir görüntünün renk uzayı temsilindeki gibi-, ya da olasılığa dayalı Hough dönüşümündeki gibi yarı-rasgele seçilen veri noktaları kümesi olabilir. Nitelik uzayındaki avantaj ve dezavantaj ise bu veri kümesinin nasıl türetildiğine bağlı olarak ortaya çıkar. Dezavantajları en aza indirmek amacı ile türetilen veri noktalarına ait nitelik değerleri ne kadar çok olursa nitelik uzayı da o kadar güvenli olur. Giriş verilerine ek olarak bazı bilgilerde eklenebilir, örneğin noktaya ait renk bilgisinin yanında noktanın koordinat bilgisi gibi.

Nitelik uzayının analizi ise uygulamadan bağımsızdır. Yayınlanmış olan birçok öbekleme yöntemi varken bunların çoğu gerçek verilerden türetilen nitelik uzayını analiz etmede yeterli olamamıştır. Öbeklerin aynı şekilde (örn. elips) uzayda dağılıma sahip olduğunu varsayan yöntemler kadar öbeklerin belirlenmesi için önceden maksimum öbek sayısının verilmesine dayanan yöntemler de gerçek bir nitelik uzayının analizindeki karmaşıklığı çözememiştir.

Şekil 2.1'de nitelik uzayına ilişkin bir örnek verilmiştir. Şekil 2.1.a.'daki renkli resim üç boyutlu $L^*u^*v^*$ renk uzayında karşılık gelen noktalar olarak Şekil 2.1.b.'de gösterilmiştir. Bu örnekte öbek merkezleri arasında sürekli bir geçiş olduğundan dolayı Gaussian modellere dayalı yöntemlerin bu verileri öbeklemesi

sırasında sorunlar ortaya çıkar.



Şekil 2.1. Nitelik uzayına bir örnek (a) 400x276 boyutlarında renkli bir resim (b) 110400 veri noktası olarak $L^*u^*v^*$ renk uzayında gösterimi

Gelişigüzel yapılandırılmış nitelik uzayı, varsayımlara dayanmadığı için ancak parametrik olmayan yöntemlerle analiz edilebilir. Literatürde bu yöntemlere ait çok sayıda örnek bulunabilir ve bu yöntemler iki ana sınıfa ayrılır. Bu sınıflar hiyerarşik öbekleme ve yoğunluk tahmini'dir. Hiyerarşik öbekleme yönteminde bazı yaklaşım ölçütlerine göre veri ya toplanır ya da bölünür. Ancak bu yöntem işlemsel olarak oldukça külfetlidir ve verilerin toplanması ya da bölünmesi işleminin anlamlı bir şekilde durdurulması için gerekli olan kriter net değildir. Yoğunluk tahminine dayalı parametrik olmayan öbekleme yönteminde ise, nitelik uzayı sunulan parametrelerin deneysel olasılık yoğunluk fonksiyonları (p.d.f) olarak ele alınır. Nitelik uzayındaki yoğun bölgeler, bilinmeyen yoğunluğun modları olup p.d.f'in yerel maksimum noktalarıdır. Bir modun konumu belirlendikten sonra onunla ilgili olan öbek nitelik uzayının yerel yapısına bağlı olarak ayrıştırılır⁽¹⁴²⁻¹⁴⁴⁾.

Ortalama kayma prosedürü 1975 yılında Fukunaga ve Hostetler tarafından ilk kez ortaya atılmış parametrik olmayan bir öbekleme yöntemidir⁽¹³⁵⁾. Yöntem daha

sonraları unutulmuş, Cheng'in⁽¹³⁴⁾ makalesine kadar ilgi görmemiştir ve üstün özelliklerine rağmen istatistiksel literatürde de görülememiştir. Daha sonraki yıllarda kesimleme ve renkli nesne takibi uygulamalarında kullanılarak tekrar gündeme gelmiştir^(140,145-149).

2.1.2. Ortalama Kayma Prosedürü

Kernel yoğunluk tahmini (örüntü tanıma literatüründe Parzen penceresi yöntemi olarak ta bilinir) en çok kullanılan yoğunluk tahmini yöntemidir. Verilen n adet veri noktası $\{x_i\}_{i=1..n}$ ler d boyutlu Öklit uzayı R^d de rastgele noktalar olmak üzere, $K(x)$ kerneli ile, (kernel yarıçapı h), x noktası için hesaplanan çok değişkenli kernel yoğunluk tahmini 2.1. eşitliğindeki gibi tanımlanır.

$$\hat{f}(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad 2.1$$

Kernel yoğunluk tahmininin kalitesi yoğunluk ve tahmin edilen yoğunluk arasındaki karesel hatanın ortalaması ile ölçülür. Pratikte, bununla birlikte, bu ölçütün sadece asimptotik yaklaşımı ölçülebilir. En optimum kernel, ortalama minimum toplam kare hatası veren Epanechnikov kernelidir ve profili 2.2. eşitliğindeki gibi verilen ve 2.3. eşitliğindeki gibi yarıçap olarak simetrik bir kerneldir.

$$k_E(x) = \begin{cases} 1-x & 0 \leq x \leq 1 \\ 0 & x > 1, \end{cases} \quad 2.2$$

$$KE(x) = \begin{cases} \frac{1}{2} c_d^{-1} (d+2)(1-\|x\|^2) & \|x\|^2 \leq 1 \\ 0 & \text{diğ } d. \end{cases} \quad 2.3$$

2.3 eşitliğinde c_d d boyutlu alanın birim hacmidir. Örnek vermek gerekirse; $c_1=2, c_2=\pi, c_3=4\pi/3^{(150)}$.

Epanechnikov kerneli sınırlarda türevlenemez ve 2.4. denklemindeki profil, 2.5. denklemindeki çok değişkenli normal kernel olarak sonuçlanır.

$$k_N(x) = \exp\left(-\frac{1}{2}x\right) \quad x \geq 0 \quad 2.4$$

$$K_N(x) = (2\pi)^{-d/2} \exp\left(-\frac{1}{2}\|x\|^2\right) \quad 2.5$$

Profil temsili de uygulanarak 2.1. eşitliğindeki yoğunluk tahmincisi tekrar aşağıdaki gibi yazılabilir.

$$\hat{f}_{h,K}(x) = \frac{c_{k,d}}{nh^d} \sum_{i=1}^n k\left(\left\|\frac{x-x_i}{h}\right\|^2\right) \quad 2.6$$

Burada $f(x)$ yoğunluk fonksiyonu ile tanımlanan bir nitelik uzayının analizindeki ilk adım bu yoğunluğun modlarını belirlemektir. Modlar gradyentin sıfır noktalarında ($\nabla f(x)=0$) bulunmaktadır ve ortalama kayma prosedürü yoğunluk tahminini hesaplamaya gerek kalmadan bu sıfır noktalarını bulabilen tek yöntemdir.

2.6. eşitliğinin lineerliğinden faydalanarak yoğunluk gradyentinin tahmini, yoğunluk tahmininin gradyenti olarak ifade edilebilir.

$$\hat{\nabla}f_{h,K}(x) \equiv \nabla\hat{f}_{h,K}(x) = \frac{2c_{k,d}}{nh^{d+2}} \sum_{i=1}^n (x-x_i)k'\left(\left\|\frac{x-x_i}{h}\right\|^2\right) \quad 2.7$$

Kernel profili k 'nın tüm $x \in [0, \infty)$ için türevlenebilir olduğu varsayılarak aşağıdaki gibi bir fonksiyon tanımlanabilir.

$$g(x) = -k'(x) \quad 2.8$$

2.8. eşitliğinde tanımlanan $g(x)$ profiline sahip $G(x)$ kerneli ise şu şekilde tanımlanır;

$$G(x) = c_{g,d} g\left(\|x\|^2\right) \quad 2.9$$

2.7. eşitliğinde $g(x)$ yerine yazılırsa

$$\hat{V}f_{h,K}(x) = \frac{2c_{k,d}}{nh^{d+2}} \sum_{i=1}^n (x_i - x) g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) = \frac{2c_{k,d}}{nh^{d+2}} \left[\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) \right] \left[\frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \right] \quad 2.10$$

2.10. eşitliği elde edilir. Burada $\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)$ ifadesi pozitif bir sayı olarak kabul edilir ve pratikte de bu şart kolaylıkla sağlanabilir. 2.10. denklemindeki her iki çarpım da önem taşımaktadır. İlk terim 2.7. denklemindeki x noktası için G kerneli ile tahmin edilen yoğunlukla ilişkilidir (denklem 2.11.),

$$\hat{f}_{h,G}(x) = \frac{c_{g,d}}{nh^d} \left[\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) \right] \quad 2.11$$

ikinci terim ise ortalama kayma (değişim), yani kernel (pencere) merkezi x ile G kerneli kullanılarak elde edilen ağırlıklı ortalama arasındaki farklılıktır.

$$m_{h,G}(x) = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \quad 2.12$$

2.11. ve 2.12. denklemleri yerlerine yazılırsa 2.10. denklemini şu şekle döner;

$$\hat{V}f_{h,K}(x) = \hat{f}_{h,G}(x) \frac{2c_{k,d}}{h^2 c_{g,d}} m_{h,G}(x) \quad 2.13$$

sonuç olarak ortalama kayma vektörü şu şekilde hesaplanır.

$$m_{h,G}(x) = \frac{1}{2} h^2 c \frac{\hat{\nabla} f_{h,K}(x)}{\hat{f}_{h,G}(x)} \quad 2.14$$

2.14. ifadesinden de görülebileceği gibi x konumunda G kerneli ile hesaplanan ortalama kayma vektörü, K kerneli ile elde edilen normalize edilmiş yoğunluk gradyentinin tahmini ile orantılıdır. Normalizasyon, G kerneli ile hesaplanır ve bu yüzden ortalama kayma vektörü daima yoğunluktaki maksimum artışa işaret eder. Ortalama kayma yerel gradyent tahmini ile ilgili olduğundan tahmin edilen yoğunluğun sabit noktasına doğru bir yol tanımlayabilir. Yoğunluğun modları ise böyle sabit noktalardır. Ortalama kayma prosedürü ardışık olarak aşağıdaki işlemlerin yapılması ile gerçekleşir.

- $m_{h,G}(x)$ Ortalama kayma vektörünün hesaplanması
- Kernel $G(x)$ 'in ortalama kayma vektörü ile tekrar hesaplanması

Bu işlem, yoğunluk tahmininin gradyentinin sıfır olduğu noktaların yakınında yakınsamayı garanti eder. Düşük yoğunluk değerlerine sahip bölgeler nitelik uzayı analizinde önemsenecek olan alanlardır ve böyle alanlarda ortalama kayma adımları büyük olur. Benzer şekilde yerel maksimum noktaları yakınında ise ortalama kayma adımları oldukça küçüktür ve analiz daha hassas olur. Bu yüzden ortalama kayma adaptif bir gradyent yükseltme yöntemidir.

2.1.3. Ortalama Kayma ile Görüntü Kesimleme

Nitelik uzayı analizi uygulamadan bağımsız olduğu için, birçok alanda çeşitlilik gösteren görü uygulamalarında kullanmak üzere algoritma geliştirilmesi

amacıyla kullanılabilir. İlgili olarak düşük seviyeli işlemler olan süreksizliği koruyan yumuşatma (discontinuity preserving smoothing) ve görüntü kesimleme örnek olarak verilebilir.

Bir pikselin değerini yerel pencerenin ortalama değeri ile değiştiren yumuşatma işleminde sadece gürültüler değil bilgiler de kaybolur. Süreksizlik korumalı yumuşatma işleminde ise yumuşatma miktarı görüntüdeki bölgelerin yerel yapısı içerisinde değişir, yani kenarlar korunur. Bu amaçla bir çok filtreleme yöntemi geliştirilmiştir. Wiener filtresi, yerel difüzyon işlemleri, M tahmincileri ve iki taraflı filtreleme bu yöntemlere örnek olarak verilebilir.

Ortalama kayma prosedürü ile görüntü kesimleme geliştirilirken, hem konum vektörleri hem de renk vektörlerinin birleştirildiği bir uzay tanımlanmıştır. Birleşmiş konum-renk uzayı olarak adlandırılan bu nitelik uzayının kullanılması ortalama kaymanın görüntü kesimlemedeki verimliliğini artırmıştır^(145,149). İki taraflı filtreleme yöntemi de birleşmiş konum-renk uzayını kullanmasına rağmen ortalama kayma yönteminde konum bilgisinin kullanılma şekli ile farklıdır. Bu uzayda, renkli bir görüntüdeki pikseller için, her bir nitelik vektörü ($x_i=[x,y,r,g,b]$) iki adet konum (x,y), üç adet renk (r, g, b) bilgisine sahiptir. Sadece gri tonlara sahip bir görüntü için renk vektörü 1 elemana sahip olacak ve nitelik vektörü üç elemanlı olacaktır. Nitelik uzayı oluşturulurken $L^*u^*v^*$ renk uzayı tercih edilmiştir (gri ton bir görüntü için ise yalnızca L^* kanalı kullanılır). Bunun tercihindeki sebep ise RGB renk uzayındaki koordinatlar arasında bir doğrusallık olmaması, $L^*u^*v^*$ renk uzayının ise düzgün dağılımlı bir yapıya sahip olmasıdır.

Kesimleme algoritmasındaki ilk adım görüntünün ortalama kayma yöntemi ile filtreden geçirilmesidir. Bu amaçla, birleşmiş konum-renk uzayında kullanılacak

kernel aşağıdaki gibi tanımlanır (eşitlikte $\|\cdot\|$ sembolü kazanç işlemini ifade etmektedir).

$$K_{h_s, h_r}(x) = \frac{C}{h_s^2 h_r^2} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad 2.15$$

Burada C, kernel fonksiyonundan elde edilen değerler için uygun normalizasyon sabitidir. Nitelik vektörüne ait konum bilgisini içeren kısım x^s , renk bilgisini içeren kısım ise x^r , iki uzayda da kullanılan ortak yapıya sahip kernel $k(x)$ 'tir. Bu kernellerin doğal olarak farklı bant genişlik parametreleri olup, h_s konum bant genişliği ve h_r renk bant genişliğidir.

Orijinal ve birleşmiş konum-renk uzayındaki filtrelenmiş görüntü piksellerine ait d boyutlu vektörler x_i ve z_i , $i=1, \dots, n$, olsun. Ortalama kayma filtreleme yöntemi şu şekilde tanımlanır:

Her piksel için


- $j=1$ ve $y_{i,1}=x_i$ olarak alınır.
- Aşağıdaki eşitliğe göre (2.16.) $y_{i,j+1}$ hesaplanır ve işlem yakınsadıktan sonra $y=y_{i,c}$ olarak alınır.

$$y_{j+1} = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{y_j - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} \quad 2.16$$

- Filtrelenmiş piksel için, $z_i=(x_i^s, y_{i,c}^r)$ alınır. Burada s ve r üst sembolleri sırayla vektörün konum ve renk değerlerini ifade etmektedir.

Anlaşılacağı gibi filtrelenmiş görüntüdeki pikseller yakınsama noktalarındaki renk değerlerini alacaklardır ve bu işlem boyunca kernelin konumu, iki taraflı

filtreleme yönteminin aksine sabit değildir ve pencere (kernel) yoğunluğun arttığı noktalar boyunca veriler üzerinde dolaşır. Yöntem yakınsamayı garanti ettiği için dolayı, kullanıcının herhangi bir durma kriteri girmesinin gerekmemesi de yöntemin önemli avantajlarından. Şekil 2.2’de gri tonlara sahip 256x256 boyutundaki Kameraman resminin ortalama kayma yöntemi ile filtreleme sonucu verilmiştir. Gökyüzü ve çimenler yumuşatılmış ancak kenarlardaki detaylarda değişim olmamıştır.



Şekil 2.2 Kameraman resmi (a) Orijinal resim (b) $h_s=8$, $h_r=4$ için ortalama kayma yöntemi ile filtreleme sonucu

Ortalama kaymaya dayalı görüntü kesimleme ise ortalama kayma filtreleme yönteminin uzantısıdır. Görüntüdeki her piksel, yakınındaki modlar genel nitelik uzayı analizi yöntemleri ile yok edildikten sonra, komşuluğunda bulunan birleşmiş yoğunluğun önemli modu ile ilişkilendirilir.


Orijinal ve birleşmiş konum-renk uzayındaki filtrelenmiş görüntü piksellerine ait d boyutlu vektörler x_i ve z_i , $i=1, \dots, n$, kesimlenmiş edilmiş görüntüdeki i ninci piksele ait etiket ise L_i olmak üzere ortalama kaymaya dayalı kesimleme prosedürü

şu şekilde tanımlanır:

- Görüntü için ortalama kayma filtreleme prosedürü kullanılır ve d boyutlu yakınsama noktaları z_i 'ler hakkındaki tüm bilgiler saklanır ($z_i=y_{i,c}$).
- Birbirlerine konum olarak h_s 'ten ve renk olarak h_r 'den daha yakın olan yakınsama noktaları gruplanarak öbekler $\{C_p\}_{p=1\dots m}$ oluşturulur.
- Her $i=1,\dots,n$ için $L_i=\{p|z_i \in C_p\}$ olacak şekilde öbeklere ait yakınsama noktaları etiketlenir. İsteğe bağlı olarak M pikselden daha az piksele sahip olan alanlar görüntüden ayıklanır.

Şekil 2.3'te göl resmi için yapılan ortalama kayma kesimleme sonucu görülmektedir. Kesimleme sonuçları h_s ve h_r parametrelerinin seçimine karşı fazla hassas değildir. 256×256 boyutlarındaki resimler 17×17 boyutlarında bir pencereye karşılık gelen aynı $h_s=8$ parametresini kullanmışlardır. 512×512 boyutlarındaki resimlerde ise $h_s=16$ alınmıştır. Renk parametresi h_r ve en az öneme sahip parametre olan M de kesimlenmiş görüntüdeki bölgelerin sayısını kontrol eden parametrelerdir. Bu örneklerde kullanılan kerneller düzgün dağılımlıdır.

Sonuç olarak, Hostetler ve Fukunaga tarafından ileri sürülen ortalama kayma algoritması, nitelik uzayının analizinde oldukça verimli ve güvenilir bir yaklaşım olarak görülmüştür. Comaniciu^(147-149,160,76-178) tarafından görüntü kesimleme (ve ileride nesne takipçisi) için kullanılmak üzere adapte edilmiştir. Yöntem, gerçek zamanlı uygulamalar için bile oldukça rahat uygulanabilirliği ve kesimleme sonucunun oldukça basit bir şekilde kontrol edilebilirliği ile kendisine geniş uygulama alanı bulmuştur.



Şekil 2.3 Göl resmi (a) Orijinal resim (b) $h_s=16$, $h_r=7$ ve $M=40$ için ortalama kayma yöntemi ile kesimleme sonucu

2.2. Dalgacık Dönüşümü

Fourier teorisinden de iyi bilindiği gibi bir işaret (sinyal) sinüs ve cosinüs fonksiyonlarından oluşan bir serinin sınırlı toplamı şeklinde ifade edilebilir. Bu toplam Fourier açılımı olarak bilinir. Fourier açılımının en büyük dezavantajı sadece frekans çözünürlüğüne sahip olması ve zaman çözünürlüğüne sahip olmamasıdır. Bunun anlamı, sinyaldeki tüm frekansları temsil edebilirken değerlerin ne zaman ortaya çıktığının bilinmemesidir. Bu problemi çözmek için sinyali aynı anda hem zaman hem de frekans alanında ifade edecek bazı çözümler üretilmiştir.

Dalgacık dönüşümü ya da dalgacık analizi Fourier analizindeki bu eksiklikleri gidermek için üretilmiş en yeni çözümlerdendir. Dalgacık analizinde tamamen ölçeklenebilir modüle edilmiş pencerelerin kullanılması sinyal-kesme problemini çözer. Pencere sinyal boyunca kaydırılır ve her spektrum için hesaplama yapılır. Bu işlem her yeni bir saykıl için nispeten daha kısa (ya da uzun) pencere ile

birçok kez tekrar edilir. Elde edilen sonuç sinyalin tüm farklı çözünürlüklerdeki zaman-frekans gösterimlerinin bir koleksiyonu olacaktır. Dalgacıklar ise zaman-ölçek uzayında tanımlıdır ve ölçek terimi frekansa zıt bir kavramdır bu yüzden frekans terimi fourier dönüşümü için kullanılmıştır. Büyük ölçekten küçük ölçeğe gitmek ise resmin küçük bir bölgesine yakınlaştırma yapmak gibidir.

2.2.1. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü genel olarak aşağıdaki şekilde ifade edilir:

$$\gamma(s, \tau) = \int f(t) \psi_{s, \tau}^*(t) dt \quad 2.17$$

burada * kompleks eşleniği gösterir. Bu eşitlik $f(t)$ fonksiyonunun dalgacıklar olarak adlandırılan $\psi_{s, \tau}(t)$ temel fonksiyonlar kümesine nasıl ayrıştırılabileceğini gösterir. Burada s ve τ değişkenleri, ölçek ve konum (dönüşüm), dalgacık dönüşümü sonrasındaki yeni boyutlardır. Benzer şekilde ters dalgacık dönüşümü de 2.18. eşitliğindeki gibi verilir.

$$f(t) = \iint \gamma(s, \tau) \psi_{s, \tau}(t) d\tau ds \quad 2.18$$

Dalgacıklar ana dalgacık olarak adlandırılan tek bir temel dalgacıktan $\psi(t)$ türetilirler.

$$\psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t - \tau}{s}\right) \quad 2.19$$

Bu eşitlikte s ölçekleme faktörü, τ dönüşüm faktörü, ve $s^{-1/2}$ ise farklı ölçekler boyunca enerji normalizasyon faktörüdür. Dikkat edilirse dalgacık tabanlı

fonksiyonlar özel fonksiyonlar olmak zorunda değildir. Bu fourier ya da diğer dönüşümler ile dalgacık dönüşümü arasındaki önemli farklardandır.

2.2.2. Kesikli Dalgacıklar

Dalgacık dönüşümünün 2.17. eşitliğindeki gibi doğrudan kullanılmasını zorlaştıran üç temel özelliği vardır. Bunlardan ilki sürekli dalgacık dönüşümünün indirgenebilir olmasıdır. 2.17. denkleminde dalgacık dönüşümü sürekli ölçeklenebilen ve asıl sinyal ile bu sinyalin üzerinde sürekli kayan sinyal arasındaki ilişkinin hesaplanması yoluyla hesaplanmıştır. Ölçeklenen fonksiyonların hiçbir yerde ortogonal temellere yakın olmayacağı açıktır ve elde edilen dalgacık katsayıları bu yüzden oldukça gereksizdir. Çoğu pratik uygulamalarda bu aşırılığın yok edilmesi istenir.

Sürekli dalgacık dönüşümü indirgenebilir olmasa bile dönüşümde sınırsız sayıda dalgacık olacaktır ve bu sayının daha kolay kontrol edilebilecek kadar az olması istenebilir. Bu ise ikinci problemdir.

Üçüncü problem ise dalgacık dönüşümünde kullanılacak olan fonksiyonların çoğunlukla analitik çözümleri olmayıp yalnızca nümerik olarak hesaplanabilmesidir.

Dalgacık dönüşümünün üstünlüğünü ortaya çıkarmak için hızlı algoritmaların geliştirilmesi gerekmektedir. Daha önce de belirtildiği gibi sürekli dalgacık dönüşümü oldukça indirgenebilirdir. Bu yüzden kesikli dalgacık dönüşümü yöntemi geliştirilmiştir. Kesikli dalgacıklar sürekli olarak ölçeklenip dönüştürülemezler ancak kesikli adımlarla ölçeklenip kaydırılabilirler. 2.19. denklemi bu amaçla 2.20. eşitliğindeki gibi düzenlenir⁽¹⁵¹⁾.

$$\psi_{j,k}(t) = \frac{1}{\sqrt{s_0^j}} \psi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad 2.20$$

Bu dönüşüm fonksiyonu kesikli olarak adlandırılmasına rağmen normalde kesikli sürekli bir fonksiyondur. 2.20. eşitliğinde j ve k birer tamsayıdır ve $s_0 > 1$ olan sabit genişleme adımındır. Dönüşüm faktörü τ_0 genişleme adımına bağlıdır. Dalgacıkları kesikli yapmanın etkisi zaman-ölçek uzayında belirli aralıklarda örnekleme yapma şeklinde ortaya çıkar. Frekans eksenlerinin örneklenmesinin ikili örnekleme için uygun düşmesi için genellikle $s_0 = 2$ alınır. Zaman ekseninin de ikili olarak örneklenebilmesi için, dönüşüm faktörü genellikle $\tau_0=1$ alınır.

Daha sonra dalgacıklar, sürekli sinyalin dalgacık katsayıları cinsinden seriye açılması için kullanılır ve bu işlem dalgacık serisine ayrıştırma olarak isimlendirilir. Orijinal sinyalin kayıpsız olarak tekrar elde edilmesi kullanılan dalgacığın tipine bağlıdır. Üstün yeniden elde etme özelliğine sahip filtre bankaları ve bunların sahip olması gereken özellikler açıklanmıştır⁽¹⁵¹⁾. Ayrıca tamamen indirgenebilir olması için dalgacıklar ortonormal olmalıdır. Bu yalnızca kesikli dalgacıklar için mümkün olan bir özelliktir. Dalgacıklar özel seçilmiş olan ana dalgacığın dönüşümleri ve kendi genişlemeleri ile ortogonal yapılabilir, yani (2.21. eşitliğindeki dalgacıklar aynı zamanda biortogonaldır);

$$\int \psi_{j,k}(t) \psi_{m,n}^*(t) dt = \begin{cases} 1 & j = m \text{ ve } k = n \text{ ise} \\ 0 & d.d. \end{cases} \quad 2.21$$

Dalgacık dönüşümü katsayıları ile ifade edilmiş herhangi bir sinyal, ortogonal dalgacık tabanlı fonksiyonların toplamı ile yeniden oluşturulabilir⁽¹⁵²⁾ (2.22. denklemi).

$$f(t) = \sum_{j,k} \gamma(j,k) \psi_{j,k}(t) \quad 2.22$$

Ortogonallık sinyalin temsil edilmesi için zorunlu değildir. Dalgacıkların ortogonal olmasına çok sık ihtiyaç duyulmaz ve bazı uygulamalarda indirgenebilirlik gürültüye olan hassasiyeti azaltmada yardımcı olur⁽¹⁵²⁾ ya da kaymaya olan bağımsızlığını yok eder⁽¹⁵³⁾. Bu ise kesikli dalgacıkların bir dezavantajıdır, oluşan dalgacık dönüşümü artık kaymadan bağımsız değildir. Bu yüzden bir sinyalin kendisinin ve aynı sinyalin zamanda kaydırılmış şeklinin dalgacık dönüşümü sadece diğerinin kaydırılmış şeklini vermez.


2.2.2.1. Ölçekleme Fonksiyonu

Dalgacığın ikinin katları şeklinde zaman eksenine sığdırıldığı her zaman bant genişliği yarıya düşer. Başka bir ifade ile, her dalgacık kalan spektrumun yarısını kaplayacak şekilde alana sığdırılır ve bu yüzden sonsuz sayıda dalgacık gerekir. Bu problem alçak geçiren davranışa sahip ölçekleme fonksiyonu ile çözülür⁽⁸¹⁾. Ölçekleme fonksiyonu sadece alçak geçiren spektrumlu bir fonksiyon olarak alınıp, 2.23. eşitliğindeki gibi dalgacık bileşenlerine ayrıştırılabilir.

$$\varphi(t) = \sum_{j,k} \gamma(j,k) \psi_{j,k}(t) \quad 2.23$$

Ölçekleme fonksiyonu $\varphi(t)$ bu yol ile seçildiği için spektrumu, dalgacıklar tarafından boş bırakılan yerlere yaklaşık olarak uyar. Böylece belirli bir j ölçeğine kadar sınırsız dalgacık kullanılmış olur. Eğer sinyal ölçekleme fonksiyonu ve dalgacıkların kombinasyonu ile analiz edilecekse ölçekleme fonksiyonu spektrumu karşılar aksi halde j ölçeğine kadar dalgacıklar tarafından kaplanır. Bu yol ile sonsuz


sayıdaki dalgacıklar sınırlı bir sayıya indirilmiş olur (Şekil 2.4).



Şekil 2.4 Sonsuz sayıdaki dalgacıklar kümesi bir ölçekleme fonksiyonu ile değiştirilebilir

2.2.3. Alt Bant Kodlama

Eğer dalgacık dönüşümünü bir filtre bankası olarak ele alırsak, dalgacık dönüşümü bu filtre bankasından geçen bir sinyalin şekli olarak göz önüne alınabilir. Farklı filtre aşamalarının çıkışları dalgacık ve ölçekleme fonksiyonu dönüşüm katsayılarıdır. Bu işleme alt bant kodlama adı verilmekte ve örneğin bilgisayarlı görü alanında kullanılmaktadır. Şekil 2.5'te alt bant kodlama işlemine örnek verilmiştir. Orijinal sinyal, bant genişliğinin $1/8$, $1/4$, $1/2$ katlarına sahip 4 alt sinyale bölünmüştür.



Şekil 2.5 Filtre bankası kullanarak sinyal spektrumunun parçalanması

2.2.4. Kesikli Dalgacık Dönüşümü

Çoğu pratik uygulamada ilgilenilen sinyal örneklenir. Kesikli dalgacıkların sadece ölçekleme ve dönüştürme adımlarının kesikli olduğu zamanda kesikli olmadığının burada hatırlatılmasında yarar vardır.

2.23. eşitliğinde ölçekleme fonksiyonunun sonsuzdan belirli bir j ölçeğine kadarki dalgacıklar ile ifade edilebildiği görülmektedir. Eğer dalgacık spektrumu da ölçekleme fonksiyonu spektrumuna ilave edilirse ilkinin iki katı genişliğinde spektruma sahip yeni bir ölçekleme fonksiyonu elde edilir. Buna çok çözünürlüklü formülasyon denilir⁽¹⁵³⁾.

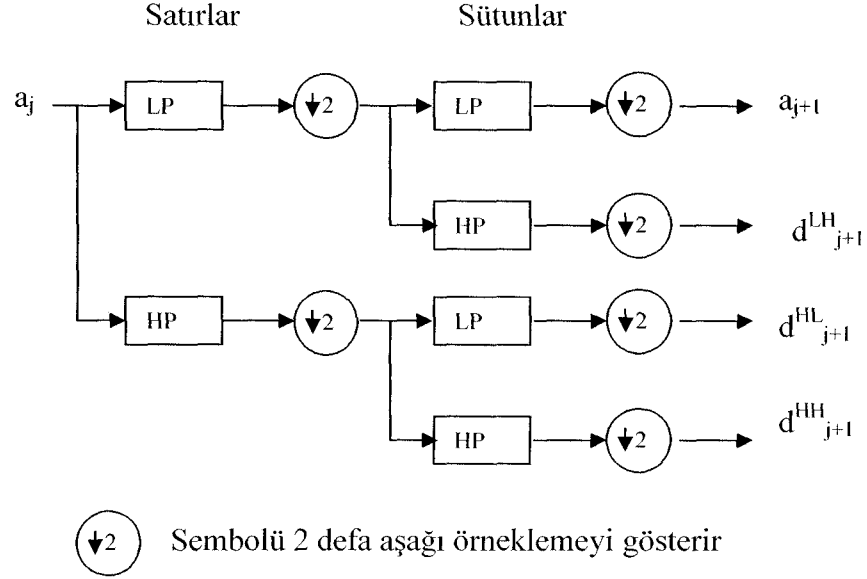
$$\varphi(2^j t) = \sum_k h_{j+1}(k) \varphi(2^{j+1} t - k) \quad 2.24$$

2.24. denkleminde $h(k)$ ölçekleme filtresidir. Daha küçük ölçek kullanılırsa sinyaldeki daha çok detay gösterilebilir. Dalgacık j seviyesi için, dalgacık filtresi $g(k)$ ile aşağıdaki gibi yazılır.

$$\psi(2^j t) = \sum_k g_{j+1}(k) \varphi(2^{j+1} t - k) \quad 2.25$$

2.2.5. İki Boyutlu Kesikli Dalgacık Dönüşümü ile Görüntü İşleme

Görüntüler de belirli bir satır ve sütundan oluşan 2 boyutlu kesikli bir sinyaldir (matris) ve dalgacık dönüşümü ile analizi mümkündür. Bir görüntü matrisi için kesikli dalgacık dönüşümü matris satır ve sütunlarının ayrı ayrı yüksek geçiren ve alçak geçiren filtrelerden geçirilmesi esasına dayanılarak yapılır (Şekil 2.6). Şekil 2.6'daki dönüşüm aynı zamanda piramit yapılı dönüşümdür.



Şekil 2.6 İndirgenmiş dönüşüm

Burada a_j giriş görüntüsünün, yaklaşık katsayıları a_{j+1} , yataydaki ve 45 derecelik açıdaki kenarların belirginleştiği detay görüntü d_{j+1}^{LH} , dikeydeki ve 45 derecelik açıdaki kenarların belirginleştiği detay görüntü d_{j+1}^{HL} , 45 derecedeki açığa sahip tüm kenarların ifade edildiği detay görüntü ise d_{j+1}^{HH} dir. Her bir filtrenin çıkışı aşağıdaki eşitlikte verildiği gibi hesaplanır⁽¹⁵⁴⁾

$$a_{j+1}[p] = \sum_{n=-\infty}^{\infty} l[n-2p]a_j[n]$$

$$d_{j+1}[p] = \sum_{n=-\infty}^{\infty} h[n-2p]a_j[n]$$


2.26

Burada $l[n]$ ve $h[n]$ sırayla alçak geçiren ve yüksek geçiren filtrelerin katsayılarıdır.

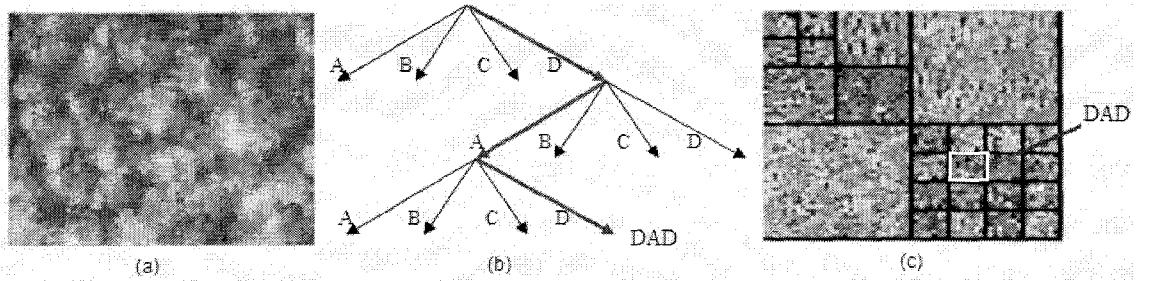
Şekil 2.6'da indirgenmiş dönüşüm gösterilmektedir. Bu dönüşümde satır ve sütunların filtrelerden geçirilme aşamalarından sonra 2 satır veya sütun aşağı örnekleme yapılır. Dolayısıyla alt kanallardaki görüntüler ilk görüntünün satır ve sütun sayısının yarısına sahip olur ve gereğinden fazla bilgilerin alınması önlenmiş

olur.

Bir görüntü 2 boyutlu kesikli dalgacık dönüşümüne sokulduktan sonra, piramit yapısında ya da ağaç yapısında analiz edilebilir. Piramit yapısında yaklaşık görüntü (a_{j+1}) tekrar dönüşüme tabi tutulurken ağaç yapısında yalnızca yaklaşık görüntü değil diğer görüntülerde (d^{HL}_{j+1} , d^{LH}_{j+1} , d^{HH}_{j+1}) tekrar dönüşüme tabidir. Şekil 2.7’de piramit yapısı şeklinde organize edilmiş Şekil 2.8’de ise ağaç yapısına sahip görüntüler verilmiştir. Dikkat edilirse hem ağaç yapısında hem de piramit yapısında aşağı örnekleme yapılmaktadır.



Şekil 2.7 Piramit biçiminde ayrıştırma, $j=2$



Şekil 2.8 Ağaç yapısında görüntü ayrıştırma (a) orijinal resim (b) Seçilen ağaç yapısı (c) Ayrıştırma sonucu

Kesikli dalgacık dönüşümü (DWT), uzunluğu 2 nin tamsayı kuvvetlerinden oluşan veri vektörlerinin lineer dönüşümüdür ve veri vektörünü sayısal olarak farklı ancak uzunluk olarak aynı başka bir vektöre dönüştürür. Yani veriyi farklı frekanstaki bileşenlerine ayırarak her bir bileşenin ölçeğine uygun olan bir çözünürlükte incelenmesini olanaklı kılar. Her bir sonraki ölçekte verinin uzunluğu aşağı örneklemeden dolayı yarıya düşer.

Bu bölümde görüntü işleme alanında da kullanım alanına sahip olan dalgacık dönüşümü açıklanmıştır. Bu dönüşüm işlevselliği ile görüntü sıkıştırma, veri depolama, gürültü filtreleme, doku analizi ve tıbbi görüntü işleme uygulamalarında kullanılmıştır.

2.3. K-means ile Öbekleme

Bu kısımda değinilmesi gereken bir konu da, sunulan çalışmada kullanılan iteratif bir sınıflandırma algoritması olan K-means ile öbeklemedir.

K-means, veri kümesini k adet öbeğe bölen ve her öbek için grup içi hata kare toplamını minimize eden iteratif bir öbekleme yöntemidir⁽¹⁵⁵⁾. Burada k veri kümesinin bölünmesini istediğimiz öbek sayısını temsil eder ve genellikle bilinen bir sayıdır. K-means yönteminin en basit formu iki ana prosedüre dayanır. Bunlardan ilki noktaları gruplara atamaktır. Noktalar genellikle ortalama değeri en yakın olan gruba dahil edilir. İkinci aşamada oluşan bu grupların ortalama değerleri yeniden hesaplanır. Bu işlem ise noktaların gruptan gruba taşınma işlemi bittiğinde yani grup içi hata kare toplamı minimize edildiğinde sona erer.

Bu öbekleme yönteminde verinin kaç öbeğe ayrılacağını doğru tahmin etmek çok önemlidir. Çünkü algoritma her bir öbeğin bir merkeze sahip olduğu varsayımına dayanır. Burada i 'ninci öbek merkezi c_i ile, öbeklenecek olan j 'ninci elemanı ise x_j nitelik vektörüyle gösterilsin. Örneğin, eğer dağınık bir haldeki noktaları kesimlemek istiyorsak x noktaların koordinatları olacaktır, eğer gri tonlara sahip bir resmi kesimlemek istiyorsak x bir pikselin sahip olduğu gri ton değeri olacaktır.

Bütün elemanların kendi öbeklerinin merkezine yakın olduğunu varsayılarak amaçlanan fonksiyon aşağıdaki gibi tanımlanabilir;

$$\Phi(\text{öbekler}, \text{veri}) = \sum_{i \in \text{öbekler}} \left\{ \sum_{j \in i' \text{ninci öbek}} (x_j - c_i)^r (x_j - c_i) \right\} \quad 2.27$$

Dikkat edilirse, öbeklerin tahsis ettiği noktaların sayısının bilinmesi halinde her bir öbek için en iyi merkezin hesaplanması çok kolay olacaktır. Ancak noktaların öbeklere tahsisi için çok fazla ihtimal vardır. Bunun yerine, algoritma daha önce sözü edilen iki aşama ile iteratif olarak hesaplama yapar:

- Öbek merkezlerinin bilindiği varsayılarak her nokta en yakınındaki öbek merkezi ile gruplanır.
- Tahsis edilecek nokta sayısının bilindiği varsayılarak öbek merkezlerinin yeni kümesi seçilir. Her bir merkez o öbek tarafından tahsis edilen noktaların ortalamasıdır.

Öbek sayısı belirlendikten sonra rasgele seçilen öbek merkezleri ile bir başlangıç yapılır ve yukarıda açıklanan iki adım iteratif olarak takip edilir. Bu işlem er geç amaçlanan fonksiyonunun yerel minimum noktasında yakınsayacaktır. Bununla birlikte, yöntem fonksiyonun global minimum noktasındaki yakınsamayı

garanti etmez. Her bir öbeği sıfırdan farklı nokta sayısına sahip olmasını sağlayacak şekilde tahsisat evresini deęiřtirmedikçe k adet öbek üretmeyi de garanti etmez.

Algoritma řu řekilde verilebilir:

- Öbek merkezi olacak herhangi k adet nokta seçilir
- Öbek merkezleri sabitleřinceye kadar
- Her nokta en yakınındaki öbek merkezi ile gruplanır
- Her öbeğin en az bir adet veri noktasına sahip olması sağlanır; bunun için boş öbeklere dięer öbeklerden de uzak olan rasgele seçilen bir veri noktası eklenir.
- Öbek merkezleri öbekteki noktaların ortalaması ile deęiřtirilir.

Bu yaklařımla görüntü kesimleme yapılırken karşılařılacak olan bir problem; alanların birleřmemiř olabilmesi ya da çok yaygın bir řekilde daęıtılabilesidir. Bu etki piksel koordinatlarının da nitelik olarak kullanılması ile azaltılabilir ancak büyük veri kümelerinde bu yaklařım da iyi sonuç vermemektedir⁽¹⁵⁶⁾.

2.4. Kesikli Uzayda Olasılık

Olasılık, belirsizliğin hesaba katılmasını sağlayan uygun bir mekanizmadır ve görüntü işleme uygulamalarında da kullanılmaktadır. Bu kısımda çok kısa birkaç hatırlatma yapılacaktır.

Genelde, bir olasılık modeli ayrılabilir çeřitli tipteki deneysel çıktıların karşılařtırılması için kullanılır. Bu çıktılar çoęunlukla olay olarak isimlendirilirler. Eđer bir olayın ortaya çıkması mümkün ise çıkmaması da mümkündür. İki olayın bağımsız olarak ortaya çıktığı gözlenebiliyorsa art arda ortaya çıkma olasılıkları da

vardır. Kesikli ve sınırsız bir uzay D , olsun. F olarak adlandırılan, D nin alt kümelerini oluşturmak için aşağıdaki özellikleri göz önüne alalım.

F teki boş bir küme D ye eşittir.

Kesişme özelliği: Eğer $S_1 \in F$ ve $S_2 \in F$ ise $S_1 \cap S_2 \in F$.

Tümleyen özelliği: Eğer $S_1 \in F$ ise $S_1' = D - S_1 \in F$.

F 'nin elemanları olaylara karşılık gelmektedir. Dikkat edilirse ortaya çıkan olayların herhangi bir mantıksal kombinasyonundan bahsedilebilir.

2.4.1. Olasılık Fonksiyonu P

F 'nin elemanlarını birim artışlarla alan bir P fonksiyonu tanımlansın. P 'nin şu özellikleri taşıması gerekir;

P fonksiyonu F 'nin tüm elemanları için tanımlı olmalıdır.

$P(\text{boş küme})=0$

$P(D)=1$

$A \in F$ ve $B \in F$ ise $P(A \cup B) = P(A) + P(B) - P(A \cap B)$ dir.

Burada $0 \leq P(A) \leq 1$ dir.

2.4.2. Şartlı Olasılık

Eğer bir olayın olması başka bir olayın olmasına bağlı olarak tanımlanıyorsa şartlı olasılık söz konusudur. $A \in F$ ve $B \in F$ olsun. A nın C 'ye bağlı olarak ortaya çıkma ihtimali

$$P_A(B) = \frac{P(B \cap A)}{P(A)} = P(B | A)$$

2.28

olarak verilir. Dolayısıyla $P(A \cap B) = P(A|B)P(B) = P(B|A)P(A)$ dır. Bazı olasılık modellerinde olaylar birbirine bağılı değildir. Bu durumda $P(A \cap B) = P(A|B)P(B) = P(A)P(B)$ olur. Örneğin A olayları bir çok A_i ($i=1 \dots n$) alt olayından meydana geliyorsa $P(B|A) = \sum_{i=1}^n P(B|A_i)P(A_i|A)$ olarak yazılır.

Sürekli uzaydaki çok boyutlu ihtimalleri kapsayan olasılık fonksiyonu ise Olasılık Yoğunluk Fonksiyonu olarak adlandırılır.

2.4.3. Histogram

Histogram bir verinin gözlemlerdeki tekrar etme sayısıdır. $I(x)$ gözlemleri 1 ile R arasında değişiyor ise herhangi bir gözlem değeri n için histogram şu şekilde hesaplanır:

$$h(n) = \sum_{i=1}^R \delta[I(x) - n] \quad 2.29$$

Burada δ birim darbe fonksiyonudur. Herhangi bir m gözleminin olasılığı ise

$$P(m) = \frac{h(m)}{\sum h} \quad 2.30$$

olarak verilir. Histograma dayalı basit olasılık modelleri, genellikle görüntülerde, bölgelere ait olasılık yoğunluklarını belirlemek için kullanılır. Ancak renk uzayları lineer değilse bu yöntem iyi sonuç vermez. Daha farklı olasılık dağılımı yöntemleri , örneğin gaussian dağılımı, kullanmak gerekir.

2.5. Kernel Yoğunluk Tahminini

Kernel yoğunluk tahmini, uygun bir parametrik model bulunamadığı durumlarda veri kümesinin yapısı hakkında bilgi edinmeye yönelik parametrik olmayan bir yöntemdir. Kernel yoğunluk tahmini yöntemi gözlemlerden elde edilen olasılık yoğunluk fonksiyonlarını hesaplamak için kullanılır⁽¹⁵⁷⁾. Herhangi bir X değişkeni için bağımsız gözlemlerden elde edilen bir veri kümesi $S = \{x_1, x_2, \dots, x_N\}$ verilmiş olsun. X noktasındaki yoğunluk tahmini $p(x)$ için kernel yoğunluk tahmincisi $\hat{p}(x)$ aşağıdaki gibi verilir.

$$\hat{p}(x) = \frac{1}{N} \sum_{i=1}^N K_{\sigma} \left(\frac{x - x_i}{\sigma} \right) \quad 2.31$$

Burada K_{σ} , σ bant genişliğine sahip kernel fonksiyonudur ve σ tahmin edilen değerlerin yumuşaklığını kontrol eder. Kernel yoğunluk tahmini, yoğunluk fonksiyonunun belirli bir şekilde olduğunu varsaymadığı için yoğunluk tahmini için oldukça genel bir yaklaşımdır. Daha fazla boyuta sahip veri kümeleri için tahmin edilen yoğunluk tek boyutlu kernellerin çarpımı olarak aşağıdaki gibi verilebilir.

Burada d boyut sayısını gösterir⁽¹⁵⁸⁾.

$$\hat{p}(x) = \frac{1}{N} \sum_{i=1}^N \prod_{j=1}^d K_{\sigma_j} \left(\frac{(x - x_i)_j}{\sigma_j} \right) \quad 2.32$$

Bu çalışmada, kernel yoğunluk tahmini yöntemi hem nesneye hem de arka plana ait modellerin geliştirilmesinde kullanılmıştır. Gelen her bir sonraki görüntü karesindeki aynı konumdaki piksellerin renk değerleri tahmin edilecek veri kümesi (gözlemler) olarak kullanılmıştır. Bu tahmin edilen modeller kullanılarak, görüntüdeki değişimlerden (hareket, ışık değişimi gibi) kaynaklanan piksel değerlerindeki değişimler kolaylıkla algılanmıştır.

2.6. Ortalama Kayma Yöntemi ile Nesne Takibi

Görsel niteliklerin karmaşık ortamlarda sağlam ve güvenilir bir şekilde takip edilmesi gerçekten üstesinden gelinmesi gereken zor bir işlemdir. Kapalı devre izleme ve görüntüleme, algılamaya dayalı kullanıcı arabirimleri, akıllı odalar ve video sıkıştırma gibi gerçek zamanlı uygulamalar hareketli nesnelerin takip edilmesine gereksinim duyarlar. Buna ek olarak gerçek zamanlı uygulamalarda takip edici sistem kaynaklarının çok az bir yüzdesini kullanmalı ve kalanı ise ön-işleme aşaması ya da tanımlama, yörünge yorumlama ve ilişki kurma gibi yüksek seviyeli işlemler için ayrılmalıdır. Takip edicinin getireceği yoğun hesaplama külfeti kritik uygulamalar için bu noktada önemli olmaktadır.

Bu bölümde, ortalama kayma algoritmasının, hedeften elde edilen istatistiksel bilgilere dayanılarak renk, doku gibi görsel niteliklerinin verimli bir şekilde takibinde nasıl kullanıldığından bahsedilecektir. Bu yöntem birden çok (farklı renkli bölgelere sahip) hedefin, örneğin yüzler, insan gövdeleri, değişik renk/doku örüntüleri, gerçek zamanlı olarak ve hedeflerin kısmi kaybolması durumunda bile sağlam bir takip sağlamaktadır. Ana düşünce, aktif görüntüdeki hedefin koordinatı ile sonraki görüntü karesindeki hedefin özelliklerine benzer en yakın bölgenin koordinatının belirlenmesine dayanır.

Aşağıdaki tanımlamalar yapılmış olsun;

$\{x_i(j+1)\}_{i=1..n}$ (j+1). görüntüdeki piksellerin konumu

$\{q_k(j+1)\}_{k=1..m}$, $m=1..256$ (j+1). görüntüdeki m adet aralıktan oluşan renk histogramı

$\{p_k\}_{k=1..m}$ m adet aralıktan oluşan hedefe ait renk histogramı

Ayrıca $x_i(j+1)$ konumundaki piksel ile ilgili olarak $c[x_i(j+1)]$ indeksinin o pikselin rengine ait histogram aralığını belirtecek olan $c:R^2 \rightarrow \{1..m\}$ fonksiyonu da

tanımlanmış olsun. Hedefin varlığı için ölçüt aşağıdaki gibi tanımlanan⁽¹⁵⁹⁾ orantı histogramıdır.

$$r_k = \left\{ \frac{p_k}{q_k(j+1)}, 1 \right\}, \{r_k\}_{k=1..m} \quad 2.33$$

Orantı histogramının $(j+1)$. görüntüdeki izdüşümü $r_c[x_i(j+1)]$ değerini tüm $i=1..n$ için $x_i(j+1)$ pikseli ile ilişkilendirir. Orantı histogramı hedefe ait baskın rengi vurgulayıp, dağınık ve arka plan renklerinin varlığını azalttığı için izdüşüm görüntüsü $\{r_c[x_i(j+1)]\}_{i=1..n}$ hedefin varlığının uzaysal ölçütünü gösterir. İzdüşüm görüntüsündeki değerleri her bir piksel konumundaki ağırlık değeri olarak alırsak, hedef takip işlemi izdüşüm görüntüsündeki yerel modun konumunu belirleme işlemine dönecektir.

Görüntü koordinatları x ve y 'nin (en ve boy olarak) hx ve hy ile normalize edildiğini varsayalım. Bu, ortalama kayma takip çalışmasında pencere yarıçapı olarak $h=1$ kullanılmasını olanaklı kılar. Burada hx ve hy hedefi sınırlayan pencereye ait x ve y koordinatlarındaki yarıçaplardır. Ortalama kayma takip algoritması aşağıdaki aşamalardan oluşmaktadır⁽¹⁶⁰⁾.

Öncelikle j . görüntüde takip edilecek hedefin konumu $\hat{y}(j)$ belirlenir, m adet aralıktan oluşan hedefe ait renk histogramı $\{p_k\}_{k=1..m}$ hesaplanır ve sonraki görüntü $((j+1)$. görüntü) için:

1. m adet aralıktan oluşan renk histogramı $\{q_k\}_{k=1..m}$ hesaplanır.
2. orantı histogramı $\{r_k\}_{k=1..m}$ hesaplanır.
3. izdüşüm görüntüsü $\{r_c[x_i(j+1)]\}_{i=1..n}$ üretilir
4. $\hat{y}_1(j+1) = \hat{y}(j)$ ve $u=1$ alarak ortalama kayma iterasyonlarına başlanır.

Yakınsayana kadar 2.34 eşitliğindeki hesaplama yapılır.

$$\hat{y}_{u+1}(j+1) = \frac{\sum_{i=1}^n x_i(j+1) r_c[x_i(j+1)] K(\|\hat{y}_u(j+1) - x_i(j+1)\|^2)}{\sum_{i=1}^n r_c[x_i(j+1)] K(\|\hat{y}_u(j+1) - x_i(j+1)\|^2)}, u \leftarrow u+1 \quad 2.34$$

İterasyon sırasında hesaplanan yeni koordinata pencere taşınır ve tekrar hesaplama yapılır. Ardışık iki hesaplama arasındaki fark, belirli bir hata değerinin (toleransın) altına düştüğünde hesaplama bırakılır, yakınsama sağlanmış olur. K kerneli uniform profile sahip bir kernel olarak seçilirse hedefin konumu yerel komşuluk içerisindeki basit ağırlıklı ortalama hesaplaması yapılarak bulunmuş olur. Bu yöntemde sadece bir çift iterasyon ile yakınsama sağlanmıştır ve tüm prosedür oldukça basittir. Bu nedenle hızlı hareket eden hedefler de kolaylıkla takip edilebilmektedir.

3. ARAŞTIRMA BULGULARI

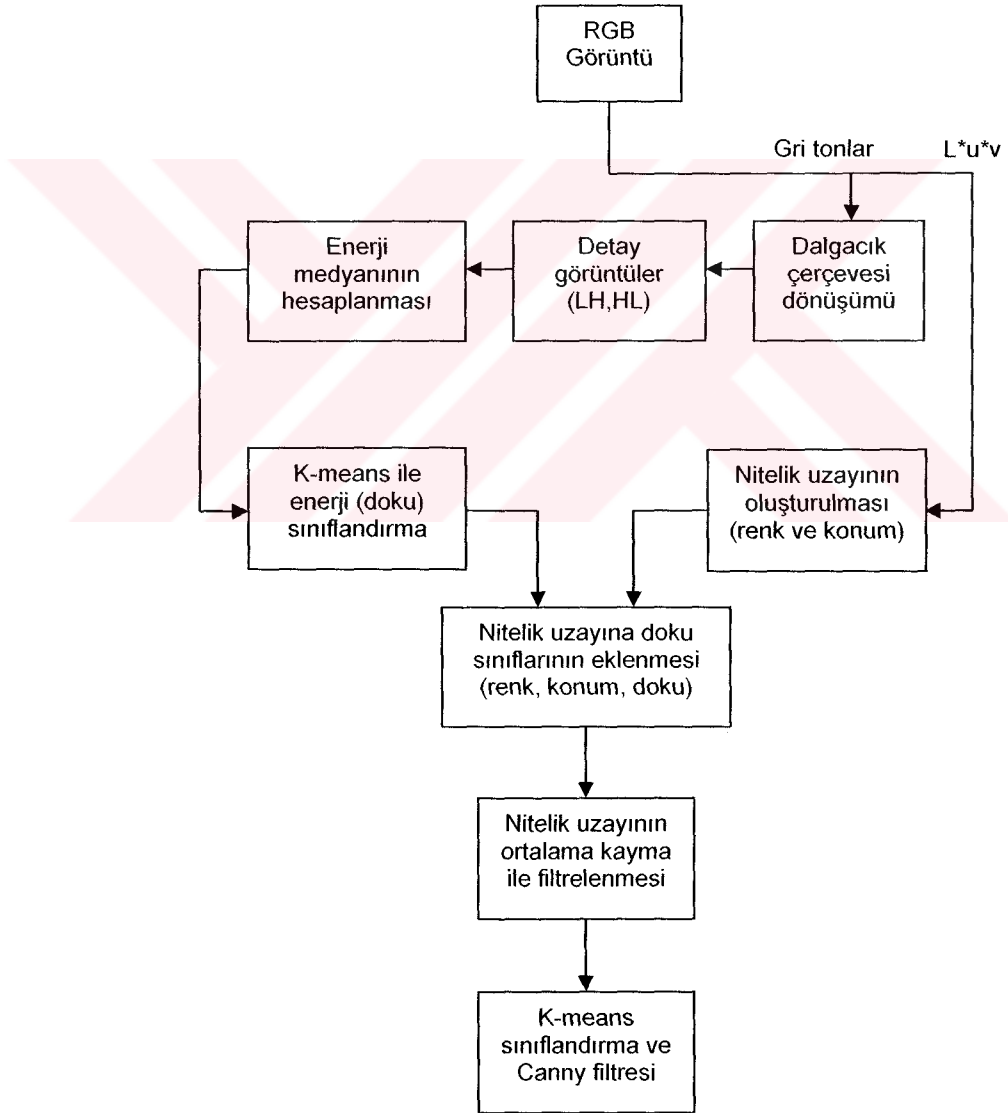
Tezde sunulan çalışma iki kısımdan oluşmaktadır. Bu çalışmalar görüntü kesimlemesi ve nesne takibi ile ilgili yöntemlerdir. Bu bölümde kısımlar halinde, yöntemlere ilişkin araştırma bulguları ve detaylı açıklamaları sunulacaktır. İlk olarak geliştirilen renkli görüntü kesimleme yöntemi detaylarıyla açıklanacaktır. Daha sonra geliştirilen nesne takibi yöntemi sunulacaktır.

3.1. Geliştirilen Renkli Görüntü Kesimleme Yöntemi

Bu tezde sunulan görüntü kesimleme yöntemi düşük seviyeden bilgiler olan renk ve doku niteliklerine dayanmaktadır. Renkli görüntü kesimlemede ortalama kayma ile filtreleme yönteminin gösterdiği performans üstündür ve yöntem kolaylıkla uygulanabilmektedir. Bu yöntem genelde iyi sonuçlar vermesine rağmen kullandığı renk ve uzaysal bilgiler bazı durumlarda yeterli olmamaktadır. Bu nedenle sunulan çalışmada görüntülerdeki doku bilgisinin de ortalama kayma ile filtreleme algoritması ile birlikte kullanılabilmesi düşünülmüştür. Son yıllarda doku karakterizasyonu için kullanılan yaygın bir yaklaşım da kesikli dalgacık dönüşümüdür. Sunulan yöntemde görüntüdeki dokuların görüntü dönüşümünden bağımsız olarak analizini sağlayan dalgacık çerçeveleri kullanılmıştır. Ortalama kayma yönteminin klasik renk ve konum uzayına ilave bir nitelik olarak doku karakteristiği de eklenmiştir. Çeşitli görüntüler üzerinde uygulanan algoritma tatmin edici sonuçlar vermiştir ve bölüm sonunda bu sonuçlar tartışılmıştır.

3.1.1. Giriş

Dünyada bulunan nesnelerin ya da alanların hemen hemen hepsinde doku bilgisi bulunmaktadır ve görüntü kesimlemede böyle önemli bir niteliğin dikkate alınması iyi bir sonuç verecektir. Ancak doğada karşılaşılan dokular, genellikle perspektif, ışık değişimi ve deformasyondan dolayı düzgün dağılımlı değildir ve istatistiksel yollarla karakterize edilmeleri zordur. Bu nedenle sunulan yöntemde dokular yumuşak, yatay, dikey ve karmaşık olmak üzere 4 ana sınıfa ayrılmıştır. Sunulan yönteme ait algoritma blok diyagramı olarak Şekil 3.1’de verilmiştir.



Şekil 3.1 Sunulan kesimleme yöntemi

Ortalama kayma yöntemi gerçekten de çok kullanışlı bir analiz yöntemidir ve bir çok renkli kesimleme algoritmasında başarıyla kullanılmıştır. Ancak ortalama kayma ile filtreleme yapılırken karşılaşılan sorunlardan biri renkleri yakın ancak dokuları farklı bölgelerin kenarlarının filtreleme sonucunda düzgün olarak belirlenememesidir.

3.1.2. Doku Niteliğinin Çıkarımı

Herhangi bir gerçekleşmiş görü sisteminin gerçek dünya ile başarılı bir şekilde çalışması beklenir. Gerçek dünyadaki ortamlarda ise çoğunlukla doku bilgisi mevcuttur. Bu yüzden böyle bir sistem bu tip girişleri de kabul edip işleyebilmelidir. Aynı dokuya sahip bölgeleri algılamak ve farklı dokuya sahip bölgeleri ayırt etmek, yüzeyleri ve nesnelere belirlemeye yönelik ilk adımlardır. Bu işlem doku kesimleme olarak adlandırılır.

Doku analizinde çok çeşitli yaklaşımlarla uzun yıllarda çalışılmıştır. Çeşitli yöntemler doğrudan görüntünün gri tonlarını kullanarak doku analizi yapmıştır. Bu yöntemlere, gri ton co-occurrence matrisi⁽³⁴⁾, otokorelasyon fonksiyon analizi⁽³⁴⁾, genelleştirilmiş co-occurrence matrisleri⁽¹⁶¹⁾, ikinci mertebeden uzaysal ortalamalar⁽⁷³⁾ ve hem uzay hem de frekans ortamında iki boyutlu filtreleme^(41,80,162,163) örnek olarak verilebilir. Diğer yaklaşımlar dokulu görüntünün primitifler açısından organize edilmesi ya da temsil edilmesine dayanan sembolik bir seviyede çalışır. Bunun örneği Julesz'in^(39,164) çalışmasında ve dizimsel doku analizinde görülebilir. Doku ayırımında bazı doku analizi yöntemleri, uzaysal frekans kanalları (işaret işleme sırasında) ve algılamalı gruplama (sembolik kısımda) kullanılmıştır^(165,166). Dokuların modele dayalı analizi sıkça kullanılmış olan diğer bir yaklaşımdır. Bu yöntemler,

Markov alanları^(167,168) ve fractal tabanlı modelleme⁽⁶¹⁾ gibi istatistiksel modelleme yöntemlerini içermektedir.

Dokusal özellikleri tanımlayan niteliklerin hesaplanması bu tip yaklaşımların çoğunun temelini oluşturur. Julesz^(169,170) önceleri ikinci mertebeden istatistiklerle özdeş olan doku çiftlerinin insanlar tarafından dikkatlice ayırlamayacağını varsaymış ancak sonraları bu varsayımı çelişen örnekler vermiştir⁽³⁹⁾. Böyle doku çiftlerinin dikkatlice ayırt edilebilmesindeki en önemli faktör doku primitiflerinin belirli şekil özelliklerinin olmasıdır. Bunlar, texton olarak adlandırılan yakınlık, lineerlik, sonlanma vb. gibi özelliklerdir⁽³⁹⁾.

Doku karakterizasyonu için momentlerin kullanımı da alternatif bir yöntem olmuştur^(96,171,172). Tuceryan'ın⁽¹⁷²⁾ çalışmasında gri tonlu doku analizinde her piksel için altı adet moment kullanılmış ve bu momentler lineer olmayan bir dönüşümle birer nitelik olarak kullanılmıştır. Ancak binlerce pikselden oluşan bir resimde altı adet nitelik işlem süresini uzatmış ve bu piksel niteliklerinin sınıflandırılması sırasında kullanılacak olan altı boyutlu nitelik vektörü büyük bir işlemsel külfet getirmiştir.

İnsan görme sistemi karmaşık dokuları işleyememesine rağmen frekans alanındaki belirli bazı özelliklerinden dolayı farklı dokuları kolaylıkla algılayabilmektedir. Gabor filtrelerinin darbe cevapları insan algılamasına benzerdir ve uzay-frekans çözünürlükleri de uygundur. Çok kanallı Gabor filtreleri de doku analizinde uzun bir süre kullanılmıştır. Ancak filtrelerin parametreleri dokunun yayılım karakteristiğine uymadığı zaman alınan sonuçlar pek tatmin edici olmamıştır. Ayrıca bu tip yöntemlerdeki dezavantajlardan diğeri işlemsel olarak oldukça külfetli olmasının yanında düşük frekanslı bileşenlerin

değerlendirilmesindeki zorluktur⁽⁸³⁾. Bunlara ek olarak, Gabor filtre depolarının çıktıları karşılıklı ortogonal değildir, bu ise doku nitelikleri arasında benzer ilişkilerin kurulmasına ve istenmeyen sonuçlara yol açar. Son olarak, bu dönüşümler genellikle ters çevrilemezler, bu ise doku sentezinde uygulanabilirliklerini kısıtlar.

Bu problemler dalgacık teorisinin gelişmesi ve kesikli dalgacık dönüşümünün doku analizinde kullanılmaya başlanması ile büyük ölçüde ortadan kaldırılmıştır. Görüntü kesikli bir sinyal olduğundan dalgacık dönüşümünden bahsederken bu dönüşümün kesikli olduğunun kastedildiği anlaşılmalıdır. Bu yeni uzay-frekans analiz metodu ile doku niteliğini karakterize etmek için bir çok çalışma yapılmış ve dalgacık dönüşümünün değişik bir çok versiyonu kullanılmıştır.

Dalgacık dönüşümünün doku analizinde kullanılmasıyla ilgili yapılan ilk çalışma Mallat'a aittir. Mallat⁽⁸¹⁾ doku karakterizasyonu için piramit yapısındaki dalgacık dönüşümünü kullanmıştır. Piramit yapıli dalgacık dönüşümü sinyali daha düşük frekanslarında daha dar bant genişlikleri ile analiz eder ve asıl bilgiyi düşük frekans bölgelerinde taşıyan sinyallerin analizi için yeterlidir. Mallat'ın yaptığı bu çalışma bir çok çalışmaya öncülük etmiş ve piramit yapısının çok bantlı uzantısı olan dalgacık paketlerinin^(86,87) kullanılmasıyla genişletilmiştir. Ağaç yapıli dalgacık paket dönüşümünün kullanılması ise doku analizi için önemli bilgiler içeren farklı frekanslı bölgelerin ayrıştırılması için kullanılmıştır⁽⁸⁸⁾.

Dalgacık dönüşümü ile doku analizi yapılırken geleneksel yöntemlerde sinyal (yani görüntü) aşağı örneklenir ve filtrelerle konvolusyon işlemine tabi tutulur. Bunun sonucunda ayrıştırılan sinyalin uzunluğu orijinal sinyalin uzunluğunun $1/2^n$ katı kadardır (n burada ayrıştırma seviyesini temsil eder ve bir tamsayıdır). Görüntü için söz edilirse, ayrıştırılan görüntüdeki bir piksel orijinal görüntüdeki 2^n tane

pikseli temsil eder ve bu yüzden piksel tabanlı nitelik çıkarımı ve kesimleme yapılamaz.

Unser doku karakterizasyonu için yeni bir yaklaşım olan dalgacık çerçevelerini kullanmıştır. Bu yöntemde, doku görüntü dönüşümlerinden bağımsız olarak karakterize edilir. Bu özelliği ile doku istatistiğinin daha iyi yapılmasını ve bölge sınırlarında daha detaylı doku tanımlamasının yapılmasını sağlar. Dalgacık çerçevesi dönüşümü sadece filtre çıkışları sonrasında aşağı örnekleme yapılmaması yönünden normal dalgacık dönüşümünden farklıdır. Burada ayrıştırılan sinyal ile orijinal sinyalin uzunlukları aynıdır. Dolayısıyla piksel tabanlı nitelik çıkarımı yapılabilir. Hızlı iteratif bir yöntem olan dalgacık çerçevelerinin kullanımının, normal dalgacık dönüşümüne göre daha iyi sonuç verdiği Unser'in çalışmalarında görülmüştür.

Bu tezde doku, sınıflandırılmasında kullanılacak yöntemlerden en uygun olanı dalgacık dönüşümü olarak belirlenmiştir. Bu tercihin yapılmasında, yöntemin yeni ve popüler olmasının, geliştirmeye açık olmasının ve kolay uygulanabilirliğinin yanında literatürdeki diğer yöntemlerin (Gabor filtreleri, moment vs.) doku analizi konusunda yetersiz kalması ve sınırlarına ulaşmış olması da etkili olmuştur.

Ortalama kayma ile nitelik uzayı analizi gerçekten güvenli ve daha az kullanıcı kontrolü gerektiren bir şekilde yapılabilmektedir. Bu yüzden doku niteliğini de nitelik uzayına bir boyut olarak ekleyebilmek için dalgacık çerçevelerini kullanmak ve ayrıştırma filtresi olarak ta ortogonal filtreleri kullanmak en doğru seçenek olarak görülmüştür.

Doğadaki dokular ışık şartlarından, perspektiften ve deformasyondan dolayı tam olarak düzgün dağılımlı değildirler. Kesimleme çalışmamızın amacı doğal

görüntüleri işlemek olduğu için dokuyu sınıflandırırken temel olarak 4 sınıf kullanılmıştır. Bu sınıflar “yumuşak (dokusuz), yatay, düşey ve karmaşık” olarak isimlendirilir. Bu dört ana sınıfın kullanılmasının sebebi tipik olarak doğadaki tüm doku çeşitlerini temsil edebilmektir. Doku niteliğinde kullanılan bu sınıflara örnek olarak gökyüzü, deniz (yumuşak), zebra tüyü (yatay tekrarlı), jaguar postu (hem yatay hem düşey tekrarlı, yani karmaşık) verilebilir.

Kullanılacak olan dalgacık dönüşümü çeşidi ve ayrıştırma filtresi belirlendikten sonra dokunun nitelik çıkarımının nasıl yapılacağı önemli bir konudur. Çünkü Unser’in sunduğu kesimleme çalışmalarında dokular arasındaki sınırlar yakınında ve büyük bölgelerin iç kısımlarında hatalar görülmüş bu hataların ise doku niteliği çıkarımından kaynaklanmış olabileceği vurgulanmıştır⁽¹⁵⁰⁾.

Dalgacık dönüşümüne dayalı doku kesimleme yöntemlerinin çoğunda dokuyu karakterize etmek için genellikle alt bantlardaki dalgacık katsayılarının enerji ve entropi özellikleri kullanılmıştır. Katsayılar oldukça seyrek olduğundan dolayı pencereye dayalı tekniklerin kullanımı düzgün bir doku karakterizasyonu yapmak için gereklidir. Ağaç yapılı dalgacık dönüşümünde ise doğru ağaç dalını seçmek için alt kanallardaki görüntülerin en düşük varyansa sahip olanı ele alınmış ve yine katsayıların enerji, entropi ve olasılık dağılımı özellikleri ile nitelik çıkarımı yapılmıştır⁽⁸⁵⁾. Ancak bu işlem oldukça uzun hesaplamalar gerektirmektedir.

Bu tezdeki doku karakterizasyonunda alt bantlardaki küçük bir pencere operatörü içerisindeki dalgacık katsayılarının enerjilerinin medyan değeri kullanılmıştır. Medyanın seçilmesindeki sebep bölgeler arasındaki sınır geçişlerinde ilgili olan dokuları süzücü etki yapmasından dolayıdır⁽¹⁷³⁾. Böyle bir durumda bölge sınırından kaynaklanan dalgacık katsayılarındaki artış bölgenin kenarı boyunca


yoğunlaştırılır ve medyan operatörü tarafından işleme alınmaz. Ortalama, medyan ve maksimum operatörleri arasında yapılan denemeler, maksimum operatörünün güvenilir sonuçlar verdiğini ortalamanın ise önemli bir yumuşatma sağladığını ancak sınır boyunca yanlış doku karakterizasyonuna sebep olduğunu, medyan operatörünün ise üstün sonuçlar verdiğini göstermiştir.

Pencere operatörüne dayalı doku karakterizasyonunda dikkat edilmesi gereken önemli bir nokta da pencere genişliğidir. Doku, ölçeğe bağımlı bir özellik olduğu için pencere boyutları yerel doku karakterini algılayabilecek kadar geniş olmalı fakat sınır etkilerinin yok olmasına sebep olacak kadar da büyük olmamalıdır. Küçük pencere boyutunun kullanılmasını savunan çalışmanın⁽¹⁷³⁾,nin aksine denemelerimizde görüntüdeki dokunun büyüklüğüne de bağlı olarak genellikle 21x21'lik pencere büyüklüğünün yeterli sonuç verdiği görülmüştür. Bu fark, kullandığımız dalgacık dönüşümü yönteminde (dalgacık çerçevesi) aşağı örnekleme yapılmaması, dolayısıyla alt banttaki görüntülerin boyutlarının azalmamasından dolayıdır.

3.1.3. Nitelik Uzayının Ortalama Kayma Yöntemi ile Analizi

Renk bilgisi doku temsilinde önemli bir bileşen olmayıp asıl bilgi gri tonlardan elde edilir. Sunulan doku analizi yönteminde ilk adım renkli görüntüyü gri ton olarak ele alıp yukarıda değinilen 4 sınıfa ayırmaktır. Renkli görüntünün gri tonları R, G ve B değerlerinin ortalaması alınarak elde edilmiştir. Bu gri ton resim için doku analizi ise MATLAB 6.5 yazılımı kullanılarak biortogonal 6.8 dalgacık dönüşümü çerçevesiyle yapılmıştır. Doku niteliğini asıl karakterize eden bilgi orta frekanslı bölgelerdedir⁽¹⁷³⁾. Bu yüzden çalışmamızda, alt bant görüntülerinden

yalnızca orta frekanslı bölgeler olan yatay (LH) ve dikey (HL) ayrıntıya sahip görüntüler kullanılmıştır. LL ve HH kanalları doku hakkında fazla bilgi içermediğinden bunların kullanılması gerekli değildir. Bu alt bant görüntülerinde pencere operatörü kullanılarak dalgacık katsayılarının kareleri enerji olarak hesaplanır ve medyan operatörü ile yatay ve dikey ayrıntıdaki görüntüler için enerji görüntüsü oluşturulur. Bundan sonraki adım bu iki görüntüden sözü edilen dört ana sınıfın belirlenmesidir. Bunun için her iki görüntü K-means algoritması ile enerji sınıflandırılmasına tabi tutulmuştur. K-means iki öbek oluşturacak şekilde uygulandığında, yüksek enerjili bölgeler doku özelliğine sahip iken düşük enerjili bölgeler doku niteliğine sahip olmayan yumuşak bölgeler olarak belirlenmiştir. Daha sonra, dokulu ve yumuşak olarak sınıflandırılan her iki görüntü piksel bazında karşılaştırılarak yalnızca yatay doku, yalnızca dikey doku, hem yatay hem de dikey (karmaşık) doku ve yalnızca yumuşak doku olarak etiketlenmiştir. Dolayısıyla bu bölgelerde bulunan pikseller de nitelik uzayında kullanılmak üzere sınıflara ayrılmış olurlar. Bu işlem Şekil 3.2’de görülmektedir. Orijinal görüntüye ait yatay ve dikey doku niteliklerinden oluşturulan diğer sınıflar değişik gri tonlarla gösterilmektedir.



Şekil 3.2 (a) Orijinal görüntü (b) Yatay dokuya sahip bölgeler siyah yumuşak dokulu yerler beyaz renklidir (c) Dikey dokuya sahip bölgeler beyaz yumuşak dokuya sahip bölgeler ise siyah renktedir (d) Elde edilen 4 doku sınıfı farklı gri tonlarla gösterilmiştir

Önceki bölümlerde ortalama kayma yönteminin temel özellikleri ve nasıl uygulanacağı verilmiştir. Ortalama kayma ile filtreleme yapıldığında bir görüntüde temel olarak yakın renge sahip bölgeler arasında homojenlik sağlanırken farklı renkli bölgeler ve kenarlar korunur. Ancak düzgün bir bölge ile dokulu (yatay, düşey, karma) bir bölge yakın renklere sahip olduğunda ortalama kayma filtreleme yönteminde ilave bilgiler kullanılmadığında bölgelerin kenarlarının kaybolması çözülmesi gereken bir problem olarak ortaya çıkar

Şu da bir gerçektir ki kesimleme işleminde ne kadar çok nitelik kullanılırsa sonuç o kadar güvenli olmaktadır. Neyse ki ortalama kayma analizi, gerekli ilave her türlü bilgiyi nitelik uzayına eklemeye ve bunları işlemeye izin veren oldukça kullanışlı bir yöntemdir. Örneğin görüntülerdeki hareketli nesnelerin kesimlenmesi sırasında renk bilgisine ilave olarak değişen (hareket eden) piksellere ait hareket bilgisi de nitelik vektörüne eklenebilir⁽¹⁷⁴⁾. Tezde yapılan kesimleme çalışmasında her bir pikselin nitelik vektörüne doku analizi sonucu elde edilen sınıf bilgileri eklenmiştir. Dolayısıyla ortalama kayma analizinde kullanılacak olan nitelik vektörü 2 adet konum, 3 adet renk ve 1 adet te doku bilgisinden oluşmak üzere 6 boyutlu olacaktır. Böyle bir nitelik uzayı klasik ortalama kayma yönteminden farklı olarak sadece h_s ve h_r alanının içerisinde bulunan piksellerin değil aynı doku niteliğine sahip olan piksellerin analiz edilmesini sağlayacaktır. Piksellere ait renk uzayı doğrusal bir özelliğe sahip olmasından dolayı $L*u*v^*$ olarak kullanılmıştır. $L*u*v^*$ renk uzayı RGB renk uzayına göre daha lineerdir ve RGB uzayındaki vektörlerin belirli bir katsayı matrisi ile çarpılması sonucu elde edilir.

Uygulamalarımızda genellikle 480x320 boyutlarında renkli resimler kullanılmıştır. Uygulama sonuçlarına bakıldığında ilave edilen bu doku bilgilerinin

ortalama kayma ile filtreleme sırasında bölge sınırları arasındaki geçişlerde düzeltici bir etki yaptığı görülmüştür.

Ortalama kayma ile görüntü filtrelendikten sonra, kesimleme işleminde hala popüler bir öbekleme yöntemi olan k-means kullanılmıştır. Filtrelenmiş görüntü piksellerine ait $L*u*v^*$ uzayındaki renk ve doku bilgilerinden oluşan bu nitelikler k-means algoritmasına kesimleme amacı ile gönderilir. Burada piksellerin konumsal bilgilerinin kullanılmadığına dikkat edilmelidir. Filtrelenmiş görüntü k-means yöntemi ile kesimlendikten sonra elde edilen sınırlar orijinal resmin üzerinde gösterilmiştir. Sınırlar elde edilirken Canny kenar sezici filtresi kullanılmıştır ve küçük bölgeleri belirleyen önemsiz sınırlar manuel olarak yok edilmiştir.

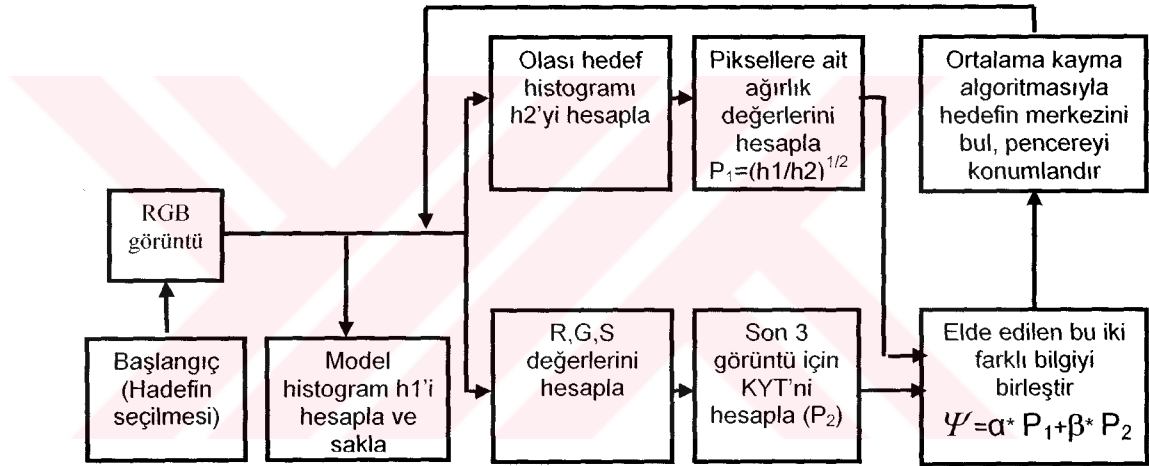
3.2. Geliştirilen Nesne Takibi Yöntemi

Bu tezde ikinci olarak, görüntü dizilerinde ortalama kayma algoritması kullanılarak yapılan nesne takibi çalışması sunulmaktadır. Ortalama kayma algoritması nesnenin (veya hedefin) istatistiksel renk dağılımını kullanan, parametrik olmayan bir yöntemdir. Bazı durumlarda takip edilecek nesne ve içinde bulunduğu ortamın rengi, dolayısıyla renk olasılık dağılımları çok benzer olabilmektedir. Bu gibi durumlarda nesne takibi için sadece renk dağılımı bilgisini kullanmak iyi sonuç vermeyecektir. Bu problemin üstesinden gelmek için, sunulan yöntemde, değişim algılamak üzere kernel yoğunluk tahmini yöntemine dayalı istatistiksel ön-arka plan modelleme yöntemi kullanılmaktadır. Daha güvenilir bir nesne takibi çalışması yapabilmek amacı ile renk dağılımına ek olarak, bu istatistiksel değişim bilgisi de, geliştirilmiş ortalama kayma algoritması içerisinde birleştirilmiştir. Yönteme ait algoritma Şekil 3.3'te görülmektedir. Geliştirilen yöntemin daha iyi performans

gösterdiği gerçek hayattan alınan görüntü dizileri üzerinde uygulamalar yapılarak kanıtlanmış ve 4. bölümde sonuçlar karşılaştırmalı olarak sunulmuştur.

3.2.1. Giriş

Sunulan çalışma üç ana kısımdan oluşmaktadır. Bu kısımlar, başlangıç ve istatistiksel model geliştirme, model ağırlık görüntüsünü oluşturma ve son olarak, birleştirilmiş ağırlık görüntüsüne ortalama kayma algoritmasının uygulanmasıdır. Bu kısımlar aşağıda ayrıntılı olarak sunulmuştur. Algoritmaya ait blok diyagram Şekil 3.3 te verilmiştir.



Şekil 3.3 Geliştirilen Nesne Takibi Algoritması

3.2.2. Başlangıç ve İstatistiksel Model Geliştirme

Takip edilecek hedefi belirlemek için, RGB formatındaki görüntünün ilk karesinde hedefi içerisine alacak şekilde dikdörtgen bir seçim çerçevesi etkileşimli olarak seçilir. Böylece arama penceresi belirlenir ve hedefi modellemek için gerekli

istatistiksel bilgi (histogram olarak temsil edilen renk dağılımı) bu pencere içerisinde hesaplanabilir.

3.2.3. Örnek Ağırlık Görüntüsünün Oluşturulması

Bu aşamada ortalama kayma algoritmasında kullanılacak olan örnek ağırlık görüntüsü oluşturulmaktadır. Bu ağırlık görüntüsü iki adet farklı bilgi kaynağı kullanılarak oluşturulmuştur. İlk kaynak renge dayalı nesne görünüm modelidir. RGB renk uzayında elde edilen nesneye ait renk histogramı kullanılarak arama penceresi içerisindeki her bir pikseldeki nesne renginin benzerlik oranı hesaplanır.

Bu hesaplama histogram benzerlik ölçütü olan Bhattacharyya katsayısı kullanılarak

yapılır. Hedefe ait model histogramı $\hat{q} = \{\hat{q}_u\}_{u=1..m}$, ve $\sum_{u=1}^m \hat{q}_u = 1$, y noktasındaki

hedefe ait olduğu tahmin edilen histogram $\hat{p}(y) = \{\hat{p}_u(y)\}_{u=1..m}$ ve $\sum_{u=1}^m \hat{p}_u(y) = 1$ ise

Bhattacharyya katsayısı $\hat{\rho}(y)$ (m aralıktan oluşan histogram için) aşağıdaki gibi elde edilir⁽¹⁷⁵⁾.

$$\hat{\rho}(y) \equiv \rho[\hat{p}(y), \hat{q}] = \sum_{u=1}^m \sqrt{\hat{p}_u(y) \hat{q}_u} \quad 3.1$$

Bu katsayı iki histogramın benzerlik ölçütü olarak kullanılır. Katsayı (normalize edilmiş histogramlar için) 1'e ne kadar yakınsa iki histogram birbirine o kadar benzerdir. Her bir nokta için histograma dayalı ağırlık aşağıdaki gibi tanımlanır⁽¹⁷⁶⁾.

$$w = \sqrt{\frac{\hat{q}_u}{\hat{p}_u(y)}} \quad 3.2$$

Bu ağırlık değeri her bir piksel ile ilişkilendirilerek nesne pikselleri bazında olasılık dağılımı elde edilmiş olur.

Örnek ağırlıklarının oluşturulmasında kullanılan ikinci bilgi ise bahsedilen kernel yoğunluk tahmini ile elde edilen hareket bilgisidir. Ardışık görüntü karelerindeki aynı piksele ait renk bilgileri (gözlemleri) $x_1, x_2 \dots x_N$ verilmiş olsun, piksele ait renk olasılık yoğunluğu her renk kanalı için (RGB) 2.31. eşitliği kullanılarak bulunabilir. Her pikselin rengi 3 boyutlu vektör olarak $x=[r \ g \ s]$ temsil edilir. Burada $r=R/(R+G+B)$, $g=G/(R+G+B)$ ve $s=(R+G+B)/3$ tür. Kromatik renkler ışık değişiminin bozucu etkisini minimize ettiği için kullanılmışlardır⁽¹⁵⁷⁾. Gaussian olacak şekilde bir kernelin seçilmesiyle bir piksel için tahmin edilen yoğunluk 3 boyutlu olarak 2.32. eşitliği kullanılarak hesaplanır.

$$\tilde{p}(r, g, s) = \frac{1}{N} \sum_{i=1}^N e^{-\frac{1}{2} \left(\frac{r-r_i}{\sigma_r} \right)^2} e^{-\frac{1}{2} \left(\frac{g-g_i}{\sigma_g} \right)^2} e^{-\frac{1}{2} \left(\frac{s-s_i}{\sigma_s} \right)^2} \quad 3.3$$

3.3. eşitliğine göre, düşük olasılık değerleri değişim (hareket) gösteren piksellere, yüksek olasılık değerleri ise değişme göstermeyen piksellere karşılık gelmektedir. N yoğunluk tahmininde kullanılacak olan gözlem sayısı olup çalışmalarımızda bu sayı 3 olarak alınmıştır.

Son olarak ağırlık görüntüsünü oluşturmak için ayrı ayrı olarak elde edilen bu iki bilgi birleştirilmelidir. Birleştirme işlemi aşağıdaki formüle göre yapılmıştır,

$$\psi(x, y) = \alpha p_1(x, y) + \beta p_2(x, y) \quad 3.4$$

Bu denklemden $\psi(x, y)$, elde edilen ağırlık görüntüsü olup ortalama kayma algoritmasında kullanılacaktır. $p_1(x, y)$ ise görüntüdeki (x, y) noktasındaki renk tabanlı olasılık yoğunluğundan elde edilen ağırlık değeridir. Benzer şekilde $p_2(x, y)$ de görüntüdeki (x, y) noktasındaki harekete ait olasılık yoğunluğundan elde edilen

ağırlık değeridir. Son olarak α ve β da bu iki ayrı bilgiyi birleştirmek için kullanılan katsayılar olup $\alpha + \beta = 1.0$ dir.

3.2.4. Birleştirilmiş Ağırlık Görüntüsü ve Ortalama Kayma Yöntemi ile Nesne Takibi

Renk ve hareket olasılık dağılımlarının farklı ağırlık katsayıları ile birleştirilmesiyle elde edilen örnek ağırlık görüntüsü ortalama kayma algoritmasında kullanılarak nesne takip edilebilir. Bu örnek ağırlıkları ön plandaki nesneye ait pikseller yüksek ağırlık değerlerine, nesneye ait olmayan pikseller ise düşük ağırlık değerlerine sahip olacak şekilde histograma dayalı olarak belirlenirler^(177,178). Ortalama kayma algoritması da kernel ağırlıkları kümesi ile yerel komşuluk içerisinde bulunan bu ağırlık değerlerini işleyerek görüntüdeki nesne merkezinin konumunu belirler. Sunulan çalışmada bu ağırlık değerleri hem renk hem de hareket bilgisini içermektedir.

Bu birleştirilmiş ağırlık değerleri de kullanılarak ortalama kayma algoritmasında temel olarak x görüntü noktaları konum vektörünün yeni bir x_n konumuna olan Δx uzaklığı iteratif olarak hesaplanır.

$$\Delta x = x_n - x \text{ olup aşağıdaki gibi hesaplanır.} \quad 3.5$$

$$\Delta x = \frac{\sum_{s \in S} K(s-x)w(s)s}{\sum_{s \in S} K(s-x)w(s)} - x = \frac{\sum_{s \in S} K(s-x)w(s)(s-x)}{\sum_{s \in S} K(s-x)w(s)}$$

Burada, K kernel fonksiyonu (genellikle gauss merkezli), w piksellere ait ağırlık (weight) fonksiyonudur ve toplamlar x konumu çevresini kapsayan S penceresi üzerinden yapılır ($s \in S$).

4. TARTIŞMA VE SONUÇ

Geliştirilen yönteme ait sonuçlar ve tartışmalar bu bölümde verilecektir. Çalışma iki kısımdan oluştuğu için her bir kısmın tartışma sonuçları kendi başlığı altında verilmiştir. İlk olarak geliştirilen görüntü kesimleme yöntemine, daha sonra ise geliştirilen nesne takibi yöntemine ait sonuçlar verilmiştir.

4.1. Geliştirilen Kesimleme Yöntemi

4.1.1. Tartışma

Şimdiye kadar yapılan çalışmalara baktığımızda, doku bilgisinin ortalama kayma yönteminin nitelik uzayına aktarılmasına ilişkin bir çalışmanın yapılmadığı görülmüştür. Yapılan çalışma bu yönüyle doku analizinde de yeni bir yaklaşımdır. Farklı nitelikteki verilerin nasıl bir arada kullanılabilceği ve birleştirilebileceği bu aşamada önemli bir kriterdir. Bu amaçla, nitelik uzayına doku bilginin nasıl aktarılacağına dair bir örnek teşkil edilmektedir. Yöntemde nitelik uzayını sınıflandırma amacı ile k-means algoritması kullanılmıştır. Sonuçlardan da görülebileceği gibi sunulan yöntemin güvenilirliği bazı durumlarda standart ortalama kayma ile kesimleme algoritmasından daha yüksektir.

Bu aşamada k-means yöntemi ile filtreleme sonuçlarının öbeklenerek kesimlenmiş görüntünün elde edilmesi yeterli olmuşsa da, daha iyi sonuçlar alınması açısından, yöntemin kendine özgü parametreleriyle uyum içinde çalışacak yeni bir kesimleme algoritmasının geliştirilmesi de ileriki çalışmalar için gerekli olacaktır.


4.1.2. Sonuç

Geliştirilen yönteme ait sonuçlar bu kısımda sunulmuştur. İki adet sonuç ise standart ortalama kayma filtreleme yöntemi ile karşılaştırılmak üzere sunulmuştur.

Şekil 4.1.c ve Şekil 4.1.e' karşılaştırıldığında sunulan yöntemin sınır geçişlerindeki hassaslığı daha iyi görülmektedir. Standart ortalama kayma yönteminde öndeki çalı ve arkadaki duvar rengi yakın olduğundan dolayı h_r parametresine (renk yarıçapına) uyduğu için hem duvar bölgesine hem de çalıya ait pikseller filtreleme işlemine tabi tutulmuştur. Oysa sunulan yöntemde doku bilgisine sahip olan çalı ile dokusuz bir bölge olan duvar pikselleri aynı anda işleme alınmayıp filtreleme olayı yalnızca çalıya ait pikseller ve yalnızca duvara ait pikseller için yapılacaktır. Yani, piksel hangi bölgeye ait ise yakınsama noktası o bölge içerisinde sınırlandırılmış olacaktır.

Yine benzer şekilde Şekil 4.2.c ve Şekil 4.2.e.'den görüleceği gibi sunulan yöntemde bölge kenarları daha doğru tespit edilmiştir. Bu görüntü ortalama kayma yöntemi ile filtrelenirken çalılara ait bölge pikselleri ile çimenlere ait bölge pikselleri h_r parametresinin de etkisi ile renk gradyentinden dolayı iki bölge sınırı arasında bir bulanık bölge meydana gelmiştir. Oysa sunulan yöntemle yapılan filtrelemede sınırlar daha doğru olarak belirlenmiştir.


Yöntem farklı dokulu fakat benzer renkli bölgelerin kesimlemesinde iyi sonuçlar vermiştir. Tersî durumlar içinde aynısı söz konusudur. Yani aynı dokuya sahip fakat farklı renkli bölgelerin filtrelenmesinde ise doku niteliği fazla önemli bir rol oynamayacaktır. Böyle bir durumda yöntem bilinen ortalama kayma yöntemi ile aynı şekilde çalışarak bu bölgeleri h_r parametresi ile belirlenen komşuluk sınırı içerisinde filtreleyecek ve birbirinden ayırt edecektir.



Şekil 4.1 (a) Orijinal resim (b) $h_s=8$, $h_r=20$ için ortalama kayma ile filtreleme (c) öbek sayısı= 5 için kesimleme sonucu (d) Ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 8x8) (e) öbek sayısı= 5 için kesimleme sonucu




(a)




(b)



(c)




(d)




(e)


Şekil 4.2 (a) Orijinal resim (b) $h_s=8$, $h_r=20$ için ortalama kayma ile filtreleme (c) öbek sayısı= 5 için kesimleme sonucu (d) Ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 8x8) (e) öbek sayısı= 5 için kesimleme sonucu



(a)




(b)




(c)

Şekil 4.3 (a) Orijinal resim (b) $h_s=6$, $h_r=20$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 10x10) (c) Öbek sayısı = 6 için kesimleme sonucu



(a)




(b)



(c)


Şekil 4.4 (a) Orijinal resim (b) $h_s=8$, $h_r=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 10×10) (c) Öbek sayısı = 6 için kesimleme sonucu



(a)



(b)



(c)


Şekil 4.5 (a) Orijinal resim (b) $h_s=8$, $h_r=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 21×21) (c) Öbek sayısı = 5 için kesimleme sonucu



(a)




(b)



(c)

Şekil 4.6 (a) Orijinal resim (b) $h_s=8$, $h_r=16$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 20×20) (c) Öbek sayısı = 5 için kesimleme sonucu



(a)




(b)



(c)


Şekil 4.7 (a) Orijinal resim (b) $h_s=6$, $h_r=10$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 7×7) (c) Öbek sayısı = 4 için kesimleme sonucu



(a)



(b)



(c)


Şekil 4.8 (a) Orijinal resim (b) $h_s=8$, $h_r=15$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 55x55) (c) Öbek sayısı = 3 için kesimleme sonucu



(a)



(b)



(c)

Şekil 4.9 (a) Orijinal resim (b) $h_s=8$, $h_r=16$ için ortalama kayma ve doku niteliği kullanılarak yapılan filtreleme (pencere boyutu 20×20) (c) Öbek sayısı = 5 için kesimleme sonucu

4.2. Geliştirilen Nesne Takipçisi


4.2.1. Tartışma

Sunulan çalışmanın amacı doğal çevrede, özellikle nesne ve arka plan renk dağılımlarının oldukça yakın olduğu, benzer renkli bölgelerde ya da karmaşık ortamlarda güvenli ve sağlam bir nesne takibi yapabilen bir algoritma gerçekleştirmektir. Ormanda kamufle edilerek ilerleyen bir tankın takip edilmesi bu amaca bir örnek olarak verilebilir.


Yapılan çalışmanın üstünlüğünü ve güvenilirliğini göstermek için yapay ve gerçek görüntü dizilerinde denemeler yapılmıştır ve sonuçların sayısal analizi de sunulmuştur.

Sunulan yöntemin performansını göstermek için bir aracın yolda ilerlemesini canlandıran bir görüntü dizisi hazırlanmıştır. Nesne (araç) ve arka plan (yol) arasında yakın renk dağılımları oluşturmak için aracın gövdesi yol ile aynı renge boyanmıştır. Elimizde araç resmi ayrı olarak bulunduğu için bu resim farklı (x,y) değerleri ile yol üzerinde hareket ettirilerek yapay görüntü oluşturulmuştur. Bu (x,y) koordinatları da sonucun sayısal analizinde gerçek konum bilgileri olarak kullanılmak üzere saklanmıştır. Sunulan yöntem bu görüntü dizisi ile test edilmiştir. Karşılaştırma yapmak için, dizi $\alpha=1$ ve $\beta=0$ için yani standart ortalama kayma yöntemiyle de test edilmiştir. Standart ortalama kayma algoritmasına ait sonuçlar Şekil 4.10'da sunulmuştur. Şekil 4.10.a.'daki ilk satır takip edilen araca ait örnek görüntüler içermektedir. İkinci satır ise her kare için yerel ağırlık görüntüsünü göstermektedir. Sayısal sonuçlar ise Şekil 4.10.b'de verilmiştir. Şekil 4.10.b'deki ilk grafikte gri çizgi nesne merkezine ait gerçek konumları göstermektedir. Siyah çizgi ise ortalama kayma ile belirlenen nesne merkezinin konumlarını göstermektedir. İkinci ve üçüncü

grafikte, gerçek konumlara göre belirlenen takip hataları X ve Y konumları için gösterilmiştir. Dikkat edilirse standart ortalama kayma algoritması yaklaşık 200. kareden itibaren aracı takip etmekte hatalı davranmıştır bu yüzden X ve Y yönlerindeki hatalar grafikten de görüldüğü gibi nispeten büyüktür.



(a)




(b)


Şekil 4.10 $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen araç Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir

Aracın hareketine ait bu görüntü dizisi, sunulan yöntemin performansını göstermek için kullanılmıştır. Ortalama kayma için renk ve hareket bilgisinin yoğunluk tahminlerinin birleştirme katsayıları $\alpha=0.5$ ve $\beta=0.5$ olarak ayarlanmıştır. Aynı zamanda α ve β nin farklı değerleri için farklı görüntü dizilerinde denemeler

yapıldığında β 'nin α 'dan büyük seçildiği durumlar için harekete ait olasılık yoğunluğu daha baskın olacağı için hem x hem de y eksenindeki hataların daha büyük olduğu görülmüştür. Benzer olarak α 'nın β 'dan büyük seçildiği durumlar için ise renge ait olasılık yoğunluğu daha baskın olacağı için hem x hem de y eksenindeki hataların daha büyük olduğu görülmüştür. En uygun sonuçlar birleştirme faktörlerinin eşit alındığı ($\alpha=\beta=0.5$) durumda elde edilmiştir. Sonuç Şekil 4.11'de verilmiştir.



(a)



(b)

Şekil 4.11 $\alpha=0.5$ ve $\beta=0.5$ için sunulan yönteme ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen araç Alt satır: Her görüntü karesi için ağırlık görüntüleri. (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir


Şekil 4.11.a.'daki ilk satır aynı aracın hareketine ait dizinin takip sonuçlarını göstermektedir. İkinci satırda ağırlık görüntüsü verilmiştir ve görüldüğü gibi yerel pencere içerisindeki arka plan (yol) ve ön plan (araç) Şekil 4.10'daki sonuca göre daha iyi ayırt edilmektedir. Bu, nesne ve ortam aynı renk dağılımlarına sahip iken standart ortalama kayma algoritmasının nesneyi güvenli ve hassas bir şekilde takip edemeyeceğini gösterir. Bu problemi gidermek için nesnenin renk dağılımı arka planın renk dağılımından iyi bir şekilde ayırt edilmelidir. Sunulan yöntem, standart ortalama kayma algoritmasında hareketin kernel yoğunluk tahminini kullanarak bu ayrımın iyi bir şekilde yapılmasını sağlar. Şekil 4.11b.'de ise sayısal olarak takip sonuçları görülmektedir. İlk grafikte, araç merkezine ait gerçek konumlar gri çizgi, sunulan yönteme ait takip sonuçları ise siyah çizgi ile gösterilmiştir. Gerçek konumlardan x ve y doğrultularındaki sapma değerleri, görüldüğü gibi Şekil 4.10.b'de aynı görüntü dizisi için standart ortalama kayma algoritması ile elde edilen sapmalardan daha düşüktür. Standart ortalama kayma ile sunulan yöntemin sayısal karşılaştırılması Çizelge 4.1'de verilmiştir. Bir görüntü dizisi için sunulan yöntemin toplam performansını değerlendirebilmek için toplam ortalama karesel hata (MSE) ve hem x hem de y yönlerinde ortaya çıkan gerçek değerlerden maksimum sapmaları kullanılmıştır. Çizelge 4.1'den görülebileceği gibi sunulan yöntem ortalama karesel hata, x ve y yönlerindeki maksimum sapma açısından daha iyi performans göstermiştir.

Sunulan yöntemin güvenilirliğini ve hassaslığını daha da geniş bir uygulama ile göstermek için gerçek bir görüntü dizisi üzerinde çalışılmıştır. Bu görüntüde, Şekil 4.13.a.'da görüldüğü gibi beyaz bir fincan benzer renkli bir fon (beyaz çiçeklerin olduğu) üzerinde dairesel bir şekilde hareket ettirilmektedir. Şekil 4.13.a'nın ilk satırında standart ortalama kayma algoritması ile elde edilen takip


sonuçları gösterilmektedir. Görüldüğü gibi standart ortalama kayma algoritması nesne ve fon arasındaki benzer renk dağılımından dolayı nesneyi takip etmede başarısız olmuştur. İkinci satır kernel fonksiyonu ile elde edilen ağırlık görüntüsünü gösterir. Nesnenin konumlarına ait gerçek değerler (gri çizgi) manuel olarak elde edilmiş ve Şekil 4.12’de görülen sayısal analiz için kullanılmıştır. Her iki yöndeki hata değerleri ortalama kayma algoritması 20. kareden sonra nesneyi takip edemediği için çok büyüktür.

Çizelge 4.1 Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının yapay görüntü dizisi için sayısal analizi.

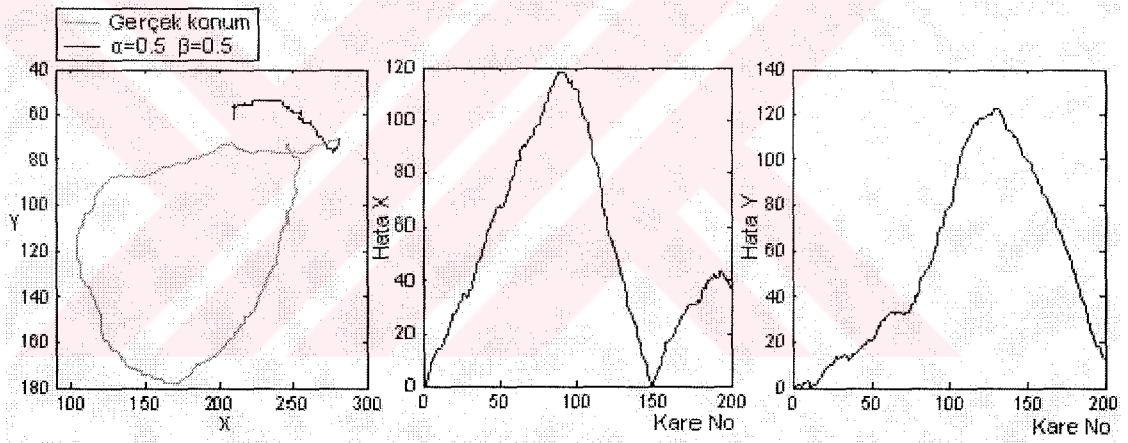
| Araba videosu | α | B | MSE X | MSE Y | X yönünde maksimum hata | Y yönünde maksimum hata |
|-------------------------|----------|-----|---------|--------|-------------------------|-------------------------|
| Standart ortalama kayma | 1.0 | 0.0 | 136.670 | 3.7501 | 21.52 | 6.662 |
| Sunulan çalışma | 0.5 | 0.5 | 34.197 | 0.1757 | 8.51 | 1.002 |



Şekil 4.12 Yapay video görüntüsü için iki yönetime ait X ve Y yönündeki hataların karşılaştırılması




(a)

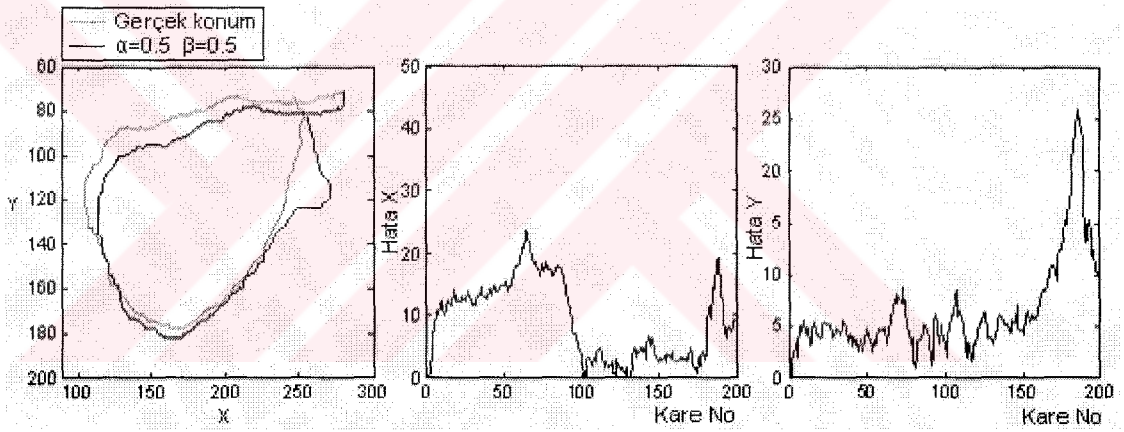


(b)

Şekil 4.13 $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen fincan (Dikkat edilirse 20. kareden itibaren takip edilememiştir) Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir



(a)

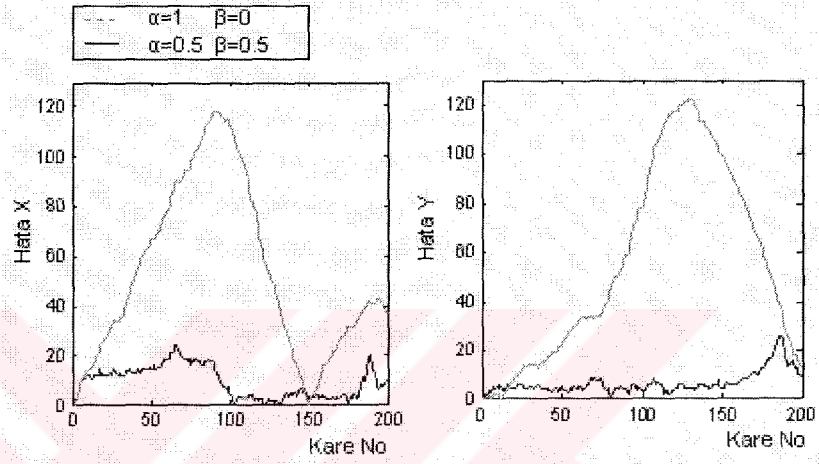


(b)

Şekil 4.14 $\alpha=0.5$ ve $\beta=0.5$ için sunulan yöntemle ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler ve takip edilen fincan, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir

Çizelge 4.2. Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının gerçek görüntü dizisi için sayısal analizi.

| Çiçek-fincan videosu | α | β | MSE X | MSE Y | X yönünde maksimum hata | Y yönünde maksimum hata |
|-------------------------|----------|---------|--------|--------|-------------------------|-------------------------|
| Standard ortalama kayma | 1.0 | 0.0 | 4040 | 4619.5 | 117.82 | 121.97 |
| Sunulan çalışma | 0.5 | 0.5 | 122.65 | 62.63 | 23.85 | 25.88 |




Şekil 4.15 Fincan görüntüsü için iki yönteme ait X ve Y yönündeki hataların karşılaştırılması


Aynı görüntü dizisi $\alpha=\beta=0.5$ değerleri için sunulan yöntemle test edilmiştir. Bu değerlerin seçilme yöntemi daha önce açıklanmıştır. Şekil 4.14'te sonuçlar görülmektedir. Sunulan nesne takipçisi fincanı görüntünün başından sonuna dek hatasız takip edebilmiştir. Sunulan takipçinin yörüngeleri (siyah çizgi) ve nesneye ait gerçek koordinat değerleri (gri çizgi) ve gerçek değerlerden sapmalar (hatlar) Şekil 14.b'deki grafiklerden görülmektedir. Hata değerleri araç takibinin yapıldığı örneğe göre oldukça yüksektir. Bu nesneyi içeren yerel pencerenin boyutlarından kaynaklanmaktadır. Nesne takibi sırasında büyük pencere daha büyük sapmalara yol açarken küçük pencereler ise daha az sapmalara neden olmaktadır. Ortalama kayma

ve sunulan yöntemle ait sayısal analiz ve karşılaştırmalı grafik, Çizelge 4.2’de ve Şekil 4.15’te görülmektedir.

Sunulan yöntemin güvenilirliğini göstermek üzere bilgisayarlı görüye dayalı insan-bilgisayar etkileşimi (HCI – Human Computer Interaction) uygulamalarında karşılaşılan problemlerden olan insan yüz ve elinin takibi ele alınmıştır.



(a)

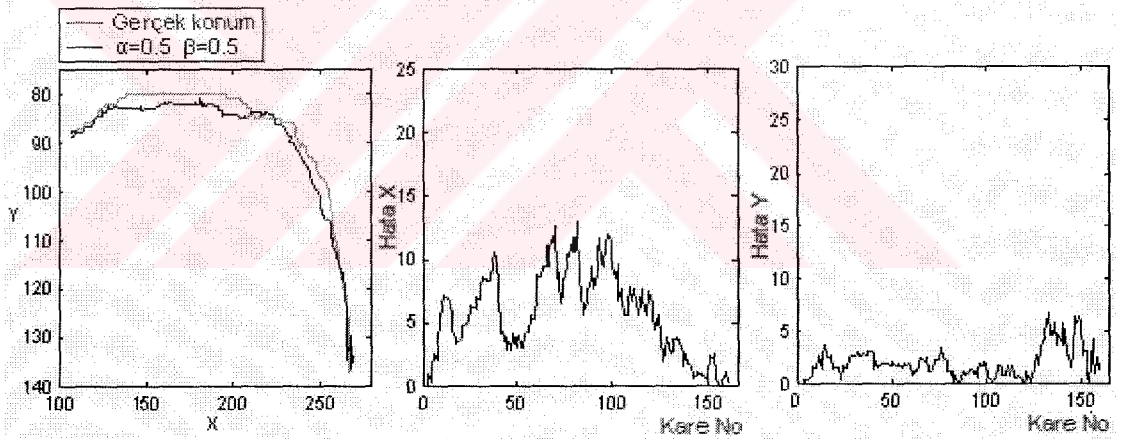


(b)

Şekil 4.16 $\alpha=1$ ve $\beta=0$ (standart ortalama kayma) için sonuçlar (a) Üst satır: Görüntü dizisinden örnekler, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir



(a)

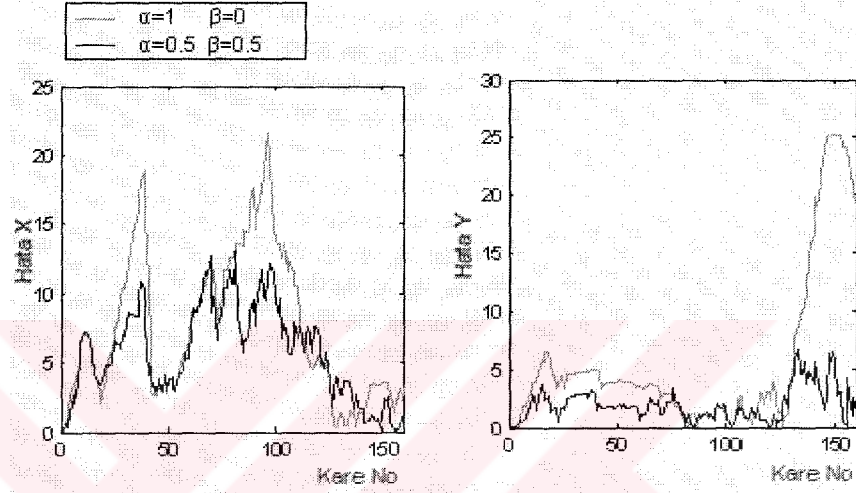


(b)

Şekil 4.17 $\alpha=0.5$ ve $\beta=0.5$ için sunulan yöntemle ait sonuçlar (a) Üst satır: Görüntü dizisinden örnekler, Alt satır: Her görüntü karesi için ağırlık görüntüleri (b) (Solda) Gerçek konumlar (gri çizgili) ve takip edilen konumlar (siyah çizgi), (Orta ve sağda) Takip sonucu oluşan X ve Y yönündeki hatalar görülmektedir

Çizelge 4.3 Sunulan yöntem ve standart ortalama kayma algoritmasına ait takip sonuçlarının el takibi görüntüsü için sayısal analizi.

| Hareketli el videosu | α | β | MSE X | MSE Y | X yönünde maksimum hata | Y yönünde maksimum hata |
|-------------------------|----------|---------|-------|--------|-------------------------|-------------------------|
| Standart ortalama kayma | 1.0 | 0.0 | 84.01 | 84.538 | 21.525 | 25.267 |
| Sunulan çalışma | 0.5 | 0.5 | 43.64 | 6.082 | 12.964 | 6.739 |



Şekil 4.18 HCI uygulaması için iki yönteme ait X ve Y yönündeki hataların karşılaştırılması

Takip problemi kişinin eli ile yüzü, aynı eksen üzerine geldiğinde yani üst üste geldiğinde ortaya çıkmaktadır. Bu durumda takipçi sadece renk bilgisini kullanırsa, yüz ve el birbirine çok yakın renk dağılımlarını oluşturacak aynı renge sahip olduğu için takip çalışması oldukça zor olacaktır. Bu probleme değinmek için hareket eden el görüntüsünü sunulan yöntemle takip etmeye çalışılmıştır. İlk olarak görüntü dizisi standart ortalama kayma yöntemi ile test edilmiştir. Buna ilişkin sonuçlar Şekil 4.16'da verilmiştir. Kullanıcı eli tamamen doğru olarak takip edilememiştir ve yaklaşık 100. kareden itibaren oluşan hatalar Şekil 4.16.b'deki grafikten görülebileceği gibi oldukça artmıştır.

Aynı görüntü sunulan yöntemle denenmiş ve elde edilen sonuçlar Şekil 4.17'de verilmiştir. Sunulan takipçi tüm dizi boyunca nesneyi takip edebilmiştir. Sayısal sonuçlar ve standart ortalama kayma ile sunulan yönteme ait karşılaştırmalar, Çizelge 4.3'te, x ve y yönündeki hataların karşılaştırması da Şekil 4.18'de verilmiştir.

4.2.2. Sonuç

Bu tezde video görüntülerinde nesnelere takip edebilme yeteneğine sahip bir çalışma gerçekleştirilmiştir. Bu çalışmada özel olarak, aynı olasılık yoğunluk değerleri üreten benzer nesne ve fon renklerinden kaynaklanan nesne takibi hatalarının nasıl giderilebileceğine değinilmiştir. Bu durumlar çoğunlukla renk tabanlı olasılığa dayalı algoritmalar için problem oluşturmaktadır. Ortalama kayma algoritması da bazı durumlarda nesnenin güvenli bir şekilde takip edilmesini sağlamaya yetmeyecek bir bilgi olan, sadece renk bilgisini kullanan bir takip algoritmasıdır. Bu problemi ortadan kaldırmak için sunulan çalışmada renk bilgisine ilave olarak kernel yoğunluk tahmini ile elde edilen hareket bilgisi de ortalama kayma algoritması içerisine eklenmiştir. Bu bütünlük çalışmada nesne ve ortam renkleri benzer olduğunda da takip hatalarını azaltabilme avantajına sahip olmuştur. Yapay ve gerçek görüntüler üzerinde elde edilen sonuçlarla yapılan sayısal analizler, sunulan takip yönteminin standart ortalama kayma algoritmasından daha iyi sonuçlar verdiğini göstermiştir.

KAYNAKLAR

1. M. Sonka, V. Hlavac, R. Boyle, Image Processing, Analysis and Machine Vision, Brooks and Cole Co., USA, 1999.
2. J. S. Weszka, C. Dyer, A. Rosenfeld, IEEE Trans. Systems, Man and Sybernetics, **6**, 269(1976).
3. J. S. Weszka and A Rosenfeld, IEEE Trans. Systems, Man and Sybernetics, **9**,38(1979).
4. G. T. Herman and H. K. Liu. Computer Graphics and Image Processing, **7**,130(1978).
5. M. Nagao and T. Matsuyama. A Sutructural Analysis of Complex Aerial Photograps, Plenum Press, New York, 1980.
6. P. K. Sahoo, S. Soltani, A. K. C. Wong and Y. C. Chen. CVGIP, **41**, 233(1988).
7. P. M. Narendra and M. Goldberg. PR, **9**,207(1977).
8. Y. I. Otha, T. Kanade and T. Sakai, Computer Graphics and Image Processing, **13**, 222(1980).
9. J. Kittler and J. Illingworth. IEEE Trans. Systems, Man and Sybernetics, **15**, 652(1985).
10. M. H. Hassan, A Class of Iterative Thresholding Algorithms for Real Time Image Segmentation, In Intelligent Robots and Computer Vision; Proceeding of the Seventh Meeting, Cambridge, MA, 1989.
11. F. Lavagetto, Infrared Image Segmentation Through Iterative Thresholding In real-time image processing II, Orlando, FL, 1990.
12. A. Kundu and S. K. Mitra. IEEE Trans. Pattern Analysis and Machine Intelligence, **9**, 569(1987).
13. J. K. Canny. IEEE Trans. Pattern Analysis and Machine Intelligence, **8**, 679(1986).
14. A. Rosenfeld, R. A. Hummel, and S. W. Zucker, IEEE Trans. Systems, Man and Sybernetics, **6**, 420(1976).

15. S. W. Zucker, Relaxation Labelling, Local Ambiguity, and Low-Level Vision, Pattern Recognition and Artificial Intelligence, 1976.
16. E. M. Riseman and M. A. Arbib. Computer Graphics and Image Processing, **6**, 221(1977).
17. E. R. Hancock and J. Kittler, IEEE Trans. PAMI, **12**, 165(1990).
18. T. Pavlidis, Structural Pattern Recognition, Springer Verlag, Berlin, 1977.
19. Y. T. Liow. CVGIP – Image Understanding, **53**, 313(1991).
20. S. A. Dudani, Region Extraction Using Boundary Following Pattern Recognition and Artificial Intelligence, 1976.
21. D. H. Ballard and C. M. Brown, Computer Vision, Prentice Hall, Englewood Cliffs, NJ, 1982.
22. P. V. C. Hough. A Method and Means for Recognizing Complex Patterns. US patent 3,069,654, 1962.
23. L. Xu and E. Oja. CVGIP – Image Understanding, **57**, 131(1993).
24. R. M. Haralick and L. G. Saphiro, CVGIP, **29**, 100(1985).
25. P. Zamperoni, Analysis of Some Region Growing Operators for Image Segmentation, Advances in Image Processing and Pattern Recognition, North Holland, amsterdam, 1986.
26. W. E. L. Grimson and T. L. Perez, IEEE Trans. PAMI, **9**, 469(1987).
27. N. R. Pal and S. K. Pal. IEEE Trans. Systems, Man and Sybernetics, **17**, 857(1987).
28. R. Adams and L. Bischof, IEEE Trans. PAMI, **16**, 641(1994).
29. Y. L. Chang and X. Li, IEEE Trans. IP, **3**, 868(1994).
30. Y. L. Chang and X. Li. Image and Vision Computing. **13**, 559(1995).
31. T. Kurita. IEICE Trans. Informations and Systems, **78**,1546(1995).
32. A. Baraldi and F. Parmiggianni, IEEE Trans. on Geoscience and Remote Sensing, **34**, 137(1996).
33. A. Rosenfeld and A. C. Kak, Digital Picture Processing, Academic Press, New York, 1982.
34. R. M. Haralick, Proceedings of the IEEE, **67**, 786(1979).

35. P. Brodatz, Textures: A Photographic Album for Artists and Designers, Dover Publications, Inc., New York, 1966.
36. D. Chetverikov, Experiments in the rotation invariant texture discrimination using anisotropy features, Proceedings of the 6th IEEE Congress on PR, Munich, Germany, 1982.
37. A. R. Rao, A Taxonomy for Texture Description and Identification. Springer Verlag, New York, 1990.
38. J. Sklansky, IEEE Trans. Systems Man and Sybernetics, **8**, 237(1978).
39. B. Julesz, Nature, **290**, 91(1981).
40. B. Julesz and J. R. Bergen, Textons, The Fundamental Elements in Preattentive Vision and Perception of Textures, Computer Vision, Los Altos, CA, 1987.
41. H. Voorhees and T. A. Poggio, Detecting Textons and Texture Boundaries in Natural Images. In 1st International Conference on Computer Vision, London, England, 1987.
42. S. Ando, Texton Finders Based on Gaussian Curvature of Correlation with an Application to Rapid Texture Classification, Proc. of the IEEE Int. Conf. on Systems, Man and Sybernetics, 1988.
43. K. R. Castleman, Digital Image Processing, Prentice-Hall, Englewood Cliffs, NJ, 1996.
44. A. R. Shulman, Optical Data Processing, Wiley, New York, 1970.
45. A. Rosenfeld, Digital Picture Analysis, Springer Verlag, Berlin, 1976.
46. S. S. Liu and M. E. Jernigan. CVGIP, **49**, 52(1990).
47. R. M. Haralick, K. Shanmugam and I. Dinstein, IEEE Trans. Systems, Man and Sybernetics, **3**, 610(1973).
48. C. G. Gotlieb and H. E. Kreyszig, CVGIP, **51**, 70(1990).
49. F. Argenti, F. Alparone and G. Benelli, IEEE proceedings, Radar and Signal Processing, **137**, 1990.
50. G. E. Carlson and W. J. Ebel, Co-occurrence Matrix Modification for Small Region Texture Measurement and Comparison, In IGARSS'88, Edinburgh, Scotland, NJ, 1988.

51. L. S. Davis and A. Mitiche, *Computer Graphics and Image Processing*, **12**, 25(1980).
52. F. Tomita and S. Tsuji, *Computer Analysis of Visual Textures*, Kluwer, Norwell, MA, 1990.
53. A. Perry and D. G. Lowe, *Segmentation of Non-random Textures Using Zero Crossing*, In 1989 IEEE Int. Conf. on Systems, Man and Sybernetics, Cambridge, 1989.
54. Z. Fan, *Edge-Based Hierarchial Algorithm for Textured Image Segmentation*, In ICASSP, Glasgow, Scotland, 1989.
55. P. W. Fung, G. Grebbin and Y. Attikiouzel. *Contextual Classification and Segmentation of Textured Images*. ICASSP, Albuquerque, NM, 1990.
56. B. P. Kjell and P. Y. Wang, *Noise Tolerant Texture Classification and Image Segmentation*, In *Intelligent Robots and Computer Vision IX: Algorithms and techniques*, Boston, 1991.
57. M. M. Galloway, *Computer Graphics and Image Processing*, **4**, 172(1975).
58. A. Gisolfi, S. Vitulano and A. Cacaе, *Texture and Structure*, In *Advances in Image Processing and Pattern Recognition*, North Holland, Amsterdam, 1986.
59. K. I. Laws, *Texture Energy Measures*, In *DARPA Image Understanding Workshop*, Los Angeles, CA, DARPA Los Altos, CA, 1979.
60. C. M. Wu, Y. C. Chen and K. S. Hsieh, *IEEE Trans Medical Imaging*, **11**, 141(1992).
61. A. P. Pentland. *PAMI*, **6**, 661(1984).
62. B. Mandelbrot, *The Fractal Geometry of Nature*, Freeman, New York, 1982.
63. A. S. Besicovitch and H. D. Ursell, *Journal of the London Mathematical Society*, **12**, 18(1937).
64. T. Lundahl, W. J. Ohley, S. M. Kay, and R. Siffert, *IEEE Trans. Medical Imaging*, **5**, 152(1986).
65. H. E. Hurst, *Trans. of the American Society of Civil Engineers*, **116**, 770(1951).

66. N. Sarkar and B. B. Chaudhuri, IEEE Trans. Systems, Man and Sybernetics, **24**, 115(1994).
67. Q. Huang, J. R. Lorch and R. C. Dubes, **27**, 339(1994).
68. X. C. Jin, S. H. Ong and Jayasooriah, Pattern Recognition Letters, **16**, 457(1995).
69. J. Serra and G. Verchery, Film Science Technology, **6**, 141(1973).
70. M. Siman, Knowledge-Guided Segmentation of Texture Images. IEEE Int. Conf. Systems Engineering, Pittsburgh, PA, 1990.
71. L. M. Linnet and A. J. Richardson, ICASSP'90, Albuquerque, NM, Piscataway, NJ, 1990.
72. K. Deguchi and I. Morishita, IEEE Trans. Computers, **27**, 739(1978).
73. A. Gagalowicz, C. Griffine and D. Picard. IEEE Int. Conf. Systems, Man and Sybernetics, Beijing/ Shenyang, China, 1988.
74. O. R. Mitchell, C. R. Myer, and W. Boyne. IEEE Trans. Computers, **26**, 408(1977).
75. R. W. Ehrich and J. P. Foith, Computer Graphics and Image Processing, **8**, 174(1978).
76. A. Gagalowicz, Sthocastic Texture Fields Synthesis from a Priori Given Second Order Statistics. In Proceedings, Pattern Recognition and Image Processing, Chicago, IL, 1979.
77. W. K. Pratt and O. C. Faugeras, IEEE Trans. Systems, Man and Sybernetics, **8**, 796(1978).
78. X. Y. Yang and J. Liu, Pattern Recognition Letters, **22**, 1073(2001).
79. M. Unser and M. Eden, IEEE Trans. PAMI, **11**, 717(1989).
80. J. M. Coggins and A. K. Jain, Pattern Recognition Letters, **3**, 195(1985).
81. S. G. Mallat, IEEE Trans. PAMI, **11**, 674(1989).
82. A. C. Bovik, M. Clark, and W. S. Geisler, IEEE Trans. PAMI **12**, 55(1990).
83. M. Unser, IEEE Trans. IP, **4**, 1549(1995).
84. B. Wang, Y. Motomura and A. Ono, IEEE Trans. Systems, Man, and Cybernetics, **3**, 2527(1997).

85. X. Y. Jiang and R. C. Zhao, Texture Segmentaton Based on Incomplete Wavelet Packet Frame, Proc of 2nd International Conf. on Machine Learning and Cybernetics, Xian, 2003.
86. T. Chang and C. C. J. Kuo. IEEE Trans. IP, **2**, 429(1993).
87. A. Laine and J. Fan, IEEE Trans. PAMI, **15**, 1186(1993).
88. X. Jiang and R. Zhao, A New Method of Texture Segmentation, IEEE Int Conf. Neural Networks and Signal Processing, Nanjing, China, 2003.
89. P. Vautrot, N. Bonnet and M. Herbin, IEEE Int. Conf. IP, **3**, 145(1996).
90. A. Gagalowicz and C. Graffine, Blind Texture Segmentation, ICPR, Rome, Italy, 1988.
91. C. Bouman and B. Liu, IEEE Trans. PAMI, **13**, 99(1991).
92. J. Portilla and E. P. Simoncelli, Int. J. Computer Vision, **40**, 49(2000).
93. F. Tomita, Y. Shirai, and S. Tsuji, IEEE Trans. PAMI, **4**, 183(1982).
94. R. Urquhart. PR, **15**, 173(1982).
95. N. Ahuja, IEEE Trans. PAMI, **4**, 336(1982).
96. M. Tuceryan and A. K. Jain, IEEE Trans.PAMI **12**, 211(1990).
97. J. Roning and E. L. Hall. Shape, Form and Texture Recognition for Automotive Brake Pad Inspection. In Automated Inspection and Measurement, Cambridge, MA, 1987.
98. J. Chen and A. K. Jain, Structural Approach to Identify Defects in Textured Images. In Proc. of the IEEE Int. Conf. Systems, Man and Sybernetics, Beijing/ Shenyang, China, 1988.
99. E. J. Wood, Texile Research Journal, **60**, 212(1990).
100. W. Adam and B. Nickolay, SME Technical Paper (Series), MS, 1989.
101. B. S. Heaton, J. J. Henry and J. C. Wambold. Texture Measuring Equipment vs Skid Testing Equipment. In Proc. of the 15th ARRB Conference, Darwin, Australia, 1990.

102. C. K. Kennedy, A. E. Young and I. C. Butler, Measurement of Skidding Resistance and Surface Texture and the Use of Results in the UK. In First Int. Symposium on Surface Characteristics, Philadelphia, 1990.
103. A.R.Rao and R. Jain, Quantative Measures for Surface Texture Description in Semiconductor Wafer Inspection. In Integrated Circuit Metrology, Inspection and Process Control IV, San Jose, 1990.
104. Quantative Remote Sensing, International Geoscience and Remote Sensing Symposium Vancouver, Canada, 1990.
105. E. Monjoux and J. P. Rudant, Texture Segmentation in Aerial Images, In Image Processing Algorithms and Techniques II, San Jose, 1991.
106. P. Millerand S. Astley, Image and Vision Computing, **10**, 277(1992).
107. D. L. Toulson and J.F. Boyce, Image and Vision Computing,**10**, 324(1992).
108. L. R. Schad, S. Bluml and I. Zuna, MRI, **11**, 889(1993).
109. H. H. S. Ip and S. W. C. Lam, PR, **28**, 1299(1995).
110. J. Puzicha, T. Hofmann and J. M. Buhman, Non-parametric Similarity Measure for Unsupervised Texture Segmentation and Image Retrieval In Computer Vision and Pattern Recognition, Los Alamitos, 1997.
111. R. E. Kalman, A New Approach to Linear Filtering and Prediction Problems, Trans. ASME, 82, 35(1960).
112. M. Isard and A. Blake. International Journal of Computer Vision, **29**, 5(1998).
113. J. MacCormick and A. Blake, A Probabilistic Exlusion Pirinciple for Tracking Multiple Objects. In Proc. IEEE Computer Society Conference on CVPR, 1999.
114. C. Rasmussen and G. Hager, Joint Probabilistic Techniques for Tracking Multi-Part Objects, In Proc. IEEE Computer Society Conf. on CVPR, 1998.
115. S. Intille, J. Davis, and A. Bobick, Real-time Closed-world Tracking, In Proc. IEEE Computer Society Conference on CVPR, 1997.
116. D. Koller, J. W. Weber, and J. Malik, Robust Multiple Car Tracking with Occlusion Reasoning, In Proc. European Conf. Computer Vision, 1994.

117. S. S. Blackman, G. K. Tucker, R. J. Dempster, and S. H. Roszkowski, Application of Multiple Hypothesis Tracking to Shipboard Irst Tracking, SPIE, 1996.
118. W. Koch, IEEE Trans. Aerospace and Electronic Systems, **36**, 1(2000)
119. J. J. Leonard, B.A. Moran, I. J. Cox and M. L. Miller, Underwatersonar Data Fusion Using an Efficient Multiple Hypothesis Algorithm, In IEEE Int. Conf. Robotics and Automation, 1995.
120. E. Polat, Tracking Multiple Object Using Multiple Hypothesis Tracking Framework, PhD Thesis, Pennsylvania State University, Pennsylvania, 2002.
121. K. Nickels and S. Hutchinson, IEEE Trans. Robotics and Automation, **17**, 28(2001).
122. D.B.Gennery. International Journal of Computer Vision, **7**, 243(1992).
123. D. Lowe. International Journal of Computer Vision, **8**, 113(1992).
124. C. Bregler and J. Malik, Tracking People with Twist and Exponential Maps, CVPR, 1998.
125. G. Hager, Real-Time Feature Tracking and Projective Invariances as a Basis for Hand-Eye Coordination, CVPR, 1994.
126. I. Weiss and M. Ray, IEEE Trans. on PAMI, **23**, 116(2001).
127. E. Marchand, P.Bouthemy, F. Chaumette, and V. Moreu, Robust Real-Time Visual Tracking Using a 2D-3D Model Based Approach, IEEE Int. Conf. on Computer Vision, 1999.
128. F. Jurie, Model-Based Object Tracking in Cluttered Scenes with Occlusions, Int. Conf. on Intelligent Robots and Systems, 1997.
129. J. K. Aggarwal and Q. Cai, CVIU, **73**, 428(1999).
130. D. M. Gavrilla and L.S. Davis. 3D Model-Based Tracking of Humans in Action: A Multi-View Approach, CVPR, 1996.
131. T. B. Moeslund and E. Granum, CVIU, **81**, 231(2001).
132. C. Wren, A. Azarbayejani, T. Darrell, and A. Pentland, PAMI **19**, 7(1997).
133. I. Haritaoglu, D. Harwood, and L. Davis, Hydra: Multiple People Detection and Tracking Using Silhouettes, CVPR, 1999.
134. Y. Cheng, IEEE Trans. PAMI, **17**, 790(1995).

135. K. Fukunaga, L.D. Hostetler, *IEEE Trans. Info. Theory*, **21**, 32(1975).
136. A.Yilmaz, K.Shafique, N.Lobo, X.Li, T.Olson, and M.Shah, *Target Tracking in FLIR Imagery Using Mean Shift and Global Motion Compensation*, *IEEE Workshop Computer Vision Beyond Visible Spectrum*, 2001.
137. Porikli, F.M., *Human Body Tracking by Adaptive Background Models and Mean-Shift Analysis*, *IEEE International Workshop on Performance Evaluation of Tracking and Surveillance*, 2003.
138. J. Zieren, N. Unger, S. Akyol, *Hands Tracking From Frontal View for Vision-Based Gesture Recognition*, *DAGM-Symposium*, 2002.
139. G.R. Bradski, *Computer Vision Face Tracking for Use in a Perceptual User Interface*, *IEEE Workshop on Applications of Computer Vision*, Princeton, NJ, 1998,
140. R. T. Collins, *Mean-Shift Blob Tracking Through Scale Space*, *IEEE Conference on CVPR*, 2003.
141. T. Lindeberg, *International Journal of Computer Vision*, **30**, 79 (1998).
142. M. Herbin, N. Bonnet and P. Vautrot, *Pattern Recognition Letters* **17**, 1141(1996).
143. A. Touzani and J.G. Postaire, *Pattern Recognition Letters*, **9**,1(1989).
144. R. Wilson and M. Spann, *Pattern Recognition Letters*, **23**, 1413(1990)
145. D. Comaniciu and P. Meer, *Mean Shift Analysis and Applications*, *7th Int. Conf. on Computer Vision*, 1999.
146. B. Georgescu, I. Shimshoni, P. Meer, *Mean Shift Based Clustering in High Dimensions: A Texture Classification Example*, *CVPR*, 2003,
147. D. Comaniciu, V. Ramesh, P. Meer, *Proceedings of IEEE Conf. CVPR*, (2000).
148. D. Comaniciu, P. Meer, *Distribution Free Decomposition of Multivariate Data*, *Pattern Anal. and Applications*, **2**, 22(1999).
149. D. Comaniciu, P. Meer, *Robust Analysis of Feature Spaces: Color Image Segmentation*, *CVPR*,1997.

150. H. Wang and D. Suter, Color Image Segmentation Using Global Information and Local Homogeneity, 7th Digital Image Computing: Techniques and Applications, Sydney, 2003
151. I. Daubechies, Ten Lectures on Wavelets, Philadelphia: SIAM, 1992.
152. Y. Sheng, Wavelet Transform, In: The Transforms and Applications Handbook, CRC Press,USA, 1996.
153. C. S. Burrus, and R. A. Gopinath, H. Guo, Introduction to Wavelets and Wavelet Transforms, a Primer, Prentice Hall, NJ (USA),1998.
154. T.H. Greiner, Signal processing **54**, 1(1996).
155. S. Z. Selim and M. A. İsmail, IEEE Trans. PAMI, **6**, 81(1984).
156. A. R. Webb, Statistical Pattern Recognition, Qinetiq Ltd. Malvern, UK, 2001.
157. A. Elgammal, R. Duraiswami, L. S. Davis, Proc. IEEE, **90**, 1151(2002).
158. A. Elgammal, R. Duraiswami, L. S. Davis, Efficient Non-parametric Adaptive Color Modeling Using Fast Gauss Transform, CVPR, 2001
159. M. J. Swain, D.H. Ballard, Int. J. Comp. Vis.,**7**, 11(1991).
160. D. Comaniciu, Nonparametric Robust Methods for Computer Vision, PhD Thesis, Rutgers, The State University of New Jersey, 2000.
161. L. S. Davis, M. Clearman, and J. K. Aggarwal. IEEE Trans. on PAMI **3**, 214(1981).
162. M. Clark and A. C. Bovik, Pattern Recognition Letters, **6**, 261(1987).
163. M. R. Turner. Biological Cybernetics, **55**, 71(1986).
164. B. Julesz, Biological Cybernetics, **54**, 245(1986).
165. J. Beck, K. Prazdny, and A. Rosenfeld, A Theory of Textural Segmentation, Human and Machine Vision, New York, 1983.
166. J. Beck, A. Sutter, and R. Ivry, CVGIP **37**, 299(1987).
167. G. C. Cross and A. K. Jain. IEEE Trans. PAMI, **5**, 25(1983).
168. R. L. Kashyap, R. Chellappa, and N. Ahuja, CVGIP, **15**, 301(1981).
169. B. Julesz, IRE Trans. on Inf. Theory, IT, **8**, 84(1962).
170. B. Julesz, E. N. Gilbert, L. A. Shepp, and H. L. Frisch, Perception, **2**, 391(1973).

171. K. I. Laws, Textured Image Segmentation, Ph.D. Thesis, University of Southern California, California, 1980.
172. M. Tuceryan, Pattern Recognition Letters, **15**, 659(1994).
173. J. Chen, N. Pappas, A. Mojsilovic and B. E. Rogowitz, Adaptive Perceptual Color-Texture Image Segmentation, IEEE Trans. IP, 1(2004).
174. W. Feng and R. C. Zhao, Non Rigid Object Detection and Segmentation in Video Sequence Using 3D Mean Shift Analysis, Proc. of 2nd International Conf. on Machine Learning and Cybernetics, Xian, 2003.
175. T. Kailath, IEEE Trans. Communication. Techniques, **15**, 52(1967)
176. D. Comaniciu and V. Ramesh, Mean Shift and Optimal Prediction for Efficient Object Tracking, Int. Conf. IP, 2000
177. D. Comaniciu and V. Ramesh, Robust Detection and Tracking of Human Faces With an Active Camera, In Proceedings of the 3rd IEEE International Workshop on Visual Surveillance, Dublin, Ireland, 2000.
178. D. Comaniciu, V. Ramesh and P. Meer, IEEE Trans. PAMI, **25**, 564(2003).