

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**





KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

Trabzon

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalında
Murat AKPULAT Tarafından Hazırlanan

KALABALIK DAVRANIŞ ANALİZİ; MODELLENMESİ, ANORMAL DURUM
TESPİTİ VE SINIFLANDIRILMASI

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 01 /10/2019 gün ve 1821 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

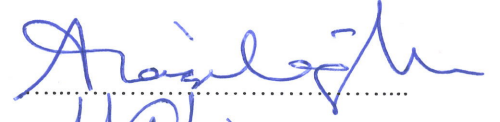



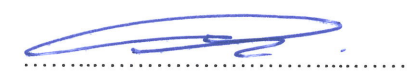
Başkan : Prof. Dr. Abdulsamet HAŞILOĞLU

Üye : Prof. Dr. Murat EKİNCİ

Üye : Prof. Dr. Mustafa ULUTAŞ

Üye : Prof. Dr. İsmail Hakkı ÇAVDAR

Üye : Doç. Dr. Ahmet Burak CAN

Prof. Dr. Asim KADIOĞLU

Enstitü Müdürü

ÖNSÖZ

Kalabalık davranış analizi çalışmaları her geçen gün önemini ve ihtiyacını artıran, farklı disiplinlerin farklı açılardan alternatif çözümler ürettiği bir konudur. Tez çalışmasında bilgisayarla görü ve makine öğrenmesi yöntemlerini kullanarak kalabalığın güvenliğini ve yönetimini sağlamak hedeflenmiştir. Kalabalık hareketlerini modellemek ve sınıflandırmak, kalabalık içerisindeki anormal durumları tespit etmek ve sınıflandırmak problemleri için geliştirilen çözümler tezin içeriğini oluşturmaktadır.

Tez danışmanlığımı üstlenen, yardımını ve desteğini her zaman hissettiğim kıymetli hocam Prof. Dr. Murat EKİNCİ'ye şükranlarımı sunarım. Sizden çok şey öğrendim, örnek kişiliğiniz hayatım boyunca rehberim olacaktır.

Tezin izlenmesi sırasında bilimsel katkıları ve yönlendirmeleriyle çalışmamı destekleyen saygı değer hocalarım Prof. Dr. İsmail Hakkı ÇAVDAR'a ve Prof. Dr. Mustafa ULUTAŞ'a teşekkürlerimi sunarım.

Doktora süresince bana destek olan, çalışmanın her aşamasını takip eden kıymetli arkadaşım Öğr. Gör. Kenan KUZULUGİL'e çok teşekkür ederim.

Hayatımın her safhasında güven ve destekleriyle yanımda olan canım anneme ve babama hürmetlerimi sunarım.

Ailemizin mutluluk kaynağı biricik oğluma ve her türlü zorluklara rağmen sabırla bana güç veren eşime teşekkür ederim.

Murat AKPULAT

Trabzon 2019

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum ‘‘Kalabalık Davranıř Analizi; Modellenmesi, Anormal Durum Tespiti ve Sınıflandırılması’’ bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Prof.Dr. Murat EKİNCİ ‘nin sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gösterdiđimi, alıřma sürecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 24/10/2019

Murat AKPULAT

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Tezin Kapsamı	3
1.3. Motivasyon	4
1.4. Kalabalık Analizinde Hareket Bölütleme	7
1.5. Anormal Durum Tespit Etme	10
1.6. Anormal Olayların Sınıflandırılması	13
1.6.1. Değişinti Matrisi ile Hareketi Temsil Etmek.....	15
1.7. Kullanılan Veri Tabanları	16
1.8. Performans Ölçütleri.....	16
1.8.1. Yersel Doğruluk.....	16
1.8.2. İşlem Karakteristik Eğrisi	17
1.9. Optik Akışı	18
1.10. Parçacık Taşıma.....	21
1.11. Örgü Entropi (Braid Entropy).....	22
1.11.1. Üretici Dizisi.....	23
1.11.2. Döngü Uzunluğu.....	24
1.11.3. Örgü Entropi Hesaplama	26
1.12. Gaussian Karışım Modeli	26
1.13. Ortalama Kayma Algoritması.....	28
1.14. En Yakın Komşu Sınıflandırıcı	28

2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME	30
2.1.	Kalabalığın Davranış Modelini Belirlemek.....	30
2.1.1.	Akış Haritası Oluşturmak	32
2.1.2.	Görüntüyü Altıgen Bölgelere Ayırmak	33
2.1.3.	İz Düşüm İşlemi.....	33
2.1.4.	Düzensizlik Haritası.....	36
2.1.5.	Kalabalığın Davranış Modeli Sonuçları	36
2.1.5.1.	Davranış Modeli Eğitim ve Test Aşamaları	36
2.1.5.2.	Davranışın Zaman İçerisindeki Değişimi	42
2.1.5.3.	Sonuçları Literatürdeki Çalışmalarla Karşılaştırmak	43
2.2.	Anormal Durum Tespiti.....	44
2.2.1.	Hareket kümelerini Belirleme.....	46
2.2.2.	Öznitelik Vektörü Hesaplama.....	49
2.2.3.	Sınıflandırma	51
2.2.4.	Anormal Durum Tespit Etme Sonuçları	53
2.2.4.1.	Yerelde Anormal Durum Tespit Etme.....	53
2.2.4.2.	Görüntünün Genelindeki Anormal Durumu Tespit Etme	61
2.3.	Kalabalık Davranışlarını Sınıflandırmak.....	67
2.3.1.	Anormal Olayların Sınıflandırılması	67
2.3.1.1.	Veri Girişi	69
2.3.1.2.	Davranış kümeleri Belirleme	69
2.3.1.2.1.	Optik Akışı ve Parçacık Taşıma Yöntemleri	69
2.3.1.2.2.	Ortalama Kayma Yöntemi	70
2.3.1.3.	Değişinti Matrisleri Arası Uzaklık Ölçüm Metrikleri	70
2.3.1.3.1.	Log-Öklid Uzaklık Metriği.....	72
2.3.1.3.2.	Affine-Invariant Riemannian Metriği.....	73
2.3.1.4.	Öznitelik Vektörü Bileşenleri	73
2.3.1.5.	Davranış Sınıflandırma Sonuçları	74
2.3.2.	Kalabalık Hareketlerini Sınıflandırmak.....	79
2.3.2.1.	Optik Akışı ve Parçacık Taşıma Yöntemleri	79
2.3.2.2.	Hareket kümeleri Belirleme	81
2.3.2.3.	Hareket kümelerini Parabol ile Temsil Etmek.....	81
2.3.2.4.	Hareket Sınıflandırma ve Sonuçları.....	81

3.	SONUÇLAR.....	84
4.	KAYNAKLAR.....	87
5.	EKLER	94



Doktora Tezi

ÖZET

KALABALIK DAVRANIŞ ANALİZİ; MODELLENMESİ, ANORMAL DURUM
TESPİTİ VE SINIFLANDIRILMASI

Murat AKPULAT

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Murat EKİNCİ
2019, 93 Sayfa, 5 Sayfa Ek

Kalabalık davranış analizi çalışmaları ile kalabalığın güvenliğini ve yönetimi sağlamak kişi hayatı açısından önemli bir konudur. Geliştirilen akıllı sistemler ile kalabalık davranışları daha iyi tahlil edilip yorumlanabilir.

Çalışmanın genel aşamaları ve hedefleri şunlardır; görüntüdeki hareket bilgisi optik akışı yöntemi ile elde edilir. Sonrasında kullanılan parçacık taşıma yöntemi ile kalabalığın davranışı hareket izleri olarak temsil edilir. Davranış bütünlüğüne göre kümelenen hareket izlerinin birbirleriyle gerçekleştirdikleri “çakışma” olayları örgü entropi (braid entropi) yöntemi ile hesaplanır ve bu sayede davranışın ne derece düzenli-düzensiz olduğu belirlenir.

Bu tez kapsamındaki hedefler, cadde ya da sokaklardaki kalabalık davranışlarını, hareketin düzensizlik değerine bağlı olarak modelleyebilmektir. Bir bütün halinde ilerleyen kalabalığın içerisinde bölgesel olarak meydana gelen düzensiz davranışlar tespit edilerek, hareketin daha iyi anlaşılması sağlanır. Ayrıca kalabalık hareketleri içerisinde, görüntünün bir bölümünde ya da tümünde gerçekleşen anormal durumları tespit etmek hedeflenir. Son bölümde, UCF veri kümesindeki 8 ve 4 farklı anormal olayları içeren görüntüler, öğrenme modelinde örgü entropiye bağlı değişinti matrisleri ile temsil edilir ve en yakın komşu yöntemi ile sınıflandırılırlar.

Anahtar Kelimeler: Kalabalık Davranış Analizi, Anormal Durum tespiti, Kalabalık Davranış Modellemesi, Anormal Durum Sınıflandırılması

PhD. Thesis

SUMMARY

CROWD BEHAVIOUR ANALYSIS; MODELLING, ABNORMAL EVENT
DETECTION AND CLASSIFICATION

Murat AKPULAT

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Murat EKİNCİ
2019, 93 Pages, 5 Pages Appendix

Providing the safety and management of a crowd through crowd behaviour analysis studies is a vital issue in terms of lives of people. Thanks to the smart systems being developed the crowd behaviour can be better analysed and assessed.

Steps and targets of the study are as follows: the motion data is obtained by optical flow method. Later, the crowd behaviour is represented by trajectories through particle advection. The “cross” events that occurred owing to the accumulated tracks according to the unity of the behaviour are calculated by the braid entropy method and according to this, how regular or irregular the behaviour is can be determined.

The targets within the scope of this thesis is to model the crowd behaviour in the streets according to the complexity levels of the motion. The motion can be better understood by determining the complex behaviour that occurs regionally within the moving crowd that proceeds as a whole. Moreover, it is also targeted to determine the abnormal events in a local area or on the whole of the image. In the final section, images from the UCF database that contain 8 and 4 different abnormal events are represented by the covariance matrix that depend on braid entropy in the learning model and are classified by the nearest neighbour classification method.

Keywords: Crowd Behaviour Analysis, Abnormal Event Detection, Crowd Analysis Modelling, Abnormal Event Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Kalabalık davranış analizi çalışmalarında kullanılan görüntülerden bazıları	2
Şekil 1.2. Tezin genel yapısı	3
Şekil 1.3. 1950 den bu zamana, kalabalık kazaları neticesinde en fazla ölümün gerçekleştiği ilk 14 ülke ve Türkiye'deki durum	6
Şekil 1.4. 1950 den bu zamana, kalabalık kazaları neticesinde en fazla ölümün gerçekleştiği ilk 14 ülke ve Türkiye'deki kaza sayıları.....	6
Şekil 1.5. Kalabalık hareketlerinin bölütlenmesi [6].	8
Şekil 1.6. Dinamik süreçler [29].	10
Şekil 1.7. Hareket modelleme [36].	12
Şekil 1.8. Kalabalık hareketlerinin sınıflandırıldığı davranış türleri [50].	14
Şekil 1.9. Hareketli alanların bölütlenmesi a) görüntü b) çalışmanın sonucu c) yersel doğruluk değeri	17
Şekil 1.10. Art arda gelen görüntüler ile elde edilen optik akışı hareket vektörleri	19
Şekil 1.11. a) 3 tane parçacığın taşınması ile oluşan hareket yörüngeleri, her bir yörünge yıldız hareketin başladığı konumu, nokta o an bulunduğu konumu ifade eder b) Her bir parçacığın x eksenine göre hareket bilgisinin zamana göre değişimi c) Hareket yörüngeleri [30, 72, 73].	23
Şekil 1.12. Dört hareket izi için çizilmiş örnek döngü [30, 72, 73].	24
Şekil 1.13. En yakın komşu sınıflandırıcı	28
Şekil 2.1. Çalışmanın basamakları	31
Şekil 2.2. a) Sistemin çerçeve girdisi b) Optik akışı sonuçları c) Parçacık taşıma sonuçları, hücrelere ayrılmış görüntüden <i>Hücreij</i> hücresinin içerisine denk gelen hareket izleri yeşil ile renklendirilmiştir.	32
Şekil 2.3. a) Hücreye 5^0 aralıklarla uygulanan iz düşüm işlemi sonunda her bir açı değeri için elde edilen çakışma olayları b) x eksenine c) 5^0 d) 10^0 e) 175^0 açı değeri için elde edilen çakışma olaylarının gösterimi	34
Şekil 2.4. Her bir hücre için örgü entropi teoremi ile öznitelik vektörü hesaplanmasının işlem basamakları	35
Şekil 2.5. Eğitim aşamasında, her bir hücre için öznitelik vektörünün oluşturulması, eğitim aşamasında kullanılan p değeri için her bir hücreden oluşan eğitim kümesi ve GMM ile sınıflandırma sonucunda elde edilen sınıflar	37
Şekil 2.6. Test aşaması	38
Şekil 2.7. Maraton koşusu görüntüsünün 2 sınıf için sınıflandırma sonuçları	40

Şekil 2.8. Maraton koşusu görüntüsünün 3 sınıf için sınıflandırma sonuçları	40
Şekil 2.9. Maraton koşusu görüntüsünün 4 sınıf için sınıflandırma sonuçları	40
Şekil 2.10. Sınıflandırma sonuçlarına göre hazırlanan entropi özet grafikleri a) Şekil 2.7' deki 2 sınıf için entropi özet grafiği b) Şekil 2.8'deki 3 sınıf için entropi özet grafiği c) Şekil 2.8'deki 4 sınıf için entropi özet grafiği	41
Şekil 2.11. Hücrelerin içerisine denk gelen davranışın zamanla ne ölçüde değiştiğini gösteren grafikler a) Görüntüde yeşil ve kırmızı ile renklendirilen bazı hücreler b) Yeşil ile renklendirilen hücrelerin zaman içerisinde değişimi c) Kırmızı ile renklendirilen hücrelerin zaman içerisinde değişimi	41
Şekil 2.12. Çalışmanın sonuçlarının literatürden farklı çalışmalarla karşılaştırılması a) Tez çalışmasının sonuçları b) Saad Ali vd. [6] c) Ramin Mehran vd. [19] d) Bolei Zhou vd. [16] e) Bolei Zhou [85].	43
Şekil 2.13. Çalışmanın genel aşamaları	46
Şekil 2.14. Elde edilen hareket izleri gösterilmiştir. a) Her bir hareket izi yeşil nokta ile başlar, kırmızı nokta ile biter. b) Ortalama-kayma yöntemi ile gruplara ayrılan hareket izleri farklı renkler ile gösterilmiştir.	47
Şekil 2.15. a) Hareket kümesine 5^0 aralıklarla uygulanan iz düşüm işlemi sonunda her bir açı değeri için elde edilen çakışma olayları b) x eksenine c) 5^0 d) 10^0 e) 175^0 açı değeri için elde edilen çakışma değerleri	48
Şekil 2.16. Her bir hareket kümesi için örgü entropi teoremi ile öznelilik vektörü hesaplanmasının işlem basamakları.....	50
Şekil 2.17. a) Her bir kümeyi oluşturan hareket vektörlerinin genlik değerine bağlı dağılımı b) Hareket vektörünün büyüklüğü.....	50
Şekil 2.18. $r = 5$ piksel, $t = 10$ çerçeve	56
Şekil 2.19. $r = 10$ piksel, $t = 10$ çerçeve	56
Şekil 2.20. $r = 5$ piksel, $t = 20$ çerçeve	56
Şekil 2.21. $r = 10$ piksel, $t = 20$ çerçeve	56
Şekil 2.22. $r = 5$ piksel, $t = 10$ çerçeve	57
Şekil 2.23. $r = 10$ piksel, $t = 10$ çerçeve.....	57
Şekil 2.24. $r = 5$ piksel, $t = 20$ çerçeve	57
Şekil 2.25. $r = 10$ piksel, $t = 20$ çerçeve.....	57
Şekil 2.26. UCSD peds1 veri kümesinden elde edilen DP ve DN sonuçları	58
Şekil 2.27. UCSD peds1 veri kümesinden elde edilen YN sonuçları.....	58
Şekil 2.28. UCSD peds1 veri kümesinden elde edilen YP sonuçları.....	58
Şekil 2.29. UCSD peds2 veri kümesinden elde edilen DP ve DN sonuçları	59
Şekil 2.30. UCSD peds2 veri kümesinden elde edilen YN sonuçları.....	59
Şekil 2.31. UCSD peds2 veri kümesinden elde edilen YP sonuçları.....	59

Şekil 2.32. a) UMN veri tabanından normal ve anormal durumların olduğu görüntüler b) Farklı t değerleri için elde edilen grafikler c) Farklı boyutta öznelik vektörü için elde edilen grafikler	62
Şekil 2.33. UMN veri tabanındaki görüntülere uygulanan yöntemin sonuçları verilmiştir. a) UMN-1, anormal durum düzensizlik değerleri, eşik değer = 0.3264 b) UMN-2, anormal durum düzensizlik değerleri, eşik değer = 0.2912 c) UMN-3, anormal durum düzensizlik değerleri, eşik değer = 0.2255	63
Şekil 2.34. UMN veri kümesindeki görüntüler için hesaplanan ROC eğrileri	65
Şekil 2.35. UCF-Suç veri tabanından görüntüler üzerinde elde edilen sonuçlar	66
Şekil 2.36. Anormal olayların sınıflandırılması probleminin genel aşamaları	67
Şekil 2.37. Eğitim ve test aşamalarında gerçekleştirilen işlemler	68
Şekil 2.38. Riemannian manifold üzerinde bulunan değişinti matrislerinin öklid uzayına taşınması.....	72
Şekil 2.39. Görüntüden elde edilen değişinti matrisi ile hesaplanan öznelik vektörü.....	73
Şekil 2.40. Optik akışı hareket vektörlerinin histogram dağılımına bağlı öznelik vektörü	74
Şekil 2.41. Hangi çerçeve bloklarının öğrenme modeline dahil edildiğini gösterir	75
Şekil 2.42. Davranış sınıflandırma çalışmasının genel aşamaları.....	79
Şekil 2.43. Hareket kümeleri "düz" ya da "dairese" davranışlara yakınlığı nispete etiketlenir	82
Ek Şekil 1. UCF veri kümesinden bazı görüntüler üzerinde hesaplanır ve anormal durum anlarını gösterir. Kırmızı çizgiler anormal durum için eşik değeri ifade eder ve bbes değerinin ortalama+standart sapma değeridir.....	94
Ek Şekil 2. UCF veri kümesinden bazı görüntüler üzerinde hesaplanır ve anormal durum anlarını gösterir. Kırmızı çizgiler anormal durum için eşik değeri ifade eder ve bbes değerinin ortalama+standart sapma değeridir.....	95
Ek Şekil 3. Veri kümelerinden 49 farklı senaryo için hesaplanan ve görüntüdeki düzensiz ve düzenli alanların ortalama değerini gösterir	96
Ek Şekil 4. UCF Anormal veri kümesinden görüntüler	97
Ek Şekil 5. UCF Anormal veri kümesinden görüntüler	98

TABLolar DİZİNİ

	Sayfa No
Tablo 1. Anormal durum hata matrisi	18
Tablo 2. Peds1 veri kümesine ait elde edilen sonuçlar	56
Tablo 3. Peds2 veri kümesine ait elde edilen sonuçlar	57
Tablo 4. Literatürden bazı sonuçlar ile çalışmamızın karşılaştırılması	60
Tablo 5. UMN veri kümesinden elde edilen sonuçların literatürden farklı çalışmalarla performansının karşılaştırılması	65
Tablo 6. 8 Sınıf İçin Sınıflandırmada Kullanılan Görüntülerin Eğitim-Test Dağılımları.....	77
Tablo 7. Sınıflandırmanın Yüzdelik (%) Başarım Sonuçları.....	77
Tablo 8. 4 Sınıf İçin Sınıflandırmada Kullanılan Görüntülerin Eğitim-Test Dağılımları.....	78
Tablo 9. Sınıflandırmanın Yüzdelik (%) Başarım Sonuçları.....	78

SEMBOLLER DİZİNİ

AUC	İşlem karakteristik eğrisinin altında kalan alan (Area Under Curve)
BOV	Video Kelimeler Torbası (Bag Of Video Words)
CNI	Tutarlı Komşu Değişmezliği (Coherent Neighbor Invariance)
CUHK	The Chinese University Of Hong Kong
DM	Yayılma Haritası (Diffusion Maps)
EBS	Kenar Tabanlı Bölütleme (Edge-Based Segmantation)
EER	Eşit hata oranı (Equal Error Rate)
FFBS	Akış Alanı Tabanlı Bölütleme (Flow Field Based Segmentation)
FTBE	Sonlu-Zaman Örgü Entropi (Finite-Time Örgü Entropi)
FTLE	Sonlu Zaman Lyapunov Üssü (The Finite Time Lyapunov Exponent)
GMM	Gaussian Karışım Modeli (Gaussian Mixture Model)
GTB	Grafik Tabanlı Bölütleme (Graph-Based Segmantation)
HFST	Yüksek Frekanslı Ve Zamansal-Mekânsal (The High-Frequency And Spatio-Temporal)
HOFME	Histograms Of Optical Flow Orientation And Magnitude And Entropy
LCSS	En Uzun Ortak Küme (The Longest Common Subsequence)
LDA	Gizli Dirichlet Tahsisi (Latent Dirichlet Allocation)
LPM	Yerel Baskı Modeli (Local Pressure Model)
LTDS	Yerel Çeviri Alanı (Local Translation Domain Segmantation)
MDT	Mixture Of Dynamic Textures
MF	Median Filter
MRF	Markov Rastgele Alanlar (Markov Random Fields)
MSC	Ortalama Kayma İle Kümeleme (Mean-Shift Clustering)
MT	İlişkisel İzleme (Meta-Tracking)
MVB	Hareket Vektörleri Tabanlı (Motion Vector Based)
NN	En Yakın Komşu Algoritması (Nearest Neighbor Algorithm)
OD	Nesneyi Tespit Etme (Object Detection)
PA	Parçacık Taşıma (Particle Advection)

PMBC	Olasılıksal Model Tabanlı Kümeleme (Probability Model Based Clustering)
RFT	Rastgele Alanlar Modeli (Random Field Topic)
ROC	İşlem karakteristik eğrisi (Receiver Operating Characteristic)
SBC	Benzerlik Tabanlı Kümeleme (Similarity Based Clustering)
SF	Çıkış Çizgisi Yazılım Çatısı (Streakline Framework)
SOG	Üretici Dizisi (Sequence Of Generator)
SRC	Sparse Reconstruction Cost
SUCS	Yapısal Ve Yapısal Olmayan Kalabalık Hareketi Sahneleri (Structured-Unstructured Crowd Scene)
SVM	Destek Vektör Makineleri (Support Vector Machine)
TB	Hareket İzleri Tabanlı (Trajectory Based)
TV	Tensor Voting
UCF	University Of Central Florida
UCSD	The University California, San Diego
WBS	Havza Sınırlama Tabanlı Bölütleme (Watershed-Based Segmantation)

1. GENEL BİLGİLER

1.1. Giriş

“Kalabalık” kavramının herkes tarafından kabul edilmiş bir tanımı olmamasına rağmen, literatürde yer alan bazı tanımlar şu şekildedir [1, 2].

“Aynı fiziksel ortamda bulunan ve ortak bir amacı paylaşan büyük bir grup insan (örneğin, bir rock gösterisine veya bir futbol maçına giden insanlar). Bir kalabalıktaki bireyler, yalnız olduklarında veya küçük bir grupta olduklarından farklı bir şekilde hareket edebilir [3].”

“Ortak çıkarların peşinde koşan insanlar [4].”

“Aynı anda aynı yerde yer alan çok sayıda insan [5].”

Literatürdeki tanımlar ışığında kalabalığa ait ortak özellikler ise şu şekilde sıralanabilir [2].

Büyüklik: Kalabalığı oluşturan kişilerin sayısının ölçülebilir olmasıdır.

Yoğunluk: Kalabalığın bölgelere göre dağılımının nasıl olduğudur.

Zaman-Davranış: Ölçülebilir bir zaman aralığı için, ortak hedefler doğrultusunda, ortak davranışların gösterilmesidir.

Gözetleme sistemlerinden alınan verilerin işlenip, kalabalığın bazı özelliklerini ortaya çıkararak, kalabalığın seyrini anlamak, nasıl bir örüntü oluşturduğunu tanımlamak ve kalabalık hareketi içerisindeki anormal durum, kişi ya da kişileri tespit-takip etmek gibi amaçlar için yapılan çalışmalar, kalabalık davranış analizi olarak adlandırılır.

Kalabalık davranış analizi çalışmaları, son yıllarda önemini artırmış ve bilgisayarla görme alanında ki araştırmacıların da yakından ilgilendiği ve alternatif çözümler üretebildiği bir konu başlığı haline gelmiştir.

Literatür incelendiğinde, genel itibari ile iki hedef doğrultusunda çalışmaların olduğu görülmüştür.

Bunlardan birincisi sosyal ihtiyaçlar için gerçekleştirilen çalışmalardır. Bu tür çalışmalarda, park, bahçe, sokak gibi halka açık alanların tasarlanması ve çevre planlanması yer alır. Kalabalığın davranışına göre caddedeki yığılmaları önlemek, daha kullanışlı alanlar

tasarlamak, panik anında kişilerin yönetimini ve güvenli bir şekilde tahliyesinin sağlamaya yardımcı olabilecek bilgileri elde etmek hedeflenir.

Kalabalık davranış analizi çalışmalarının ikinci hedefi ise kişilerin güvenliğini sağlamaktır. Bu bağlamda, gözetleme sistemlerinden elde edilen görüntüler üzerinde algoritmalar geliştirilerek, kalabalığın yoğunluğunun kestirilmesi ve nasıl bir seyir izlediğinin gözlenmesi, tehlikeli bir kalabalık oluşumunun ya da kalabalık içindeki anormal durumların önceden fark edilmesi ve tespit edilmesi, şüpheli kişi ya da kişi gruplarının görüntü boyunca takip edilmesi gibi konu başlıkları ile ilgilenir.

Kalabalığın nasıl bir davranış gösterdiğini anlamak için gerçekleştirilen birçok çalışmada öncelikli olarak kalabalık hareketli-hareketsiz bölgelere ayrılır, hareketli alanlar içerisinde benzer davranış gösteren ve konum olarak birbirine yakın hareketliler kümelenir ve nihai olarak kümelenen davranışların tanımlanması beklenir. Bu çalışmalarda hareket vektörlerinin olasılıksal, ortalama ya da istatistiksel dağılımdan faydalanarak hareketin genel akışı ile ilgili bilgiler elde edilir. Az yoğun kalabalık hareketlerindeki etkileşimi inceleyen çalışmalar da ise hareket vektörlerinin birbiriyle olan kesişim durumlarına bağlı sonuçlar üretilmiştir.

Kalabalık davranış analizi çalışmalarında kullanılan ve araştırmacıların ortak kullanımına sunulan görüntülerden bazıları Şekil 1.1’de gösterilmiştir.



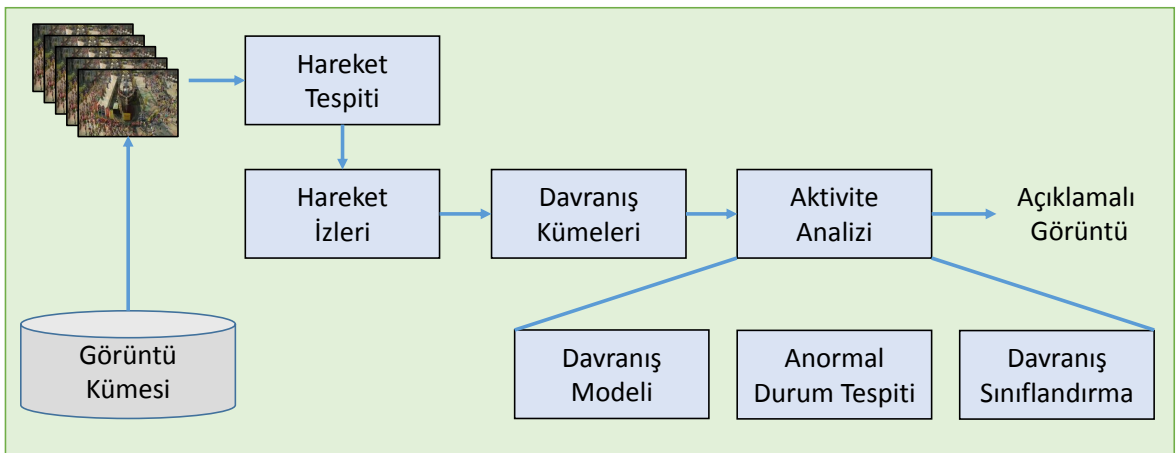
Şekil 1.1. Kalabalık davranış analizi çalışmalarında kullanılan görüntülerden bazıları

1.2. Tezin Kapsamı

Kalabalık davranış analizi çalışmalarının her geçen gün artan önemi ve sağladığı faydaları düşünerek, tez çalışması kalabalık davranışının modellenmesi, sınıflandırılması ve gerçekleştirilecek anormal durumların tespit edilmesi yönünde alternatif çözümler sunmak üzere hazırlanmıştır. Tez çalışmasının genel yapısı Şekil 1.2’de gösterilmiştir.

Kalabalık davranış analizi çalışmalarında kullanılan görüntüler, genel itibari ile bilindik ve her araştırmacının ulaşabileceği, açık kaynaklı video görüntüleridir. Farklı araştırmacılar tarafından gerçekleştirilen çalışmaların sağlıklı bir şekilde karşılaştırmasını yapabilmek için her araştırmacı aynı görüntüler üzerinde çalışmasını test eder ve başarımlarını karşılaştırır. Kalabalık davranışını modellemek için UCF-kalabalık [6] veri kümesi ve CUHK-kalabalık [7] veri kümeleri kullanılmıştır. Kalabalık davranış içerisinde gerçekleştirilecek anormal olayları tespit etmek için UCSD ve UMN veri kümeleri kullanılmıştır. Anormal olayların sınıflandırılmasında ise UCF-anormal durumlar veri kümesi kullanılmıştır. Tez çalışmasında kullanılan görüntü veri kümeleri ile ilgili açıklayıcı bilgiler Bölüm 1.7’de verilmiştir.

Video görüntüsünü işlemeye öncelikli olarak görüntüdeki hareket bilgisini elde ederek başlanır. Tez çalışmasında, hareket tespiti optik akışı yöntemi kullanılarak gerçekleştirilir. Bu yöntem sayesinde görüntüdeki kalabalığın hareketi piksel seviyesinde hareket vektörleri olarak hesaplanır ve sistemin girdi değeri olarak kullanılır.



Şekil 1.2. Tezin genel yapısı

Hareket vektörleri bir sonraki aşamada hareket izlerini elde etmek için kullanılır. Parçacık taşıma yöntemi ile hesaplanan hareket izleri görüntü boyunca oluşan kalabalık hareketlerini temsil eder.

Çalışmanın bu aşamasında hareket izlerini hedef doğrultusunda kümelemek gerekir. Tez çalışmasında iki farklı yöntemle hareket izleri kümelenir. Kalabalık hareketlerini inceleyerek caddenin ya da bir grup hareketlinin düzensizlik davranış modelinin belirlendiği çalışmada görüntü altıgen ızgaraya bölünür. Kalabalık hareketi, her bir altıgen hücre içerisine denk gelen davranışı incelemek suretiyle kümelere ayrılmış olur. Anormal durum tespiti ve anormal durumların sınıflandırılması problemlerinde ise kalabalık hareketleri ortalama kayma ile kümeleme yöntemi (MSC) ile kümelerine ayrılır. Bu yöntem sayesinde, hareket kümeleri davranışın görüntüdeki konumuna bağlı olarak elde edilir.

Kümelere içerisine denk gelen hareket izleri örgü entropi (braid entropi) yöntemi ile yorumlanır. Örgü entropi hareket izlerinin, davranış süresince birbirleriyle, belli açı değerine göre iz düşümünde yaptıkları “çakışma” (cross) olayına bağlı bir düzensizlik değeridir. Hareket izlerinin yaptıkları “çakışma” olayının fazla olması, davranışın o derece düzensiz olduğunu gösterir. Bu yöntem sayesinde hareket kümeleri içerisine denk gelen davranışın düzensizliği farklı açılardan hesaplanabilir ve öznel vektörü elde edilebilir. Her bir hareket kümesi örgü entropi özellik vektörü ile sınıflandırma yöntemlerinde temsil edilir.

Bu aşamadan sonra, elde edilen hareket kümeleri çalışmanın hedefleri doğrultusunda işlenir. Bu tez kapsamında, hareketin davranış modelini belirlemek, görüntüdeki anormal durumları tespit etmek ve anormal olayları sınıflandırmak hedeflenir.

1.3. Motivasyon

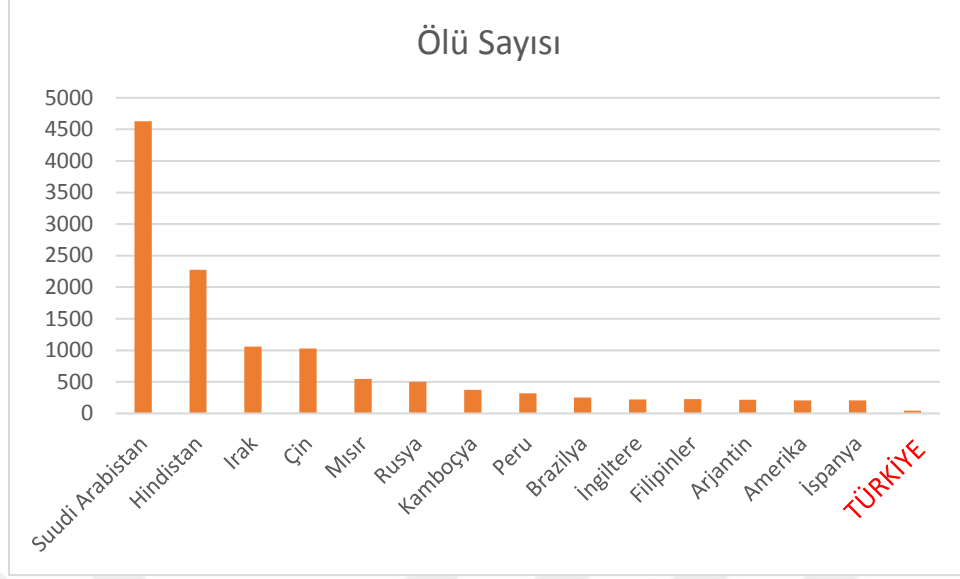
Günlük hayatın akışı kişileri kalabalıklara dâhil eder. Sokaklar, alış-veriş merkezleri, siyasi mitingler, stadyum ya da konserler kalabalığın yoğun olduğu mekânlardır. Sakin bir şekilde ilerleyen kalabalığın herhangi bir olay neticesinde aniden panik halinde koşuşan insanlara dönüşmesi muhtemeldir. Bu durum çok kısa sürede izdihama neden olabilir ve can kayıplarıyla sonuçlanabilir. Şüpheli davranışlar sergileyen tehlikeli bir kişinin kendisini kalabalık içerisinde saklaması oldukça kolaydır. Bunlar hayati tehlikesi muhtemel ve gerçekleşme olasılığı yüksek, feci olaydır. Nitekim insanoğlu böylesine acı olayları yaşamış ve üzücü tecrübeler edinmiştir.

Ali Asgary [8, 9], yaptığı çalışmalarda 1950'den bu zamana gerçekleşen, kalabalığın oluşturduğu izdiham, ezilmeler, panik hali, aşırı yoğunluk gibi olaylar neticesinde yaşanan ölümlü kazaların bilgileri verilmiştir. Bu çalışmaya göre, 1950'den bu zamana toplamda 15.794 kişi yaşamını yitirmiş, binlercesi de yaralanmıştır.

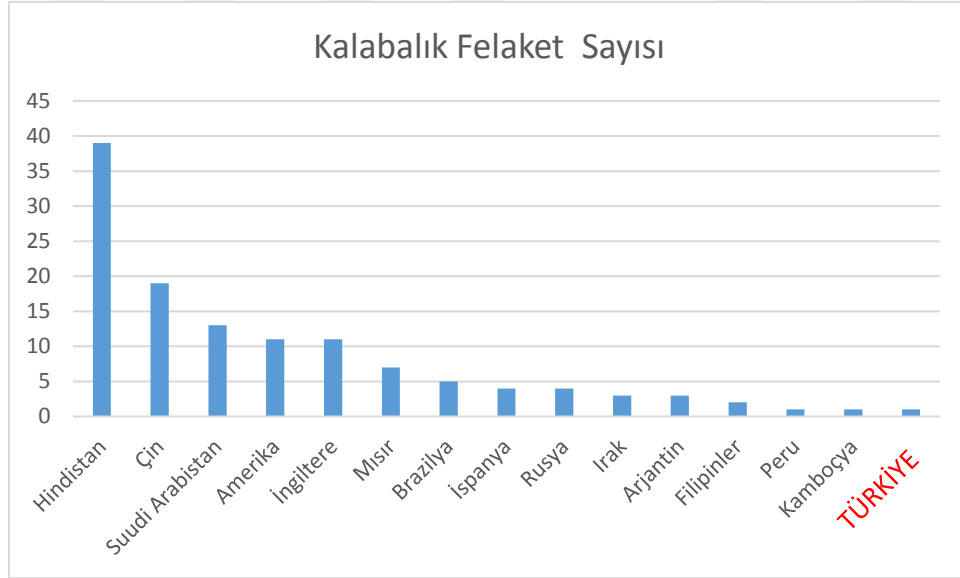
Şekil 1.3'de kalabalık felaketlerinin neticesinde gerçekleşen ölüm sayılarının ülkelere göre dağılımı gösterilmiştir. En fazla ölümün gerçekleştiği 14 ülke ve Türkiye'deki duruma yer verilmiştir. 17 Eylül 1967 yılında, Türkiye'nin Kayseri ilinde bir futbol müsabakası esnasında taraftarlar arasında yaşanan kavga ve izdiham neticesinde 43 kişi ölmüş, 300'e yakın kişi ise yaralanmıştır. Suudi Arabistan'da dini inançlarının gereğini yerine getirirken, 1950'den bu zamana farklı yıllarda gerçekleşen izdihamlar neticesinde toplamda 4631 kişi ölmüş, binlerce kişi ise yaralanmıştır.

Şekil 1.4'de ise en fazla ölüm olayının gerçekleştiği ülkelerde gerçekleşmiş felaket sayılarının grafiği gösterilmiştir. En fazla olayın 39 ile Hindistan'da olduğu görülmektedir. Türkiye'de ise 1967'de Kayseri'de 1 olay gerçekleşmiştir.

Yaşanan böylesine acı olaylar kalabalık davranış analizi konusu üzerine çalışmalar yapma ihtiyacını göstermiştir. Bilgisayarla görü, makine öğrenmesi, sosyoloji, psikoloji gibi farklı disiplinler bu konu üzerine yıllardır çalışmalar yapmaktadır. Bu tez kapsamında gerçekleştirilen çalışmalar ile güvenlik sistemlerini destekleyici, alternatif çözümler sunmak hedeflenmiştir.



Şekil 1.3. 1950 den bu zamana, kalabalık kazaları neticesinde en fazla ölümün gerçekleştiği ilk 14 ülke ve Türkiye'deki durum



Şekil 1.4. 1950 den bu zamana, kalabalık kazaları neticesinde en fazla ölümün gerçekleştiği ilk 14 ülke ve Türkiye'deki kaza sayıları

1.4. Kalabalık Analizinde Hareket Bölütleme

Kalabalık hareketlerinin bölütleme işlemleri 10 yılları aşkın bir süredir devam etmektedir. Konuyla ilgili hazırlanan derlemelerde çalışmalar kullanılan yöntemlere göre gruplara ayrılarak değerlendirilmiştir [10-15]. Bu derlemelerden Li vd. [12] kalabalık hareketlerinin bölütleme problemini


- Akış alanı tabanlı bölütleme (FFBS)
- Benzerlik tabanlı kümeleme (SBC)
- Olasılıksal model tabanlı kümeleme (PMBC)

olmak üzere 3 gruba ayırarak ele almıştır.

Akış alanı tabanlı bölütleme olarak gruplanan çalışmalarda genel itibari ile kenar tabanlı bölütleme (EBS), grafik tabanlı bölütleme (GBS) ve havza sınırlama tabanlı bölütleme (WBS) yöntemleri kullanılmıştır. Yüksek yoğunluklu kalabalık hareketlerini kümelemek için başarılı sonuçlar elde edilmiştir. Ancak uzun süreli takip ve çakışma problemlerinde çok da başarılı olarak değerlendirilmemiştir.

Zhou vd. [16], kullandığı tutarlı komşu değişmezliği (CNI) yöntemi ile kalabalık içerisinde hareketi temsil eden her bir hareket vektörün belirli sayıda k komşusu ile olan yakınlık-benzerlik ilişkisiyle dinamik olarak hareketi kümeleyebilmektedir. Benzer şekilde, Hu vd. [17], hareket alanları içerisindeki hareket vektörlerinin yönlerini ve birbirine yakınlığını kullanarak kümeleme işlemini gerçekleştirmiştir. Bir diğer çalışmasında [18] ise küme içerisindeki baskın hareket bilgisine dayalı kümeleme işlemi gerçekleştirmiştir.

Ali vd. [6], optik akışı yöntemiyle elde edilen hareket alanları, parçacık taşıma yöntemiyle hareket izleri haline dönüştürülmüş, FTLE yöntemiyle hareket bölütleri ederek hareket alanlarının sınırlarını belirlemiştir. Çalışmanın sonunda görüntüdeki kalabalık hareketlerini bölütlemiş, hareketli-hareketsiz bölgeleri sınırlayabilmiştir. Mehran vd. [19], geliştirdiği çıkış çizgisi yazılım çatısı (SF) ile akışkanlar dinamiği yöntemlerini, elde ettiği hareket izleri üzerine uygulayarak dinamik bir kümeleme sistemi ortaya koymuştur. Wang vd. [20], ise [19] deki çıkış çizgisi yöntemi kullanarak geliştirdiği platformu, yüksek hassasiyetli varyasyon modeli ile birleştirip kalabalık hareketlerini kümelemiştir. Wu vd. [21], yerel çeviri alanı (LTDS) model geliştirerek, bütün piksellerin optik akışı değerinden ziyade sadece göze çarpan (salient) alanlara odaklanarak bölütleme işlemini gerçekleştirmiştir.



Şekil 1.5. Kalabalık hareketlerinin bölütlenmesi [6].

Benzerlik tabanlı kümeleme olarak gruplanan çalışmalarda genel itibariyle, elde edilen hareket vektörleri hareket izleri (trajectory) haline dönüştürülerek bunlar arasındaki benzerlik ilişkilerine göre kümeleme işlemleri yapılır. Yapısal ve yapısal olmayan kalabalık hareketi sahnelerinde (SUCS) başarılı sonuçlar üretir. Ayrıca bu yöntem ile çakışma (overlapping), sahne tıkanıklığı (scene clutter) ve izleme hataları (tracking errors) gibi problemlere karşı etkili çözümler sunulmaktadır.

Cheriyedat vd. [22], baskın hareketi tespit etmek için çalışmasında, optik akışı ile elde edilen hareket vektörleri kullanılarak oluşturulan hareket izleri arasındaki uzaklık (LCSS) değerine göre kümeleme işlemi gerçekleştirmiştir. Zhao vd. [23], ise geliştirdiği hareket izlerine dayalı, danışmansız öğrenme modeli Tensor oylama (TV) ile yerel geometrik yapıları ve hareket örüntülerini açığa çıkarmaya çalışmıştır.

Jodoin vd. [24], ilişkisel izleme (MT) yöntemi ile baskın hareketi açığa çıkarmak istemiştir. Bu amaç için öncelikle her bir hareket vektörünün ODF değerini hesaplamıştır. Bu değer hareket vektörlerini yönlere göre dağılım bilgisini tutar. Sonra, ilişkisel izleme olarak ifade ettiği hareket yörüngelerini oluşturur. Son olarak hiyerarşik kümeleme yöntemi ile birbirine en çok benzeyen ilişkisel izleme verilerinden oluşan kümeler ile baskın hareketin örüntüsünü oluşturur.

Bölütleme çalışmalarının gruplandığı son bölüm ise olasılıksal model tabanlı kümeleme olarak isimlendirilir. Bu türden çalışmalar derlemelerde gaussian karışım modeli (GMM), rastgele alanlar modeli (RFT) ve gizli Dirichlet tahsisi (LDA) yöntemleriyle oldukça yaygın olarak kullanılmaktadır. Bu yöntemler sayesinde olayların ne zaman, nerede ve nasıl gerçekleştiği ile ilgili olasılıksal tahminlerin ölçüldüğü çalışmalar vardır.

Yang vd. [25], çalışmasında nesneyi tespit etme (OD) ya da izleme işlemlerine ihtiyaç duymadan, optik akışı ile elde ettiği hareket vektörlerinin yön ve konum değerleri ile oluşturulan yayılma haritası (DM) dağılımından yola çıkarak kümeleme işlemi gerçekleştirir. Benzer şekilde Salemi vd. [26], çalışmasında optik akışı ile elde edilen konum, yön ve

genlik değerlerinin GMM ile olasılıksal dağılımına bağlı sonuçlar üretmektedir. Zhou vd. [27, 28], çalışmalarında RFT yöntemi kullanarak yapısal olmayan mekânlarda semantik alanların tespit edilmesi problemine çözüm aramıştır. Ayrıca markov rastgele alanlar (MRF) ile hareket izleri arasında uzay-zamansal tutarlılık sağlanmaktadır.

Bu çalışmalara genel olarak baktığımızda, her bir çalışmada kalabalık hareketlerinden benzer hızda ve yönde olanlarını kümeleme bilmek hedeflenmiş ve bu kümelerin her bölgesinde benzer davranış gösterdiği kabul edilmiştir. Ancak, bizim çalışmamızda ise her bir kümenin davranışını daha yakından inceleyerek küme içerisindeki davranış farklılıklarını ortaya çıkarmak hedeflenmiştir.

Literatürde, kalabalık içerisindeki anormal davranışlar-durumlar birçok farklı anlamlarla tanımlanmış ve tespit etmek için birçok çözüm sunulmuştur. Ancak henüz anormal davranışın tanımı tek ve net bir şekilde belirlenememiştir [29]. Yapılan birçok çalışmada anormal durum, rutin bir davranışın değişmesi, beklenmedik bir olayın aniden gerçekleşmesi gibi tanımlara ifade edilmiştir. Bunlara ek olarak, kalabalık içerisinde bir kişinin diğerlerini aksi yönünde hareket etmesi, kişilerin yürüyerek belli bir hızda hareket ettiği bir ortamda bir kişinin-grubun diğerlerinden daha hızlı bir şekilde aynı ya da zıt yönde hareket etmesi gibi olaylarda literatürde yer alan anormal durumlar olarak gösterilmiştir.

Kalabalık hareketlerinin düzensizliğini inceleyen ve bu araştırmaya ilham kaynağı olan bir diğer çalışmada Saad Ali [30], farklı mekânlardaki kalabalık görüntülerini, örgü teori ile hesaplanan entropi değerlerine göre düşük-orta-yüksek seviyede düzensiz-düzenli kalabalık davranış hareketleri olarak sınıflandırmıştır. Ancak farklı mekânlardaki kalabalık hareketlerinin entropi değerini karşılaştırmak bu çalışmada kullanılan yöntemlerin özellikleri itibari ile her zaman sağlıklı sonuçlar vermeyebilir. Bahsi geçen çalışmada hareket bilgisi optik akışı yöntemi ile elde edilmiştir (ki bu çalışmada da aynı yöntem kullanılacaktır). Optik akışı yönteminde hareket bilgisini elde ederken kameranın hareketli nesnelere olan uzaklığı ve konum açısı önemlidir. Örneğin yakına konumlandırılmış bir kamera ile alınan hareketli nesnelere entropi değerinin yüksek çıkması olası bir sonuçtur ancak bu değer gerçekte de düzensizliği yansıtmayabilir. Aynı şekilde kalabalığa uzaktan bakan bir kamera ile alınan optik akışı hareket bilgisinin de entropi değeri düşük çıkar ancak bu sonuçta kalabalığın düzgün hareket ettiğini göstermeyebilir. Dolayısıyla bu çalışma ile farklı mekânların entropi değerini karşılaştırmak yerine, aynı görüntünün topolojik entropi değerinin bölgesel olarak ölçülüp değerlendirilmesi, karşılaştırılması ve bu değerlerin zaman içerisinde ne ölçüde değiştiği tespit edilmiştir.

1.5. Anormal Durum Tespit Etme

Yapılan çalışmalarda, genel itibari ile problem,

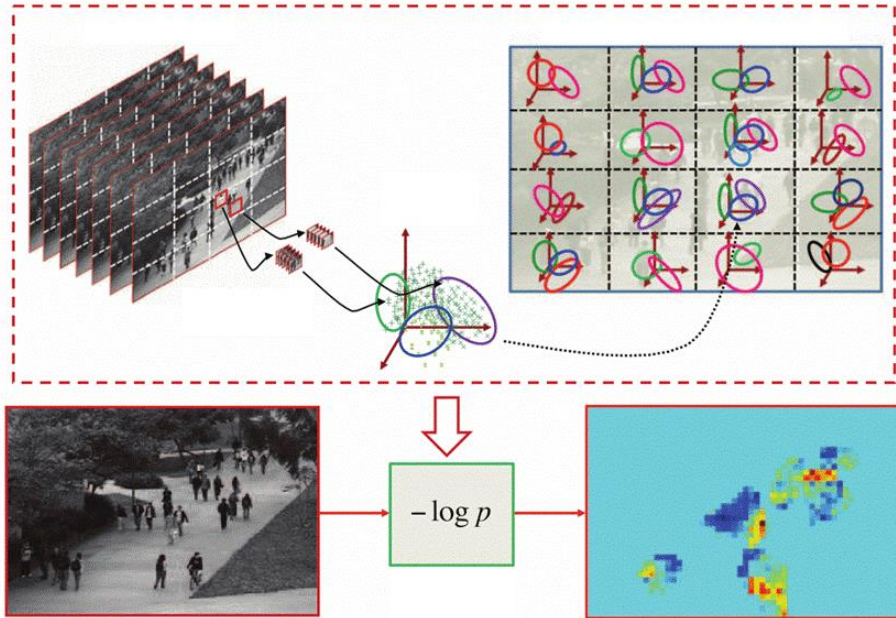
- Yerel anormal durum tespiti
- Global anormal durum tespiti

olmak üzere iki farklı yönüyle ele alınmaktadır [12, 31].

Genelde anormal durum tespiti çalışmalarında görüntüye genel olarak bakılır ve “Bu çerçevede anormal durum var mı?” sorusuna cevap aranır. Bu tür çalışmalar da belli bir video çerçeve dizisi için anormal durumun kaçınıcı çerçevede başladığını ve kaçınıcı çerçevede bittiğini tespit etmek gerekir [32].

Wu [33], çalışmasında Bayes’e dayalı yazılım çatısı geliştirmiş ve çerçeveleri “kaçış var” – “kaçış yok” (escape-nonescape) olarak etiketleyebilmiştir. Ancak bu çalışmada kullanılan yöntem yüksek yoğunluklu kalabalık davranışlarına uygulanamamıştır.

Yerelde anormal durum tespiti çalışmalarında ise anormal durumun gerçekleştiği konum çerçevenin tam olarak neresindedir, belirlemek hedeflenir. Bu tür problemlerin çözümü için literatürde hareket izleri çıkarımı ve alan hareket vektörleri olmak üzere genel olarak iki yaklaşım sunulmuştur [12].



Şekil 1.6. Dinamik süreçler [29].

Kartz [34], çalışmasında yüksek yoğunluklu kalabalıklarda yerel bölgelerdeki davranışı modellemek için bir yazılım çatısı sunmuştur. HMM ile görüntüdeki hareket geçişleri tanımlanır. Görüntü zamansal-mekânsal bölgelere ayrılır. Her bir bölge HMM ile modellenir. Bölge sayısı deneysel olarak belirlenir. Eğitim aşamasında ilgili bölgenin zaman içerisindeki davranışı belirlenir. Test aşamasında ise istatistiksel sapmalara bağlı sonuçlar üretilir. Sonuçlar yöntemin yüksek yoğunluklu kalabalık hareketleri için kullanılabilir olduğunu göstermektedir. Ancak yöntemin gereği her bir davranış için bir HMM kurulur ve sınırlı sayıda normal davranış için sistem kurulur. Bu durumda her yeni bir davranış için sistemi tekrar tekrar eğitmek gerekir. Benzer şekilde Wang [35] çalışmasında dalgalı dönüşüm yöntemleri ile yüksek frekanslı ve zamansal-mekânsal (HFST) değeri hesaplanır. Daha sonra anormal davranışı tespit etmek için çoklu HMM ile model eğitilir.

Li [29], sunduğu yöntem ile hareketin görünümü ve dinamik sürecine bağlı olarak kurduğu öğrenme modeli dinamik dokuların karışımı (MDT) ile zamansal ve mekânsal anormal durumları tespit etmeyi hedeflemiştir. Çalışması için oluşturduğu veri seti UCSD halen birçok anormal durum tespiti çalışmalarında kullanılmaktadır.


Roshtkhari [36], çalışmasında video kelimeler torbası (BOV) yöntemini kullanarak şüpheli davranışları tespit etmeyi hedeflemiştir. Bu yöntem, piksel seviyesindeki arka plan modelleme, zamansal-konumsal görüntü blokları ve hareket modellerinden elde edilen düşük seviye hareket özelliklerini kullanır.

Cong [32], sunduğu yeni yaklaşım seyrek yeniden yapılanma maliyeti (SRC) ile yerelde ve genelde anormal durum tespit etmek istemiştir. Yöntem, düzgün bir şekilde bölgelere ayrılan görüntünün her bir bölgesi için hesaplanan optik akışı hareket bilgisinin histogram dağılımına dayanır (MHOF).

Bera [37], iz tabanlı yaklaşım ile yerelde ve genelde anormal durum tespiti gerçekleştirmiştir. İzleme (tracking) algoritmaları ile gerçek zamanlı ve bayes öğrenme modeli kullanılarak başarılı sonuçlar elde etmişlerdir. Ancak yöntemin başarısı izleme algoritmaların başarısına bağlıdır.

Wang vd. [38], 3D eşit bölgelere ayrılan görüntüde her bir bölgenin SL-HOF ile hareket vektörlerinin histogram dağılımlarına bağlı bir yöntem önermiştir. Önerilen ULGP-OF ile görüntünün ön plan halinden bölgesel dokunun hareketi tanımlanır. Bu sayede görüntünün doku ve hareket bilgisi hesaplamaya dâhil edilir. Sonrasında önerilen OCELM öğrenme modeli ile sınıflandırma yapılarak anormal durumlar tespit edilir.

Khan vd. [39], sunduğu yöntem (KUGDA), komşu piksellerinin yönlerine ve baskın yöne göre tanımlanan *superpiksellerin* histogram dağılımına bağlı bir yöntemdir. Donanımsal FPGA eklentisi ile anormal durum tespiti de önemli parametreler olan hız, enerji ve bellek performansı da değerlendirilmiştir. Yöntemin başarısı K-means sınıflandırma yöntemi ile hesaplanmıştır.



Şekil 1.7. Hareket modelleme [36].

Hu vd. [40], literatürde geniş yeri olan LBP yöntemini vektör ve açı tabanlı değerler ile modifiye ederek (SCLBP) anormal durum tespiti için kullanmıştır.

Bertini vd. [41], zamansal-uzaysal HOG tanımlayıcısı ile hareket vektörlerinin dağılımına bağlı bir yöntem önermiştir. Danışmansız öğrenme yaklaşımı ile gerçek zamanlı uygulanabilir.

Ayrıca literatürdeki bazı çalışmalar da hareket vektörlerinin yoğunluk ve hız değerlerine bağlı entropi değeri ile anormal durum olup olmadığı tespit edilmeye çalışılmıştır. Colque vd. [42], görüntüyü yerel bölgelere ayırarak her bir bölgeye düşen hareket vektörlerinin hız, genlik ve entropi değerlerine göre histogram dağılımlarını oluşturmuştur (HOFME). Daha sonra bu değerler ile gerçekleştirdiği eğitim-test aşamalarıyla anormal durumları tespit etmek istemiştir. Ancak bu türden çalışmalar içinde yine, yüksek yoğunluklu kalabalık hareketlerdeki kesişim durumları gözden kaçabilir.

Yang [43] çalışmasında hareket vektörlerinin yoğunluk ve hız değerlerine göre oluşturduğu histogramlardan yerel baskı modeli (LPM) elde edilir. Daha sonra, SVM ve MF ile anormal durum tespit etmiştir. [44]' de Xiong kişilerin toplanması ve koşması olmak üzere 2 farklı tip anormal durum üzerinde çalışma yapmıştır.

1.6. Anormal Olayların Sınıflandırılması

Hareket ya da eylem tespiti ve sınıflandırılması problemleri bilgisayarla görü alanındaki önemli konu başlıklarındandır. Güvenlik sistemleri, hasta takip sistemleri, kişi-bilgisayar etkileşim sistemleri gibi birçok alanda olay ya da davranışların akıllı sistemler tarafından tespit edilmesi ve sınıflandırılması hedeflenir. Görüntü işleme ve makine öğrenmesi alanlarında kullanılan farklı metot ve yöntemlerle bu problemlere birçok alternatif çözümler tavsiye edilmiştir.

Bu türden çalışmaların amacı, video görüntülerindeki kişi-kişi gruplarının ya da ortamda gerçekleşen herhangi bir eylem ya da davranışın tespit edilmesi ve sınıflandırılmasıdır. Kişi aktivite tespiti çalışmaları basit uzuv hareketlerden karmaşık uzuv hareketlerine ve bütün bedenin hareketlerinden davranışın anlaşılmasına ve sınıflandırılmasına kadar geniş bir konuyu kapsar. Görüntüdeki kişinin davranışı “yürümek”, ”koşmak”, “zıplamak” vb. davranışlar olarak, kişi gruplarının davranışları ise “kalabalık olarak yürümek”, “kalabalık olarak koşmak”, “kavga eden kişiler” vb. davranış tipleri olarak etiketlenir. Birkaç saniyelik video görüntüsünden davranışların etiketlenmesi beklenir.

Bu türden çalışmalar, farklı poz ve kamera açıları, davranışın hareket hızı, kameranın hareket olan uzaklığı vb. değişkenlik gösteren parametrelerden dolayı çözülmesi zor problemlerdir.

Genel itibari iki aşama halinde problem ele alınır. Öncelikle hareketi temsil etme yöntemi belirlenir. Sınıflandırma yönteminde kullanılacak hareketin, davranışın ya da olayın öznitelik vektörünün belirlenmesidir. Hareket ya da davranışın başarılı bir şekilde temsil edilmesi sınıflandırmanın başarılı sonuç vermesini etkileyecektir. Sonraki aşama ise sınıflandırma yöntemidir.


Hareketi temsil etme yöntemleri ile “hareket en iyi hangi özellikleri ile temsil edilebilir?” sorusu cevaplanır. Yöntemler, hareketin ya da olayın bütünü ele alan bütüncül (holistic) bir yaklaşım veya hareketi bölgeler halinde değerlendiren bölgesel (local) bir yaklaşım olmak üzere iki çeşittir.

Literatürdeki çalışmalarda, hareketi temsil edecek öznitelik vektörlerinin manuel olarak uzman kişiler tarafından belirlendiği ya da öğrenme modelleri sayesinde sistemlerin belirlediği yöntemler bulunur.

Bütüncül yaklaşımlarda, davranışa bir bütün olarak bakılır ve hareketin bütünü öznitelik vektörünü hesaplamada kullanılır. Kişinin hareketleri 3 boyutlu konum-zaman bilgisi olarak işlenir ve davranışı temsil edecek öznitelik vektörü hesaplanır. Ancak bu yaklaşımlarda kişinin davranışını içermeyecek hareket bilgileri de öznitelik vektörüne gürültü olarak eklenebilir. Bu durum bütüncül yaklaşımların dezavantajı olarak söylenebilir.

Bobick vd. [45], geliştirdiği hareket enerji görüntüsü (MEI) ve hareket geçmiş görüntüsü (MHI) ile görüntüdeki hareket bilgisini kodlamaya çalışmışlardır. MEI hareketin görüntünün “neresinde” olduğunu hesaplarken, MHI buna ek olarak, “neresinde” ve “nasıl” meydana geldiğine odaklanır. Bu çalışma hareket tanımada başarılı sonuçlar üretebilmesine rağmen kamera açısı bu çözüm yöntemi için problem olmuştur. Weinland vd [46] ise bu çalışmaya ek olarak, geliştirdiği hareket geçmiş seviyesi (MHV) ile kamera açısı problemine alternatif çözüm üretmiştir. Çoklu kamera sisteminden aldığı bilgiyi 3 boyutlu olarak yorumlamış, fourier transform yöntemi ile konumdan ve dönmeden bağımsız özellikler elde edebilmiştir.

[47] ve [48] Poisson denklemleri kullanarak hareketi temsil edecek farklı örüntü özellikleri elde edebilmiştir. Hareketin şekli ile ilgilenir. Davranışın çeşitli lokal bölgelerinden hesaplanan değerler Poisson denklemleri ile görüntüyü temsil edecek genel bir öznitelik vektörü olarak elde edilir. Hareketin şekli ile davranışı temsil edecek bir diğer çalışmada ise [49] art arda ilerleyen görüntü çerçeveleri arasından geometrik yüzey özellikleri hesaplanır.



Şekil 1.8. Kalabalık hareketlerinin sınıflandırıldığı davranış türleri [50].

Hareketin şekli üzerinden gerçekleştirilen çalışmalara ek olarak optik akışı yöntemini kullanarak davranışı temsil edecek özellikler belirleyen çalışmalar da literatürde vardır [51-53]. Optik akışı yöntemi, davranışı art arda gelen çerçeveler arasından hareket vektörlerini hesaplamak için kullanılır.

Bütüncül yaklaşım ile hareket tespit etme ve sınıflandırma çözümlerinde karşılaşılan gürültü problemine karşı yerel çözümler nispeten alternatif çözümler sunmuştur. Yerel yaklaşımlarla davranışın tümünü değerlendirmek yerine sadece aktif bölgede ki davranışlar üzerine odaklanılmıştır. Tespit edilen ilgi noktaları ve hareket izleri sayesinde davranışın dönme, öteleme ve kamera açısı gibi faktörlerden bağımsız bir şekilde tespit edilmesini sağlamışlardır. Yerel bölge tespit edildikten sonra ilgili bölge için öznitelik vektörü hesaplanıp sınıflandırma yöntemleri ile bölgenin etiketlenmesi hedeflenmiştir.

Solmaz vd. [50], çalışmasında kalabalık hareketlerinin bölgesel olarak tespit etmiş ve davranışa göre etiketleyebilmiştir. Tespit edilen davranışın optik akışı hareket vektörlerinden jacobian matrisini hesaplamış ve matrisin öz değer ve öz vektör değerlerine göre davranışı etiketlemiştir. Etiketlediği davranış türleri ise “tıkanıklık, dağılım, düz, dairesel, çakışma” olmak üzere 5 çeşittir.

[54], Uzay-zaman ilgi noktaları ile uzayda ve zamanda değişimleri yüksek seviyede olan noktalar ile davranışı tespit etmeye ve tanımlamaya çalışmıştır. [55] ise Harris köşe noktalarını geliştirerek hareketi tespit etmiştir.

1.6.1. Değişinti Matrisi ile Hareketi Temsil Etmek

Kalabalık davranışlarını tespit etmek ve sınıflandırmak problemlerinin çözümünde kullanılan bir diğer yöntem ise davranışların değişinti matrisleri ile temsil edilmesidir. Hareketin genelinden ya da ilgili bölgesinden tespit edilen davranış hesaplanan değişinti matrisi ile öğrenme modelinde yer alır [56, 57].

Hareketi değişinti matrisi ile temsil etmenin bazı avantajları ve dezavantajları vardır. Avantajları:

- Davranışı temsil edecek farklı özellikleri birlikte, tek matris içerisinde toplamak mümkündür.
- Farklı davranışların farklı sayıda elemanları olsa da matrisin özelliği sayısınca boyutla sınırlamak mümkündür. Dolayısıyla her davranış eşit boyutta matris ile öğrenme modelinde temsil edilir.

Bu avantajlarla beraber, değişinti matrisleri Riemannian manifoldun da bulunur ve Öklid düzleminde gerçekleştirilen işlemler için uygun değildir. Değişinti matrislerini Öklid uzayına taşımak için Arsingny vd. [58], log-Öklid uzaklık metriği ve Affine-Invariant Riemannian metriği [56, 59, 60] önermiştir.

1.7. Kullanılan Veri Tabanları

On yılı aşkın süredir devam eden kalabalık davranış analizi çalışmaları araştırmacıların performans ve başarımlarını karşılaştırmalarını sağlıklı bir şekilde yapabilmeleri için ortak veri tabanları üzerinden gerçekleştirilir. Tez çalışmasının aşamalarında kullanılan veri tabanları kısa bilgileri ile birlikte aşağıda sıralanmıştır.

UCF kalabalık veri tabanı [6]; UCF CVPR (Merkezi Florida Üniversitesi, Görüntü İşleme Araştırma Merkezi), tarafından “BBC Motion Gallery” ve “Getty Images” sitelerinden toplanan görüntüler ile oluşturulmuş bir veri tabanıdır. 38 farklı video görüntüsü içerir.

UCF anormal durum veri tabanı [61]; UCF CVPR (Merkezi Florida Üniversitesi, Görüntü İşleme Araştırma Merkezi), tarafından hazırlanmıştır. 8 farklı anormal olay türünden toplamda 1900 video görüntüsü içerir.

UCSD anormal durum veri tabanı [62]; Peds1 ve Peds2 olmak üzere iki farklı mekândan elde edilen video görüntülerinden oluşur. Peds1, 34 eğitim – 36 test, Peds2 16 eğitim – 12 test videosu içerir.

UMN anormal durum veri tabanı [63]; 1’i kapalı, 2’si açık mekânlarda olmak üzere kontrollü bir şekilde hazırlanmıştır. 11 farklı senaryo içerir.

CUHK kalabalık veri tabanı [7]; 215 kalabalık sahnesi ve 474 video görüntüsünden oluşur.

1.8. Performans Ölçütleri

Yapılan çalışma sonuçlarının ne derece başarıya ulaştığı birkaç farklı yoldan hesaplanabilir. Bu bölümde kalabalık davranış analizi çalışmalarında sonuçların başarımlarının hesaplanması ve diğer çalışmalarla karşılaştırılması için kullanılan yöntemlerden bahsedilecektir.

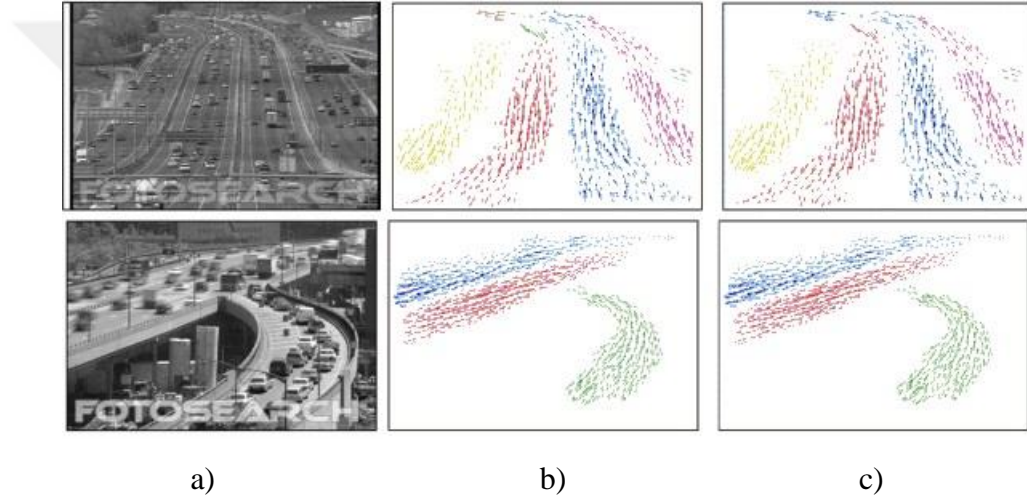
1.8.1. Yersel Doğruluk

Yersel doğruluk (ground truth) sistemin ürettiği sonucun beklenen değere ya da ürüne ne derece yaklaştığını yani ne derece başarılı olduğunu tespit etmek için manuel ya da

sistemler tarafından üretilen, istenen sonuçlar kümesidir [64, 65]. Sistemin ürettiği sonuçlar ve yersel doğruluk değerleri karşılaştırılarak başarımlar hesaplanabilir.

Kalabalık davranış analizi çalışmalarında bölütleme çalışmalarında kullanılır. Görüntüden sistemin ürettiği bölütler ile manuel olarak belirlenen yersel doğruluk bölütleri piksel seviyesinde karşılaştırılır ve başarımlar ortaya konur.

Örneğin, Hu vd. [17], çalışmasında görüntüdeki hareketli alanları bölütlerine ayırmıştır. Sonuçlarının başarısına verdiği yersel doğruluk görüntüsüne göre karar vermiştir. Bu çalışmadaki yersel doğruluk değeri bir kişi tarafından manuel olarak görüntüyü inceleyerek hareketi bölütlerine ayırmasıyla elde edilmiştir.



Şekil 1.9. Hareketli alanların bölütlenmesi a) görüntü b) çalışmanın sonucu c) yersel doğruluk değeri

1.8.2. İşlem Karakteristik Eğrisi

Sınıflandırma sonuçlarının yorumlanmasında kullanılan performans belirleme metriklerinden bir tanesi de işlem karakteristik eğrisidir (ROC). Farklı eşik değerler için hesaplanan, dikey ekseninde “duyarlılık”, yatay ekseninde ise “1-özgüllük” oranlarının bulunduğu bir grafikdir.

Hastalık tanı testleri, sinyal tanımları gibi farklı birçok disiplinde kullanılan bir istatistik karar yöntemidir. Testin ayırt etme gücünü ölçmeye, farklı testlerle başarımların karşılaştırılmasına, farklı eşik değerlerle verdiği sonuçları öğrenmeye olanak sağlar.

Kalabalık analizi çalışmalarının anormal olayları tespit etme problemlerinde başarımı ölçmek ve sonuçları diğer yöntemlerin sonuçlarıyla karşılaştırmak için işlem karakteristik eğrisi kullanılır. ROC eğrileri, eğrinin altında kalan alan (AUC) ve eşit hata oranı (EER) ile gerçekleştirilir. AUC'nin 1'e yaklaşması başarımın o nispete arttığını gösterir. AUC değerine göre farklı sonuçlar arasında başarımlar karşılaştırılması yapılabilir.

Anormal durum tespit edilmesine dair hata matrisi Tablo 1'de verilmiştir.

Tablo 1. Anormal durum hata matrisi

Anormal Durum	Var	Yok
Tespit Edildi	DP	YP
Tespit Edilmedi	YN	DN

DP (doğru pozitif): Gerçekleşen anormal durumun sistem tarafından da anormal durum olarak tespit edildiği sonuçtur.

YP (yanlış pozitif): Gerçekte anormal olmayan bir duruma sistemin hata ile anormal durum olarak belirlemesi sonucudur.

YN (yanlış negatif): Gerçekte anormal durum olmasına rağmen sistem hata ile anormal durumu tespit edememesi sonucudur.

DN (doğru negatif): Gerçekte anormal olmayan bir duruma sistemin de anormal durum olmadığını tespit etmesi sonucudur.


Duyarlılık ($DP/(DP+YN)$): Gerçekte anormal durumlar arasında sisteminde anormal durum olarak belirleyebilmesi oranıdır.

Özgüllük ($DN/(DN+YP)$): Gerçekte anormal olmayan durumlar arasında sisteminde anormal olmayan durum olarak belirleyebilmesi oranıdır.

1.9. Optik Akışı

Optik akışı yöntemi görüntüdeki hareket bilgisini elde etmek için piksel seviyesinde uygulanan bir yöntemdir [51, 66]. Yöntem, görüntünün artarda gelen çerçeve çiftleri arasındaki parlaklık (intensity) değerine bağlı olarak, x, y eksenlerinin zamana göre türev işlemi ile gerçekleşir. Bu sayede görüntünün piksel seviyesindeki hareketi, büyüklük ve yön bilgisi olarak elde edilir. Yöntem daha çok yüksek yoğunlukta ve düşük hızdaki hareket

bilgisini elde etmek için kullanılır. Bu şartlardaki görüntülerde daha başarılı sonuçlar ürettiği literatürde ifade edilir [67].



Şekil 1.10. Art arda gelen görüntüler ile elde edilen optik akışı hareket vektörleri

$$t = 1, 2, \dots, T$$

t , optik akışı çerçeve numarasını ifade eder. T , elde edilen toplam optik akışı çerçeve sayısıdır.

Optik kaynağının zamanla değişmediğini (1) ve t anında (x, y) konumundaki pixel'in, $t + 1$, anında (dx, dy) kadar yer değiştirdiği durumda bu eşitlikleri elde edebiliriz (2) [68].

$$\frac{dI}{dt} = 0 \quad (1)$$

$$I(x, y, t) = I(x + dx, y + dy, t + dt) \quad (2)$$

Taylor serisi kullanılarak işlemlere devam edildiğinde;

$$I(x, y, t) = I(x, y, t) + \frac{\partial I}{\partial x} dx + \frac{\partial I}{\partial y} dy + \frac{\partial I}{\partial t} dt + YDT \quad (3)$$

$$I_x u + I_y v = -I_t \quad (4)$$

Optik akışının genel formülü elde edilir (4).

$$I_x = \frac{\partial I}{\partial x}, \quad I_y = \frac{\partial I}{\partial y}, \quad I_t = \frac{\partial I}{\partial t}, \quad u = \frac{dx}{dt}, \quad v = \frac{dy}{dt} \quad (5)$$

Tek pikselin hareket bilgisi olarak elde edilen (4) denklemde bilinen I_x, I_y, I_t değerlerine karşılık bilinmeyen u, v değerleri vardır. Optik akışı yönteminin amacı x, y yönündeki hareket bilgisi olan u, v değerlerini hesaplamaktır.

Bu aşamada Lucas-Kanade' nin optik akışı için geliştirdiği yöntem kullanılarak çözüm geliştirilmiştir. Lucas-Kanade bir pikselin etrafındaki komşu piksellerle aynı hızda hareket ettiklerini kabul ederek pikselin hızını hesaplamıştır. Yani, 3×3 komşulu bir pikselin hareketini hesaplarken, bütün komşuların aynı hızda hareket ettiğini varsayarak denklem (4)'deki iki bilinmeyen u, v değerini bulmak için 9 denklem elde etmiş oluruz (6).

$$\begin{bmatrix} I_{x_1} & I_{y_1} \\ I_{x_2} & I_{y_2} \\ \vdots & \vdots \\ I_{x_9} & I_{y_9} \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} -I_{t_1} \\ -I_{t_2} \\ \vdots \\ -I_{t_9} \end{bmatrix} \quad (6)$$

A **d** **b**
 9x2 2x1 9x1

Örnekte 3×3 olarak seçilen komşu pencere (neighbor window, intergration window), problemin durumuna göre farklı boyutlarda seçilebilir [67].

Komşu pencere boyutunu küçük seçmek görüntüdeki ayrıntıları elde etmemizi sağlarken, bu detaylar görüntü karmaşıklığına neden olabilir ve sistemin performans yükü de oldukça artacaktır. Ayrıca görüntünün genel seyir bilgisini kaybetmemize de neden olur. Diğer taraftan büyük boyutlu bir komşu pencere, büyük ölçekli hareketleri yakalar ve görüntünün genel seyrini elde etmemizi sağlar ancak görüntüde oluşabilecek tıkanıklıklar ya da küçük hareketler fark edilemez. Bu konuda bir ödünleme söz konusudur. Çalışmamızda komşu pencere boyutuna deneysel sonuçlara göre karar verilmiştir.

6. denklem en küçük kareler yöntemiyle çözüldüğünde u, v elde edilebilir (8).

$$(A^T A)d = A^T b \quad (7)$$

2x2 2x1 2x1

$$\begin{bmatrix} \sum I_x I_x & \sum I_x I_y \\ \sum I_y I_x & \sum I_y I_y \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = - \begin{bmatrix} \sum I_x I_t \\ \sum I_y I_t \end{bmatrix} \quad (8)$$

Lucas-Kanade yöntemi ile optik akışı elde etmek için gerçekleştirilmesi gereken 4 temel aşama vardır.

1. Görüntülere gürültü azaltma işlemi uygulanır.
2. I_x, I_y, I_t hesaplanır.
3. 8. denklem hesaplanarak u, v değerleri bulunur.
4. Optik akışı değerleri birbirinden bağımsız ve genel akışa göre farklılık gösterebileceğinden sonuç değerlere (u, v) ortalama filtresi uygulanır.

1.10. Parçacık Taşıma

Optik akışı ile görüntünün çerçeve çiftleri arasındaki piksel seviyesindeki hareket bilgisi, parçacık taşıma yöntemi ile hareket izlerine (trajectory) dönüştürülür. Yöntem, ilk çerçeveden başlamak kaydı ile görüntüdeki her bir piksel üzerine yerleştirilen farazi parçacıkların, görüntü boyunca elde edilen optik akışı hareket bilgisine göre taşınması ile gerçekleşir. Bu sayede optik akışı ile elde edilen 3 boyutlu hareket bilgisi, 2 boyutlu gözlemlenebilir hareket bilgisi haline dönüştürülür [69].

Bu işlem parçacık taşıma (PA), her bir parçacığın aldığı yol ise parçacık hareket izi olarak adlandırılır.

Optik akışı çerçeve boyutu x eksenini m , y eksenini n olarak belirlendiğinde, idealde $N = m * n$ parçacık için işlem gerçekleştirilir. t anında x, y konumundaki i . parçacık $x_{i(t)}$, $y_{i(t)}$ ile gösterilebilir.

$$t = 1, 2, \dots, T$$

$$N = m * n$$

$$i = 1, 2, \dots, N$$

$$x_{i(t+1)} = x_{i(t)} + u[x_{i(t)}, y_{i(t)}] \quad (9)$$

$$y_{i(t+1)} = y_{i(t)} + v[x_{i(t)}, y_{i(t)}] \quad (10)$$

T , toplam çerçeve sayısını, $T - 1$ toplam optik akışı çerçeve sayısını ifade eder. t anında x, y konumundaki i . parçacığın, optik akışı yönteminden hesaplanan x yönündeki u

hareket bilgisi (9) ile y yönündeki v hareket bilgisinin eklenmesiyle (10), i . parçacığın $t + 1$ anındaki konumu belirlenir. Bu hesabın, kullanılan görüntüdeki piksel sayısı ile aynı sayıda parçacık için görüntünün sonuna kadar hesaplanması beklenir.

Her bir parçacık trj_i ile gösterilir ve görüntü boyunca takip ettiği yol;

$$trj_i = \{(x_{i(1)}, y_{i(1)}), (x_{i(2)}, y_{i(2)}), \dots, (x_{i(T)}, y_{i(T)})\} \quad (11)$$

ve her parçacığın bir araya gelmesiyle oluşan ve görüntüdeki hareket bilgisini temsil eden veri kümesi ise;

$$TRJ_t^{t+T} = \{trj_1, trj_2, trj_3, \dots, trj_N\} \quad (12)$$

olarak hesaplanır.


1.11. Örgü Entropi (Braid Entropy)

Topolojik entropi dinamik bir sistemdeki düzensizliğin bir ölçüsü olarak tanımlanabilir. Örgünün topolojik entropi değerinin ölçülmesi ile örgünün ne derece düzensiz bir sarmal yapıda olduğu hesaplanır [70, 71].

Braid'in kelime anlamı saç örgüsüdür. Teoriye göre, saç örgüsünü oluşturan sarmal hareketlerin matematiksel bir gösterimi vardır. Saç örgüsü oluşurken, gruplara ayrılmış saç telleri belli bir düzen ile sarmal yapıyı oluşturur. Sarmal yapı içerisindeki her bir saç tutamının diğerleri ile yaptıkları yer değiştirmelerin matematiksel karşılığı vardır. Nihayetinde bir sarmal örgü, saç tutamlarının artarda gerçekleştirdikleri yer değiştirmelerin simgesel gösterimi ile ifade edilebilir. Sarmal yapıyı ifade eden simgesel gösterimden yola çıkarak yapının ne derece karmaşık olduğu belirlenebilir. Örgü entropi teorisi, bu sarmal yapının düzensizliğini (entropi değerini) hesaplar.

Bu teoremin konumuz kalabalık akış düzensizliğine uyarlanması şu şekilde olur; parçacık taşıma yöntemi ile elde edilen her bir hareket izi, örgü entropi teorisindeki saç tutamları olarak düşünülür. Hareket izleri kalabalığın akışı boyunca sarmal bir yapı oluşturur. Dolayısıyla kalabalığın düzensizliğini hesaplamak problemi, hareket boyunca oluşan bu sarmal yapının düzensizliğini hesaplamak problemine dönüşür.

Fiziksel örgü, iç içe geçmiş 3 veya daha fazla hareket izinin oluşturduğu bir örüntü olarak tanımlanabilir (Şekil 1.11 a). İzlerin x eksenine (ya da herhangi bir eksen) ve zamana göre izdüşümü alınarak örgünün geometrik gösterimi oluşturulur ve bu işleme izlerin örgüye göre haritalanması denir (Şekil 1.11 b).



Şekil 1.11. a) 3 tane parçacığın taşınması ile oluşan hareket yörüngeleri, her bir yörünge yıldız hareketin başladığı konumu, nokta o an bulunduğu konumu ifade eder b) Her bir parçacığın x eksenine göre hareket bilgisinin zamana göre değişimi c) Hareket yörüngeleri [30, 72, 73].

1.11.1. Üretici Dizisi

İz düşüm işleminde izler, seçilen eksene göre konumları gözetilerek sıralanır. Sıralama sonucunda oluşan yer indeksleri, izlerin başlangıç kimliği olarak belirlenir. Örneğin, Şekil 1.11 (c)'deki cebirsel gösterimde 3 tane iz'in x eksenine göre iz düşümü alınmış ve 1 den 3'e kadar indeks değerleri verilmiştir. t ile $t+1$ zaman aralığında ise 1 "çakışma" işlemi gerçekleşmiştir. İzlerin, birbirinin önünden ya da arkasından yaptıkları yer değiştirmeler "çakışma" olarak isimlendirilir. Her bir *çakışma* işleminde 3 bilgi elde edilir.


Bunlar;

1. Çakışma zamanı
2. Çakışma yönü (saat yönünde ya da saat yönünün tersine)
3. Çakışma işlemin hangi izler arasında gerçekleştiğidir.

Örneğin, Şekil 1.11 (c)'de gösterilen sarmal yapıda, $t=1$ anında, 1. ve 2. hareket yörüngeleri arasında ve saat yönünde gerçekleşen kesişim (σ_1) ve $t=2$ anında 2. ve 3. hareket yörüngeleri arasında ve saat yönünün tersinde gerçekleşen kesişim (σ_2^{-1}) şeklinde simgesel olarak ifade edilir. Çakışma işleminin gerçekleştiği izlerden indeksi küçük olan simgenin numarası belirlerken, hareketin saat yönünde veya saat yönünün tersinde olması simgenin işaretini (\mp) belirler. Hareketin sonunda, gerçekleşen tüm çakışma işlemleri zamana göre

sıralanır ve bu dizilim “üretici dizisi (SOG)” olarak isimlendirilir [74, 75]. Denklem 13’ de gösterildiği gibi ifade edilir.

$$(\sigma_1 \sigma_2^{-1}) \quad (13)$$



1.11.2. Döngü Uzunluğu

Şimdiye kadar izler cebirsel gösterim ile temsil edildi ve üretici dizisi (SOG) hesaplandı. Bundan sonra ise bu bilgiler entropinin hesaplanması için kullanılır. Bu işlem “Döngü” kavramı ile gerçekleşir. Şekil 1.12’deki kırmızı noktalar izleri temsil eder. Hareket boyunca izler, birbirinin önünden ya da arkasından geçerek bir döngü oluşturur. Zaman içerisinde oluşan döngünün uzunluğu üssel bir şekilde artıyorsa, bu durum kalabalığın karmaşık bir davranış gösterdiğine işaret eder, aksi takdirde kalabalığın davranışı düz-basit bir seyir halindedir. Başka bir ifadeyle, döngü sayısının giderek artması, kalabalık akış hareketinin düzensizliğinin o derece arttığını gösterir. Şekil 1.12’deki başlangıç koordinat düzleminde dikey olarak gösterilen yeşil çizgilerden örgünün nasıl oluştuğu tespit edilebilir. μ_i ile parçacığın üstünde ya da altında gerçekleşen kesişim sayısı, v_i ile de parçacıklar arasındaki kesişim sayısı ifade edilir [74, 75].

Dynnikov koordinat sistemi, başlangıç koordinat düzlemindeki μ_i ve v_i değerlerinin farkını alarak döngünün davranışı ifade eder.

$$i = 1, 2, \dots, N - 2 \text{ olmak üzere } N, \text{ iz sayısını gösterir (14).}$$

$$a_i = \frac{1}{2}(\mu_{2i} - \mu_{2i-1}), b_i = \frac{1}{2}(v_{2i} - v_{i+1}) \quad (14)$$

a_i ve b_i komşu hareket izlerinin döngü içerisindeki hareket adımlarını gösterir ve Dymnikov koordinat sistemin ile tanımlanarak (u) döngüyü temsil ederler (15).

$$u = (a_i, \dots, a_{n-2}, b_i, \dots, b_{n-2}) \quad (15)$$

Bu bilgiler ile döngünün uzun hesaplanır. Bu işlem için Mousafir [70] kullanılmıştır. Döngünün uzunluğu, döngüdeki bütün hareket izlerinin birbirleriyle yaptıkları kesişime bağlı orantısal bir değerdir (Şekil 1.12'de yatay yeşil çizgi) (16).

$$L_q = |a_1| + |a_{n-2}| + \sum_{i=1}^{n-3} |a_{i+1} - a_i| + \sum_{i=0}^{n-1} |b_i| \quad (16)$$

Burada, $b_0 = -\max_{1 \leq i \leq n-2} (|a_i| + \max(b_i, 0) + \sum_{j=1}^{i-1} b_j)$ ve $b_{n-1} = -b_0 - \sum_{i=1}^{n-2} b_i$

Burada L_q nun büyüme oranı, döngünün zaman içerisindeki büyüme oranına bağlıdır.

1.11.3. Örgü Entropi Hesaplama

Son olarak, sonlu-zaman örgü entropi (FTBE) değeri hesaplanır. Hareket izleri, $I = [t_0, t_0 + T]$ zaman aralığı içerisinde değerlendirildiğinde,

$$entropy = \frac{1}{T} \log L_q \quad (17)$$

Denklem 17’de T , her bir altıgenin içerisindeki Örgü de gerçekleşen ilk çakışma ve son çakışma arasındaki zaman aralığıdır. FTBE, örgünün T zaman aralığında gerçekleştirdiği üssel olarak gerçekleşen çakışma işlemine bağlı düzensizlik değeridir [74-76].

Eğer L_q nun büyüme oranı yavaş ise döngü düz-basit bir hareketi temsil ediyordur. Diğer taraftan, eğer üssel bir büyüme varsa bu durum düzensiz-karmaşık bir hareketin olduğunu gösterir.

1.12. Gaussian Karışım Modeli

Gauss dağılımı, ya da normal dağılım, bir ortalama değer etrafında toplanmış rassal süreçlerin dağılımıdır. Gauss karışım modeli (GMM) ise, her biri birer Gauss olasılık dağılımıyla ifade edilen bileşenlerin farklı ağırlıklarda toplamından oluşur [77].

GMM, sinyal işlemede ve istatistiksel sınıflandırmada, olasılık yoğunluklarının sürekli ölçümlerinde veya özniteliklerin parametrik modellenmesinde sıklıkla kullanılmaktadır. GMM parametreleri bir veri kümesinde iteratif beklentinin en büyüklenmesi algoritması (Expectation-Maximization, EM) ile öncü model vasıtasıyla bulunabilmektedir.

GMM, M adet gauss dağılımının ağırlıklı toplamı olarak aşağıda gösterilmektedir.

$$p(x|\lambda) = \sum_{i=1}^M \omega_i g(x|\mu_i, \Sigma_i) \quad (18)$$

Burada , D boyutlu rassal vektörü (ölçümler veya özellikler), $\omega_i, i = 1,2,3, \dots, M$

karışım ağırlıkları ve $g(x|\mu_i, \Sigma_i), i = 1,2,3, \dots, M$ gauss yoğunluk bileşenleridir. Rastlantı değişkeni Gauss fonksiyonunun formülü aşağıdaki şekildedir (19).

$$g(x|\mu_i, \Sigma_i) = \frac{1}{2\pi^{D/2}|\Sigma_i|^{1/2}} \exp\left\{-\frac{1}{2}(x - \mu_i)' \Sigma_i^{-1} (x - \mu_i)\right\} \quad (19)$$

Burada $\sum_{i=1}^M \omega_i = 1$ olmak üzere, μ_i , ortalama vektörü, Σ_i deęişinti matrisini belirtir. GMM parametrelerinin tanımlanması için ortalama vektörlerinin, deęişinti matrislerinin ve karışım ağırlıklarının tüm yoğunluk bileşenlerinden elde edilmesi gerekmektedir.

$$\lambda = \{\omega_i, \mu_i, \Sigma_i\} \quad i = 1, 2, \dots, M$$

Verilen eğitim vektörlerine göre GMM yapılandırılmasında, GMM parametrelerinin (λ), eğitim vektörlerinin dağılımı ile uyuşacak şekilde kestirimi amaçlanmaktadır. Bu problem üzerine GMM parametrelerinin kestirimi için bazı yaklaşımlar mevcuttur. Bu yaklaşımların içerisinde günümüzde kullanılan en popüler ve başarılı yaklaşım beklenti maksimizasyonu (EM) kestirimidir.

EM algoritmasının adımları

1- Diğer kümeleme algoritmalarında olduğu gibi GMM de başlangıç parametrelerinin θ^0 belirlenmesi gerekmektedir. Başlangıç parametrelerini belirlemek için öncelikle K-means algoritması kullanılır. Bu sayede, ortalama deęer (μ_M^0), varyans (σ_M^0), ve ağırlıklar (ω_M^0) parametrelerin başlangıç deęerleri belirlenir.

E-adımı: i elemanı için sonsal olasılık (posteriori probability) Denklem 20' deki gibi elde edilir.

$$p(i|x_t, \lambda) = \frac{\omega_i g(x_t|\mu_i, \Sigma_i)}{\sum_{k=1}^M \omega_k g(x|\mu_k, \Sigma_k)} \quad (20)$$

M-adımı: ortalama deęer (μ_M^i), varyans (σ_M^i), ve ağırlıklar (ω_M^i) deęerleri güncellenir.

E ve M adımlarına belirlenen hata miktarı yakınsanıncaya kadar devam edilir.

1.13. Ortalama Kayma Algoritması

Ortalama kayma algoritması istatistiksel ve verinin nispeten daha fazla kümelendiği bölgeleri tespit etmeye yarayan bir yöntemdir [78-80].


Geleneksel ortalama kayma algoritması, ortalama kayma vektörünü Δx hesaplayarak nesne merkezinin gerçekleştirmiş olduğu hareketi değerlendirir. Başlangıç nesne pozisyonunun \hat{x} ve hesaplamak istediğimiz yeni nesne pozisyonunun \hat{x}' olduğunu düşünürsek, $\hat{x}' = \hat{x} + \Delta x$ olur. Buna göre ortalama kayma vektörü Denklem 21 olarak hesaplanır.

$$\Delta x = \frac{\sum_i K(x_i - \hat{x})w(x_i)(x_i - \hat{x})}{\sum_i K(x_i - \hat{x})w(x_i)} \quad (21)$$

Burada kullanılan $K(\cdot)$ çekirdek fonksiyonu radyal simetrik bir yapıya ve h genişliğine sahiptir.

1.14. En Yakın Komşu Sınıflandırıcı

En yakın komşu sınıflandırıcı, danışmanlı bir sınıflandırma yöntemidir. Sistem, sorgulanan elemanın uzayda yakın olduğu kümenin etiketini almasına dayanır. Hangi sınıfa ait olduğu bilinen yani etiketli elemanların sırası ile sorgulanan elemana olan uzaklığı hesaplanır. Sorgulanan eleman hangi kümenin elemanına daha yakın ise o kümenin etiketi olarak etiketlenir [81, 82].



Şekil 1.13. En yakın komşu sınıflandırıcı

Şekil 1.13’de kırmızı ve yeşil renkler olarak etiketlenen elemanlar gösterilir. Hangi sınıfa ait olduğu bilinmeyen eleman ise öncelikli olarak siyah renk ile gösterilmiştir. En yakın komşu sınıflandırma yöntemi ile siyah renkli eleman hangi sınıfın elemanına daha yakın ise o sınıfın elemanı olarak etiketlenir.

Yöntemde elemanlar arası uzaklık hesaplanmalıdır. Bu uzaklık Öklid ya da Manhattan olmak üzere farklı uzaklık ölçer metrikleri ile hesaplanabilir.

$q = [q_{x1}, q_{x2}, \dots, q_{xn}]$ ve $p = [p_{x1}, p_{x2}, \dots, p_{xn}]$ olmak üzere Öklid uzaklığı Denklem (22)’de gösterildiği gibi hesaplanır.

$$\begin{aligned} d(q, p) &= \sqrt{(q_{x1} - p_{x1})^2 + (q_{x2} - p_{x2})^2 + \dots + (q_{xn} - p_{xn})^2} \\ &= \sqrt{\sum_{i=1}^n (q_{xi} - p_{xi})^2} \end{aligned} \quad (22)$$

En yakın komşu sınıflandırma yönteminin bir diğer kullanımında ise en yakın k tane komşuya göre karar verilir. Sorgulanan eleman kendisine en yakın k tane kümeye bakılır. k tane kümeden hangi küme en fazla bulunur ise sorgulanan eleman fazla bulunan kümeye etiketlenir.

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Kalabalığın Davranış Modelini Belirlemek

Kalabalığın nasıl bir davranış gösterdiğini anlamak için gerçekleştirilen birçok çalışmada öncelikli olarak kalabalık, hareketli-hareketsiz bölgelere ayrılır. Hareketli alanlar içerisinde benzer davranış gösteren ve konum olarak birbirine yakın hareketli nesnelere kümelendir. Sonuç olarak kümelenen davranışların tanımlanması/sınıflandırılması hedeflenir.

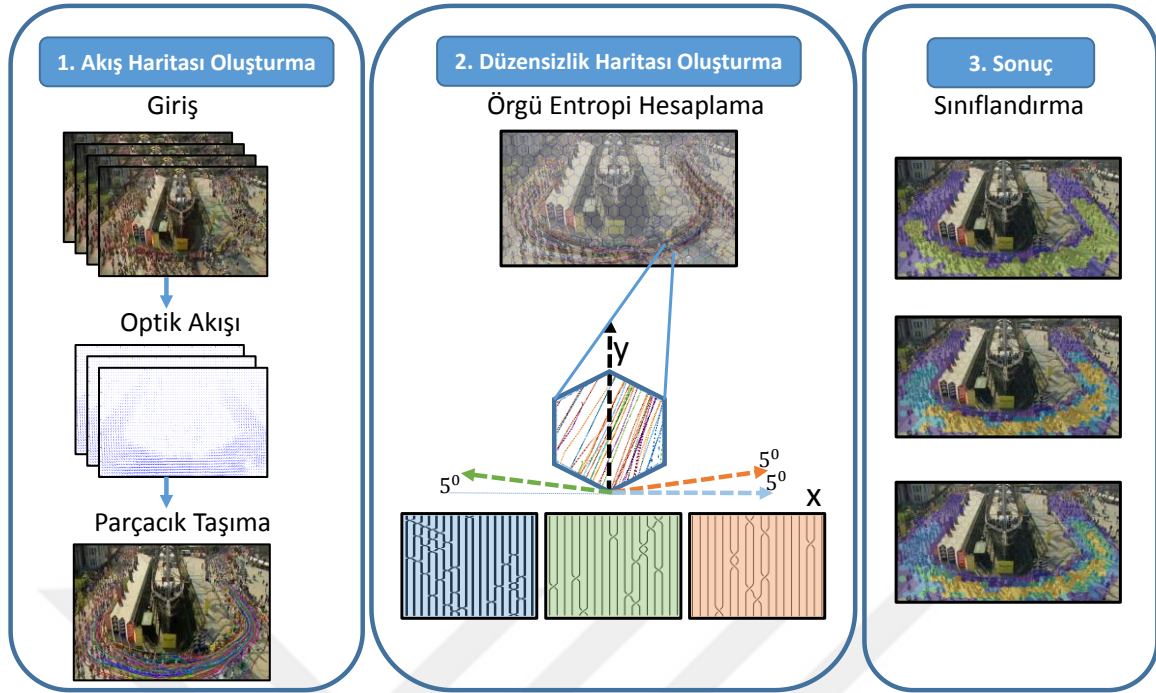
Birçok çalışmada, aynı yöne doğru, benzer hızlarda ve konum olarak birbirine yakın hareketlilerin aynı türden bir davranış gösterdiği kabul edilerek bir küme olarak belirlenir. Ancak bu kümeler içerisindeki kalabalık hareketleri her bölgesinde aynı davranışı göstermeyebilir. Bazı bölgelerinde ne derece bir etkileşim/düzensizlik olduğunu tespit etmek, kalabalığın davranışını anlamak adına önemli bir sonuçtur.

Tezin bu bölümündeki amacı, caddenin davranış modelini belirlemektir. Kalabalığın içerisinde, kişiler arasında ne derece bir etkileşim/düzensizlik olduğunu hesaplamak ve bu sayede farklı düzensizlik seviyesinde gerçekleşen davranışları farklı sınıflar halinde tespit etmektir. Bu sonuçlar kalabalığın davranışını daha iyi anlamamızı ve yorumlamamızı sağlayacaktır.

Çalışmanın basamakları Şekil 2.1’ de gösterilen aşamalar halinde sunulacaktır.

Öncelikli olarak optik akışı yöntemi ile elde edilen hareket vektörleri, parçacık taşıma yöntemi ile hareket izleri haline dönüştürülür. Hareketli nesnelere görüntü boyunca yaptığı davranışlar hareket izleri olarak temsil edilir ve “Akış haritasını” oluşturur (Bölüm 2.1.1). “Akış haritası” sisteme girdi olarak verilir.

Daha sonra görüntü, altıgen ızgara halinde hücelere bölünür (Bölüm 2.1.2). Her bir hücrenin içerisine denk gelen hareket izleri ile örgü örüntüsü oluşturulur. Örgü, 3 veya daha fazla hareket izlerinin, zaman içerisinde, birbiri arasında yer değiştirmeleriyle oluşturdukları sarmal bir örüntü olarak tanımlanır. Hareket izlerinin zaman içerisinde herhangi bir açı değerine göre konumlarının nasıl değiştiği takip edilir. Yani hareket izlerinin herhangi bir açıya göre konumlarının iz düşümü alınır (Bölüm 2.1.3). Hareket izlerinin birbirleriyle yaptıkları yer değiştirmelerin yani “çakışma” olaylarının simgesel bir karşılığı vardır.



Şekil 2.1. Çalışmanın basamakları

Örgü örüntüsünün ilgili iz düşüm değeri için entropi değeri bu simgesel karşılığına bağlı olarak hesaplanabilir.

Sonraki aşamada, görüntünün altıgenlere ayrılmış her bir hücreinde düzensizlik-karmaşıklık değeri “örgü entropi” ile hesaplanır. Böylece kalabalık davranışının “düzensizlik haritası” oluşturulur (Bölüm 2.1.4). Örgü entropi değerinin nasıl hesaplandığı detayları ile Bölüm 1.11’de anlatılmıştır.

Son olarak, elde edilen “düzensizlik haritası” bilgisine göre GMM ile sınıflandırma yapılarak, kalabalık hareketleri içerisinde farklı düzensizlik seviyesindeki davranışlar sınıflar halinde birbirlerinden ayrılır.

Çalışmanın sonunda, yöntem ayrıca UCF [83] ve CUHK [84] veri tabanlarından toplam 49 farklı görüntü üzerinde test edilerek elde edilen nicel ve nitel sonuçlar yer alır (Ek-2).

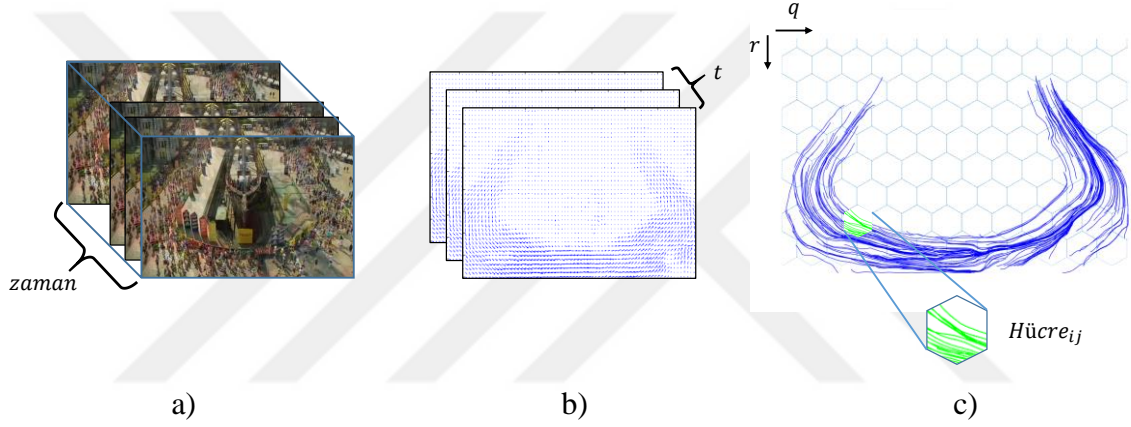
Genel itibariyle çalışmanın katkıları şu şekilde gruplandırılabilir.

- Aynı yönde ilerleyen ve birçok çalışmada bir küme olarak ifade edilen hareketli grubunun içerisinde ne derece bir etkileşim-düzensizlik olduğu bölgesel olarak hesaplanabilir.

- Görüntünün bütünü ele alındığında, hareketli alanlardaki düzenli-düzensiz davranışlar sınıflandırılabilir ve belli zaman aralıkları için caddenin davranışı modellenilebilir. Bu sayede kalabalık hareketinin akışı hakkında genel bir kanaat elde edilir.

2.1.1. Akış Haritası Oluşturmak

Akış haritası görüntüdeki hareket bilgisini izler halinde elde etmek için oluşturulur. Akış haritası, parçacık taşıma yönteminde kullanılan ve görüntüdeki hareket bilgisini taşıyan farazi parçacıklardan oluşur (23-25).



Şekil 2.2. a) Sistemin çerçeve girdisi b) Optik akışı sonuçları c) Parçacık taşıma sonuçları, hürelere ayrılmış görüntüden $Hücre_{ij}$ hücresinin içerisine denk gelen hareket izleri yeşil ile renklendirilmiştir.

$$t = 1, 2, \dots, T$$

$$N = m * n$$

$$i = 1, 2, \dots, N$$

$$trj_1 = \{(x_{11}, y_{11}), (x_{12}, y_{12}), \dots, (x_{1T}, y_{1T})\} \quad (23)$$

$$trj_2 = \{(x_{21}, y_{21}), (x_{22}, y_{22}), \dots, (x_{2T}, y_{2T})\} \quad (24)$$

⋮

$$trj_N = \{(x_{N1}, y_{N1}), (x_{N2}, y_{N2}), \dots, (x_{NT}, y_{NT})\} \quad (25)$$

$$Akış\ Haritası = \{trj_1, trj_2, \dots, trj_N\} \quad (26)$$

Buradaki t , t . çerçeve sayısını, T , toplam çerçeve sayısını (Şekil 2.2 a), $(trj_1, trj_2 \dots)$ hareket izlerini ifade eder. Görüntüyü temsil eden “Akış Haritası” (26) (Şekil 2.2 (c)’ de mavi izler olarak gösterilmiştir), sistemin girdi değeri olarak kullanılabilir. Parçacık taşıma yönteminin temel aşamaları ve nasıl uygulandığı Bölüm 1.10’ da anlatılmıştır.

Görüntüdeki durağan alanların, gürültülerin ve yeterince mesafe almayan parçacıkların görüntüyü temsil yeteneği olmadığından, ortalama mesafeden daha az hareket eden hareket izleri sonraki aşamalarda hesaplamaya dâhil edilmezler.

2.1.2. Görüntüyü Altıgen Bölgelere Ayırmak

Tezin bu bölümünün özgün değeri, görüntünün bütünü ele alıp hareket bilgisinin entropi değerini hesaplamak ve diğer farklı görüntülerle ya da görüntünün ilerleyen çerçeveleriyle karşılaştırmak değil, mevcut çerçeveyi eşit hücrelere bölerek hareketi yorumlamaktır. Bu sayede, hareketi semantik bölütlere ayırmak, her bir hücrenin entropi değerini komşu parçalarla karşılaştırmak ve bütün bir hareketin hangi bölümlerinde entropi değeri nasıl değişiyor takip etmek, mümkün olabilir.

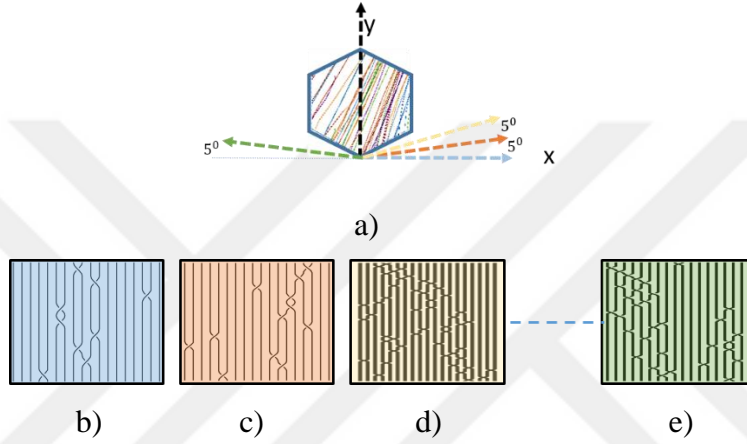
$$Hücre_{ij}, \quad i, j = \{(1,1), (1,2), \dots, (q, r)\} \quad (27)$$

Bu amaç için çerçeve altıgen ızgara ile bölünür (Şekil 2.2 c). Toplam da $q * r$ tane hücrenin adres değerleri belirlenir (27). Akış haritasındaki her bir hareket izi, hücrelerin içerisine denk gelen parçalarına göre bölünür. Örneğin, Şekil 2.2 (c)’de $Hücre_{ij}$ içerisine denk gelen hareket izlerinin parçaları yeşil çizgiler halinde gösterilmiştir. Bu aşamadan sonra işlemler her bir hücreye denk gelen iz parçalarına göre gerçekleşecektir.

2.1.3. İz Düşüm İşlemi

Kalabalık akış hareketlerinden elde edilen hareket yörüngelerinin örgü entropi teorisi yöntemi için düzenlenmesi gerekir. Yöntemin şartı gereği, örgüyü oluşturan hareket izlerinin yönü her zaman ileriye doğru olmalıdır [71]. Şekil 2.2 (c)’de gösterilen hareket izlerinin herhangi bir açıdaki iz düşümünün zamana göre değeri alındığında örgü entropi yöntemi için ön koşul sağlanmış olur.

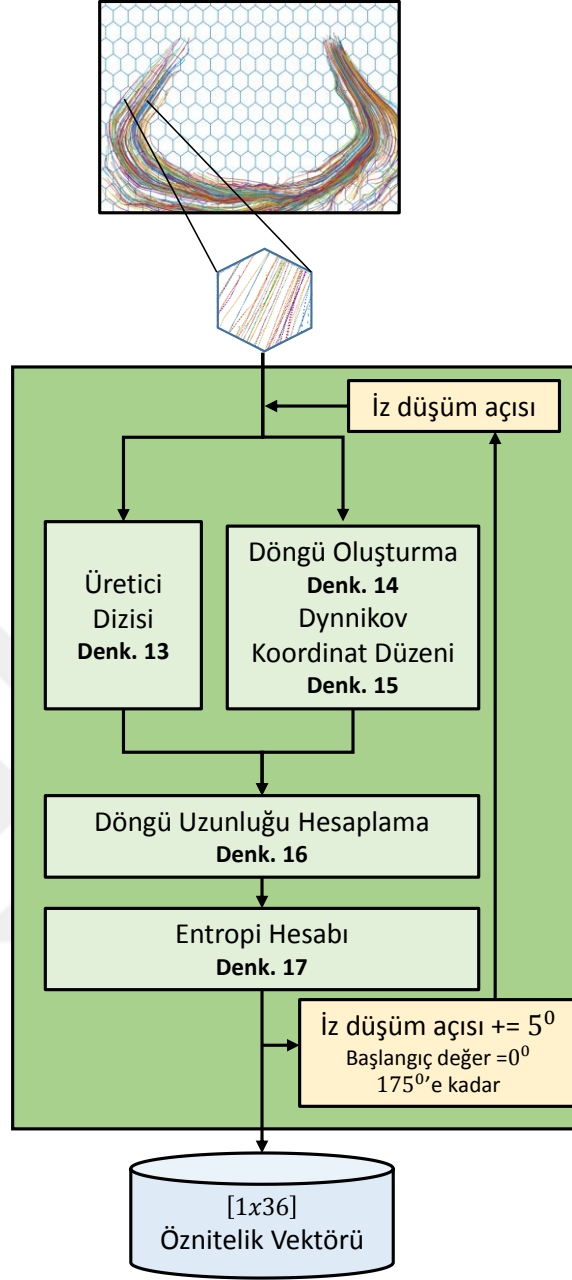
Bu çalışma için her bir hücrenin içerisindeki hareket iz grubuna 5^0 derecelik aralıklarla iz düşüm işlemi uygulanır (Şekil 2.3 a). Yani iz grubuna 36 farklı açıdan bakılarak izler arasındaki çakışmalar keşfedilir. Her bir açı değerine göre hücrenin örgü entropi değeri hesaplanır. Hesaplama işleminin aşamaları Şekil 2.4’de gösterilmiştir. Hesaplama kullanılan yöntemlerin detaylı bilgisi Bölüm 1.11’de anlatılmıştır. Ayrıca hareket boyunca yapılan çakışma işlemleri, ilgili iz düşüm açısı için özgün değerlerdir. Bu sayede her bir hücrenin 36 farklı örgü entropi değeri hesaplanır (28).



Şekil 2.3. a) Hücreye 5^0 aralıklarla uygulanan iz düşüm işlemi sonunda her bir açı değeri için elde edilen *çakışma* olayları b) x eksenine c) 5^0 d) 10^0 e) 175^0 açı değeri için elde edilen *çakışma* olaylarının gösterimi

$$Entropi_{Hücre_{ij}} = [b_1, b_2, b_3, \dots, b_{36}] \quad (28)$$

Bu değerler altıgenin 36 farklı açıdan tespit edilmiş, düzensizlik davranışını gösteren sonuçlardır. Farklı açılardaki eksenlere iz düşüm işlemi ile elde edilen kesişim durumları, renkleri ile uyumlu bir şekilde, Şekil 2.3 (b,c,d,e)‘ de gösterilmiştir.



Şekil 2.4. Her bir hücre için örgü entropi teoremi ile öznitelik vektörü hesaplanmasının işlem basamakları

2.1.4. Düzensizlik Haritası

Son olarak denklem (28)' de $Hücre_{ij}$ için hesaplanan 1×36 boyutundaki örgü entropi öznitelik vektörü (Şekil 2.4), ızgaradaki bütün hücreler için hesaplanarak ilgili k anında ki “düzensizlik haritası” oluşturulur. Düzensizlik haritası, var olan bütün k değerleri için hesaplanır (29).

$$k = 1, 2, \dots, L/T$$

$$L = \text{toplam çerçeve sayısı}$$

$$T = \text{her bir } k' \text{ da işlenen çerçeve sayısı}$$

$$\text{Düzensizlik Haritası}_k = \left\{ \text{Entropi}_{Hücre_{ij}}^k \right\}, \quad (29)$$

$$i, j = \{(1,1), (1,2), \dots, (q, r)\}$$

2.1.5. Kalabalığın Davranış Modeli Sonuçları

Düzensizlik haritası, literatürdeki birçok çalışmada gösterilenin aksine, aynı yönde ilerleyen yüksek yoğunluklu bir kalabalık grubu ya da akış hareketinin her bölgede aynı davranışı göstermediği sonucunu ortaya koymuştur. Diğer bir ifadeyle, aynı yöndeki kalabalık hareketlerinin içerisinde etkileşim-düzensizlik durumlarının fazla ya da az olduğu bölgeler vardır. Bu bölgeler tespit edildiğinde ve görüntüdeki harekete bir bütün olarak bakıldığında, kalabalığın davranışı düzensizlik açısından daha iyi anlaşılabilir.

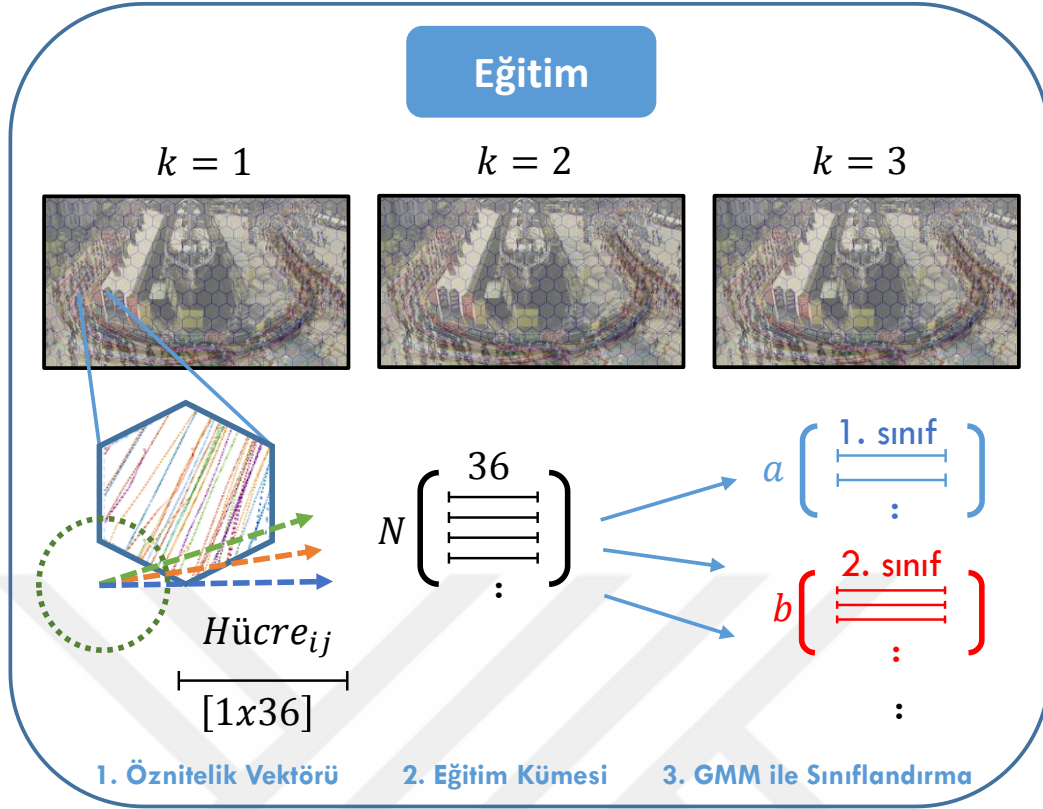
2.1.5.1. Davranış Modeli Eğitim ve Test Aşamaları

Danışmansız bir öğrenme modeli olan Gaussian karışım modeli (GMM) ile kalabalık hareketleri içerisinde farklı seviyede düzensizlik gösteren bölgeler sınıflandırılmıştır.

Öğrenme modeli eğitim ve test olmak üzere iki aşamada tamamlanır.

Her bir hücre, örgü entropi yöntemi kullanılarak 5^0 'lik aralıklarla hesaplanan 1×36 boyutlu bir öznitelik vektörü ile öğrenme modelinde temsil edilir. Sadece içeresine hareket izleri düşen hücreler hesaplamaya dâhil edilirler.

UCF veri tabanındaki maraton koşusu görüntüsü için öğrenme modeli şu şekilde oluşturulur.



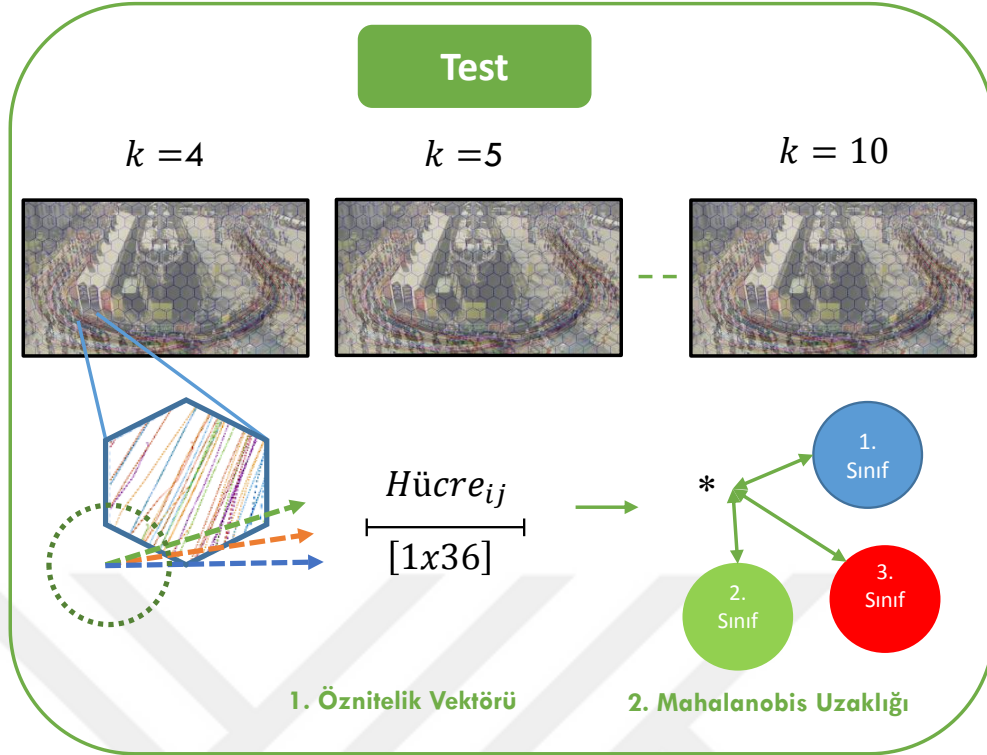
Şekil 2.5. Eğitim aşamasında, her bir hücre için öznitelik vektörünün oluşturulması, eğitim aşamasında kullanılan p değeri için her bir hücreden oluşan eğitim kümesi ve GMM ile sınıflandırma sonucunda elde edilen sınıflar

Maraton koşusu görüntüsünde boyutları 1000×620 piksel olmak üzere toplam $l = 500$ çerçeve bulunur. Görüntü $T = 50$ çerçevelik bölümlere ayrılır. Her bir bölüm k ile gösterilir. Toplamda $k = 1, 2, \dots, 10$ için bölümler elde edilir. Eğitim aşaması için $k = 1, 2, 3$ ve test aşaması için $k = 4, 5, \dots, 10$ ayrılır. Her bir görüntü düzgün altıgen ızgara ile hücrelere bölünür. Her bir hücrenin köşegen uzunluğu, düzgün altıgenler için kenar uzunluklarına eşittir. Bu deney için köşegen uzunluğu $r = 15$ piksel olarak işlemler gerçekleştirilmiştir.

Eğitim aşaması Şekil 2.5' te gösterildiği gibi 3 aşamadan oluşur.

1. Öznitelik vektörü oluşturmak:

Her k bölümü için optik akışı yöntemi ve parçacık taşıma yöntemi kullanılarak akış haritası oluşturulur. Görüntü altıgen hücrelere ayrılır. Her bir hücreye denk gelen hareket izlerinin örgü entropi yöntemine 5^0 lik aralıklarla düzensizlik değeri hesaplanır. Böylece hücrenin $[1 \times 36]$ boyutunda öznitelik vektörü elde edilir.



Şekil 2.6. Test aşaması

2. Eğitim kümesi oluşturmak:

$k = 1, 2$ ve 3 için her bir hücrenin öznitelik vektörü oluşturulur ve toplamda $[N \times 36]$ boyutlu bir eğitim kümesi elde edilir.

3. GMM ile sınıflandırma:

Eğitim kümesi GMM ile sınıflara ayrılır. Sınıflandırma sonucu, $\{[ax36], [bx36], \dots\}$ boyutlarda sınıflar elde edilir.

Test aşaması ise Şekil 2.6' da gösterildiği gibi gerçekleştirilir. Test için ayrılan $k = 4, 5, \dots, 10$ bölümleri için de her bir hücrenin öznitelik vektörü hesaplanır ve eğitim aşamasında belirlenen sınıflara olan mahalanobis uzaklığına göre en yakın sınıfa etiketlenir. Bu sayede kalabalık hareketleri içerisinde farklı özellik düzensizlik davranışları gösteren bölgeler sınıflara ayrılarak belirlenir.


Şekil 2.7 - 2.8 - 2.9'da 2, 3 ve 4 sınıf için elde edilen sonuçlar yer almaktadır. Sınıf sayısı arttıkça daha hassas bir sınıflandırma olduğu görülmektedir. Farklı düzensizlik seviyesindeki davranışlar birbirinden ayrılmıştır. Düzgün hareketin olduğu bölgeler ve dönme olayının olduğu bölgeler farklı sınıflar halinde tespit edilmiştir. Dönme olaylarının olduğu hücrelerde büyük ihtimalle kişiler arasında etkileşim düzensizliğe yol açmıştır.

Bu deęerler ile tespit edilmek istenen bir dięer sonu ise, farklı sınıflar halinde elde edilen davranışların zaman ierisinde blgesel olarak nasıl deęiřtięini de gzlemektir. Bu sayede ilgili caddedeki grnt iin kalabalıęın davranışı daha iyi anlaşılabilir. Zaman ierisinde sınıfların hcrelere gre daęılımının nasıl deęiřtięi artan k deęerleri ile birlikte gsterilmiřtir.


Farklı dzensizlik seviyesindeki sınıfların farklı k blmleri iin ortalama entropi deęerinin nasıl deęiřtięi Őekil 2.10'da entropi zet grafięi ile zet halinde gsterilmiřtir. Her bir k blm iin sınıfları oluřturan hcrelerin ortalama rg entropi deęerleri hesaplanmıřtır. Bu sayede tespit edilen sınıfın dzensizlik deęerinin zaman ierisinde nasıl deęiřtięi takip edilebilir.

Őekil 2.10 a'daki grafik, Őekil 2.7'deki 2 sınıf iin, Őekil 2.10 b' deki grafik, Őekil 2.8'deki 3 sınıf iin ve Őekil 2.10 c' deki grafik, Őekil 2.9'daki 4 sınıf iin sınıflandırma sonularına gre hazırlanan entropi zet grafikleridir. Grafikler, renklendirilen sınıflandırma sonuları ile aynı renkte gsterilmiřtir.

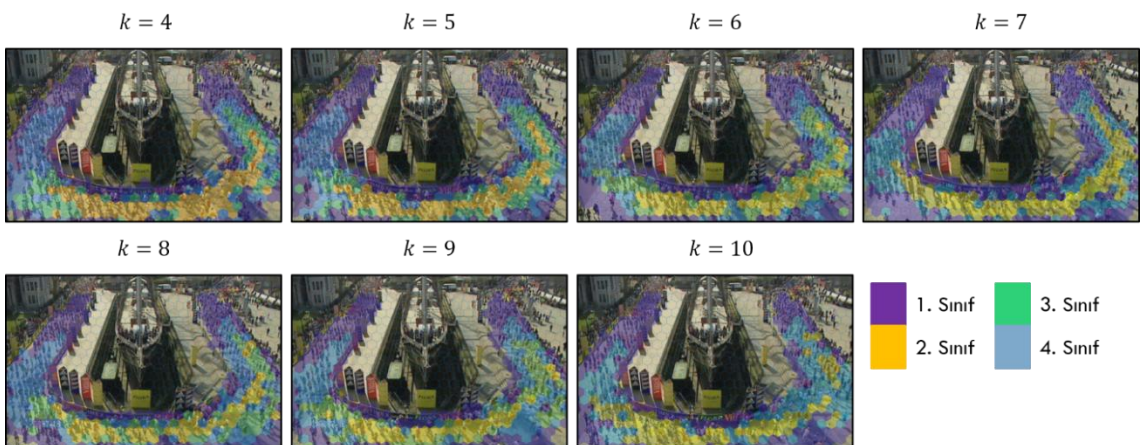
Entropi zet grafikleri ile birlikte sınıflandırma sonuları yorumlandığında, hangi blgelerde daha dzensiz bir davranış olduęu grlmektedir. Kalabalık hareketinin dz ve belli bir sre ierisinde aynı Őekilde devam eden blgelerde rg entropi deęeri dřk iken, hareketin dnme blgelerinde ise kiřilerin birbirlerine olan etkileřimine baęlı olarak nispeten daha yksek bir deęerde olduęu grlmřtr.




Şekil 2.7. Maraton koşusu görüntüsünün 2 sınıf için sınıflandırma sonuçları



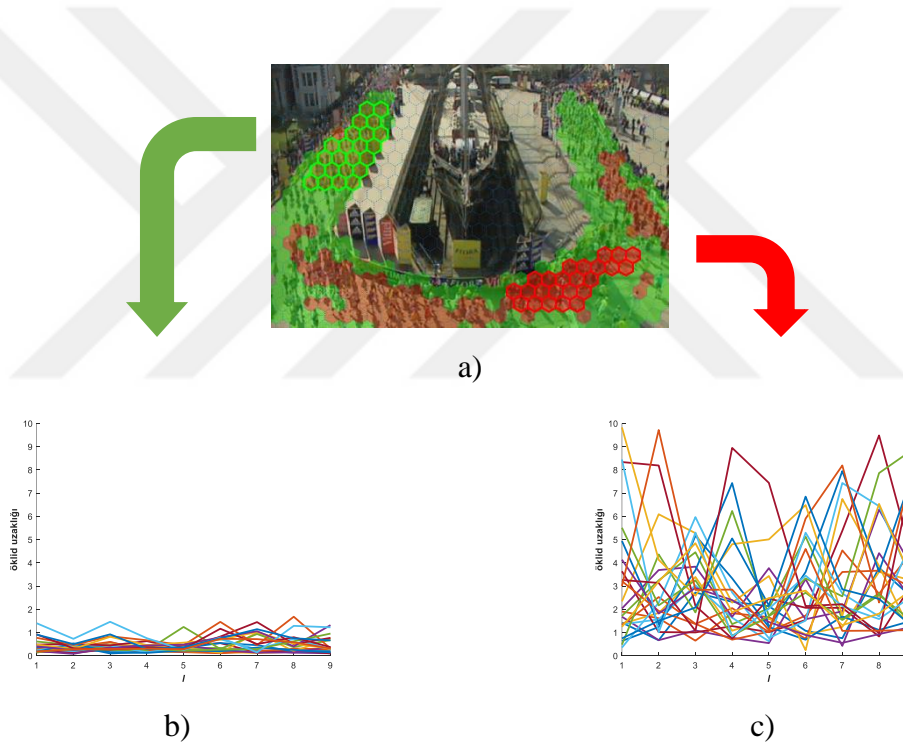
Şekil 2.8. Maraton koşusu görüntüsünün 3 sınıf için sınıflandırma sonuçları



Şekil 2.9. Maraton koşusu görüntüsünün 4 sınıf için sınıflandırma sonuçları



Şekil 2.10. Sınıflandırma sonuçlarına göre hazırlanan entropi özet grafikleri a) Şekil 2.7’deki 2 sınıf için entropi özet grafiği b) Şekil 2.8’deki 3 sınıf için entropi özet grafiği c) Şekil 2.8’deki 4 sınıf için entropi özet grafiği



Şekil 2.11. Hücrelerin içerisine denk gelen davranışın zamanla ne ölçüde değiştiğini gösteren grafikler a) Görüntüde yeşil ve kırmızı ile renklendirilen bazı hücreler b) Yeşil ile renklendirilen hücrelerin zaman içerisinde değişimi c) Kırmızı ile renklendirilen hücrelerin zaman içerisinde değişimi

2.1.5.2. Davranışın Zaman İçerisindeki Değişimi


Şekil 2.11’de, her bir hücrenin içerisine denk gelen davranışın zaman içerisinde ne ölçüde değiştiği takip edilmiştir. Şekil 2.11 (a)’da kırmızı ve yeşil renkte iki sınıfa ayrılmış hücreler gösterilmektedir. Maraton koşusu için $k = 10$ ile toplam da 10 bölüm vardır. Gözlemlemek istediğimiz değer ise her bir hücre içerisindeki davranışının 10 bölüm boyunca ne ölçüde değiştiğidir. Değişim, her bir hücrenin, k bölümünde hesaplanan 1×36 uzunluğundaki öznitelik vektörünün (28), $k + 1$ anındaki öznitelik vektörüne olan *öklid uzaklığına* göre belirlenir (30). Eğer k ve $k + 1$ arasında hücrenin davranışında çok ciddi değişimler olmuşsa öznitelik vektörleri arasındaki öklid uzaklığında büyük sapmalar beklenir. Aksi durumda, yani hücrenin zaman içerisindeki davranışı bir önceki davranışına benzer ise öklid uzaklığında fazla değişim olmaz.

$$\begin{aligned} \text{Öklid Uzaklığı}_{Hücre_{ij}}^l &= \left[B.entropy_{Hücre_{ij}}^k, B.entropy_{Hücre_{ij}}^{k+1} \right] \\ l &= 1, 2, \dots, 9 \end{aligned} \quad (30)$$

Şekil 2.11 (b) ve (c)’deki grafiklerde gösterilen her bir çizgi bir hücrenin l değeri boyunca davranışını gösterir. Şekil 2.11 (b)’de, Şekil 2.11 (a)’da yeşil ile renklendirilen hücrelerin davranışı gösterilir. Bu bölgelerdeki davranışlar, genel itibari ile düz bir harekettir. Kişiler arasında yer değiştirmeler ve etkileşimler görülmez. Dolayısıyla hücrelerin bir sonraki öznitelik vektörü ile arasında ciddi farklılıklar görülmez. Şekil 2.11 (b)’deki grafikte gösterildiği gibi hücrelerin öklid uzaklık değerleri 0 ile 2 arasında değişmektedir.

Şekil 2.11 (c)’de ise Şekil 2.11 (a)’da kırmızı ile renklendirilen hücrelerin davranışları takip edilir. Bu bölgelerde kalabalık dönme olayını gerçekleştirir. Dolayısıyla kişiler arasında etkileşim ve bir düzensizlik hali oluşur. Her hücrenin içerisine denk gelen davranışta zaman içerisinde farklılıklar gerçekleşir. Sonuç olarak şekil 2.11 (c)’deki hücrelerin zaman içerisindeki öklid uzaklık değerlerinde 0 ile 10 arasında olmak üzere önemli sapmalar gerçekleştiği görülmektedir.

Tezin bu bölümünde, kalabalık hareketleri içerisindeki her bir hücrenin içerisine denk gelen davranışın zaman içerisinde ne ölçüde değiştiği tespit edilmiştir. Bu sonuçlar davranışı anlamaya ve yorumlamaya yardımcı olabilecek değerlerdir.



Şekil 2.12. Çalışmanın sonuçlarının literatürden farklı çalışmalarla karşılaştırılması a) Tez çalışmasının sonuçları b) Saad Ali vd. [6] c) Ramin Mehran vd. [19] d) Bolei Zhou vd. [16] e) Bolei Zhou [85].

2.1.5.3. Sonuçları Literatürdeki Çalışmalarla Karşılaştırmak

Bu bölümünde elde edilen sonuçların literatürden sonuçlarla karşılaştırılması ve yorumlanması bulunmaktadır.

Şekil 2.12 (b,c)'deki literatürden çalışmalar incelendiğinde, aynı yönde ve konum olarak birbirine yakın hareketler bir bölüt olarak belirlenmiştir. Her bir bölüt renklendirilerek gösterilmiştir. Maraton koşusu ve kâbe görüntüsünde, kalabalık hareketi tek bir bölüt ile sonuçlandırılmıştır. Bu sonuç, kalabalık hareketinin her bölgede aynı düzende hareketine devam ediyormuş gibi olmasıdır. Aslında görüntüler incelendiğinde, hareketin düzgün ilerleyen bölgelerinde kişiler arasında etkileşim az iken, dönme noktalarında ise kişiler arasında etkileşimin arttığı, nispeten düzensiz bir hareketin olduğu görülmektedir.

Literatürdeki bu çalışmalar davranışı bir bütün olarak ele aldığı için, kalabalık içerisindeki düzensizlik bilgisini göz ardı eder.

Şekil 2.12 (d,e)'de gösterilen çalışmalarda ise, kişilerin hareketi sadece 2 çerçeve arasındaki hareketin yön ve konum bilgisine bağlı olarak, noktalar halinde gösterilmiştir. Ancak bu sonuçlar da, 2 çerçevelik davranış hareketin düzensizliği ile ilgili yeterli bilgiyi içermemektedir. Hareketi bir bütün ve aynı türden bir davranış olarak göstermektedir.

Şekil 2.12 (a)'da gösterilen bizim çalışmamızın sonuçlarında ise görüntü eşit altıgen ızgara ile hücrelere ayrılmıştır. Her bir hücrenin içerisine denk gelen davranışların örgü entropi yöntemi ile düzensizliğini gösteren öznitelik vektörleri hesaplanmıştır. Danışmansız öğrenme modeli ile kalabalığın hareketlerinin düzensizliğe bağlı davranışı modellenmiştir. Sadece hareket yönü ve konumuna bağlı kalmaksızın, davranışı düzensizlik seviyesine göre sınıflandırarak, literatürdeki çalışmalara nispeten daha anlaşılır halde modellenmiştir. Maraton koşusu görüntüsü için, hareketin düz ve düzgün bir seyir halinde olduğu bölgeler ile dönme noktalarındaki düzensiz davranışlar sınıflar halinde birbirinden ayrılmıştır. Şekil (2.7 – 2.8 – 2.9)'da farklı sınıf sayılarına göre kalabalığın davranışı gösterilmiştir.

2.2. Anormal Durum Tespiti

Güvenlik önlemlerinin her geçen gün önemini artırmasıyla birlikte, caddeler, alış-veriş merkezleri, hava alanları, park-bahçe gibi kalabalığın yoğun olduğu alan ve mekânlarda güvenlik kameraları oldukça yoğun bir şekilde kullanılmaktadır. Bu sistemlerin kullanılması ile güvenliği tehdit edecek unsurlar, yetkili kişilerin göz yordamı ile gün boyunca davranışları monitörden gözlemlenmeleri ile tespit edilmektedir. Ancak kişiler, uzun süreli ve her detaya hâkim bir şekilde gözlem yapamayabilirler. Bu problemi mümkün olan en alt seviyeye indirmek ve güvenlik sistemlerini daha etkin bir şekilde kullanmak için akıllı güvenlik sistemleri geliştirilmektedir. Güvenlik sistemlerinden alınan yığınla bilgi işlenerek kalabalığın davranışı ile ilgili bazı anlamlı bilgiler elde edilebilir.

Literatürde, kalabalık içerisindeki anormal davranışlar-durumlar birçok farklı anlamlarla tanımlanmış ve tespit etmek için birçok çözüm sunulmuştur. Ancak henüz anormal davranışın tanımı tek ve net bir şekilde belirlenememiştir [29]. Yapılan birçok çalışmada anormal durum, rutin bir davranışın değişmesi, beklenmedik bir olayın aniden gerçekleşmesi gibi tanımlarla ifade edilmiştir. Bunlara ek olarak, kalabalık içerisinde bir kişinin diğerlerini aksi yönünde hareket etmesi, kişilerin yürüyerek belli bir hızda hareket

ettiği bir ortamda bir kişinin-grubun diğerlerinden daha hızlı bir şekilde aynı ya da zıt yönde hareket etmesi gibi olaylarda literatürde yer alan diğer anormal durumlar olarak gösterilmiştir.

Kalabalık içerisindeki anormal durum ya da kişi/kişileri tespit etmek, özellikle kalabalığın yoğunlaştığı bölgelerde kişilerin nispeten az pikseller ile temsil edilmesi, hareket anındaki tıkanıklık, kamera açısı, kameranın davranışa olan uzaklığı gibi durumlara bağlı olarak yüksek oranda başarı elde edilmesi zor bir problemdir.

Genel olarak çalışmalar incelendiğinde probleme aşağıda ifade edildiği gibi iki farklı yaklaşım ile çözüm üretilmiştir.

1. Hareket vektörleri tabanlı çözümler (MVB)
2. Hareket izleri tabanlı çözümler (TB)

Hareket vektörleri tabanlı yaklaşımlarda görüntü eşit bölgelere ayrılır ve her bir bölge içerisine denk gelen hareket vektörlerinin yön ve büyüklüğüne bağlı dağılımlarına göre bölgenin zaman içerisindeki davranışı tespit edilir. Ancak bu tür çözümlerde hareketin belirli sınırlar içerisinde olduğunu kabul etmek her zaman doğru olamayabilir. Bizim çalışmamız ise davranışı belirli bir süre takip ederek ve davranışın tümünü değerlendirmek üzere olacaktır.

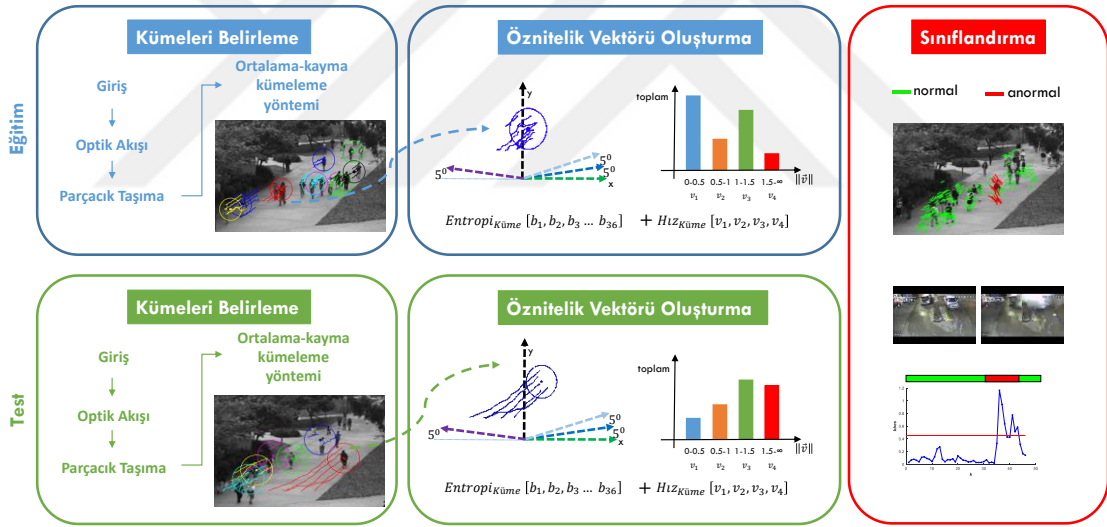
Hareket izleri tabanlı yaklaşımlarda ise izleme (tracking) algoritmaları kullanılarak kişiler hareket süresince takip edilir ve oluşturdukları izler (trajectory) elde edilir. Benzer özelliklerine göre izler kümelenir ve uygulanan öğrenme modeliyle anormal davranış gösteren kümeler tespit edilmeye çalışılır. Özellikle yüksek yoğunluklu kalabalıklarda nispeten az piksellerle temsil edilen kişiyi tespit etme, görüntü boyunca takip etme ve izleme algoritmalarının uygulama gücünden dolayı çok fazla tercih edilmemiştir. Bizim çalışmamız ise izleme algoritmalarını kullanmadan, bütüncül (holistic) bir yaklaşımla kalabalık hareketini temsil eden izler elde edilecektir.

Çalışmamızda, elde edilen hareket kümelerinin “Örgü Entropi” yöntemi (Bölüm 1.11’de detay bir şekilde anlatılmıştır.) kullanılarak düzensizlik değerleri hesaplanır. Bu değerler hareket kümesini oluşturan izlerin birbirleriyle yaptıkları çakışma olayına bağlıdır. Her bir hareket kümesi örgü entropi ve izleri oluşturan hareket vektörlerinin sadece büyüklük değerinin histogram dağılımına bağlı olarak hesaplanan öznelik vektörü ile temsil edilir. Amacımız, yerelde gerçekleşen ve anormal davranış gösteren hareket kümelerini öğrenme modeliyle tespit etmektir. Ayrıca sahnenin “bölüm örgü entropi skor (bbes)” değerini

hesaplayarak görüntünün genelinde gerçekleşen anormal durum ya da panik davranışını tespit etmektir.

Bahsedilen her iki çözüm modeline göre daha avantajlı olduğunu düşündüğümüz çalışmamızın katkıları şu şeklide sıralanabilir;

- Çalışmamız örgü entropi yöntemini kullanarak yerelde ve genelde gerçekleşen anormal durumları tespit etmeye yönelik hazırlanmıştır.
- İz tabanlı çalışmalara alternatif olarak hazırlanmıştır. Ancak izleme algoritmalarının uygulama zorluklarını gerçekleştirmek yerine, bütüncül bir yaklaşımla, grupların ya da kişilerin görüntü boyunca hareket izlerini elde etmek üzere olacaktır.
- Hareket vektörleri tabanlı çalışmalarda olduğu gibi davranışı belirli alan içerisine sınırlamak değil, belirli bir süre içerisinde, kişi ya da kişilere ait davranışın bütününe göre karar verme imkânı sağlar.



Şekil 2.13. Çalışmanın genel aşamaları

2.2.1. Hareket Kümelerini Belirleme

Öncelikli olarak, optik akışı yöntemi (Bölüm 1.9) ile art arda gelen çerçeve çiftleri arasında piksel seviyesindeki hareket vektörleri elde edilir. Daha sonra, parçacık taşıma yöntemi (Bölüm 1.10) ile farazi parçacıklar hareketlendirilerek görüntüdeki davranış hareket izleri halinde elde edilir (Şekil 2.14 a). Parçacığın bulunduğu son konum, devam eden davranışın o an için son konumunu gösterir. Parçacıkların son konum bilgilerine göre

uyguladığımız ortalama kayma ile kümeleme yöntemi (MSC) [80] sayesinde, hareket izleri birbirlerinden ayrı konumlarda ve bağımsız bir şekilde gerçekleşen davranışlar olarak kümelenir (Şekil 2.14 b).

$$t = 1, 2, \dots, T$$

$$N = m * n$$


$$i = 1, 2, \dots, N$$

$$trj_1 = \{(x_{11}, y_{11}), (x_{12}, y_{12}), \dots, (x_{1T}, y_{1T})\} \quad (31)$$

$$trj_2 = \{(x_{21}, y_{21}), (x_{22}, y_{22}), \dots, (x_{2T}, y_{2T})\} \quad (32)$$

⋮

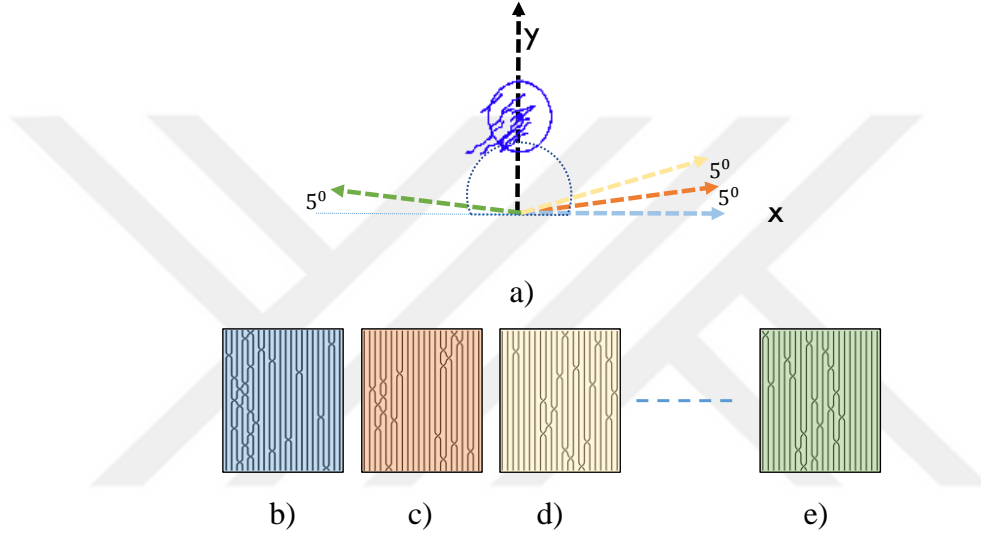
$$trj_N = \{(x_{N1}, y_{N1}), (x_{N2}, y_{N2}), \dots, (x_{NT}, y_{NT})\} \quad (33)$$



Şekil 2.14. Elde edilen hareket izleri gösterilmiştir. a) Her bir hareket izi yeşil nokta ile başlar, kırmızı nokta ile biter. b) Ortalama-kayma yöntemi ile gruplara ayrılan hareket izleri farklı renklerle gösterilmiştir.

Formüllerdeki t çerçeve sayısını, T ise toplam çerçeve sayısını ifade eder. N toplam piksel sayısını ve her bir ($trj_1, trj_2 \dots$), parçacığın görüntü boyunca yaptığı hareketi yani bir hareket izini temsil eder. Her bir hareket izi, Şekil 2.14 (a)'da mavi renkle gösterilmiştir. Hareket izleri parçacığın t_1 anındaki konumundan, t_T anındaki konumuna kadarki hareket bilgisinden oluşur. i . hareket izinin T anındaki, yani son çerçevedeki konumu (x_{iT}, y_{iT})

olarak ifade edilir. Şekil 2.14 (a)'da mavi renk ile gösterilen izlerin t_1 anındaki konumu yeşil nokta ile gösterilirken, t_T anındaki konumu ise kırmızı nokta ile gösterilmiştir. Ortalama kayma ile kümeleme yöntemi izlerin son konumlarına (34)'de gösterildiği gibi uygulanır (Bölüm 1.13). Ortalama kayma ile kümeleme yönteminin sonunda her bir davranış kümeler halinde birbirlerinden ayrılmış olur. Şekil 2.14 (b)'de her bir hareket kümesi farklı renk ile gösterilmiştir. Bir kümeye dâhil olan hareket izleri ise aynı renktedir.



Şekil 2.15. a) Hareket kümesine 5^0 aralıklarla uygulanan iz düşüm işlemi sonunda her bir açı değeri için elde edilen *çakışma* olayları b) x eksenine c) 5^0 d) 10^0 e) 175^0 açı değeri için elde edilen *çakışma* değerleri

$$\text{Ortalama Kayma } [(x_{1T}, y_{1T}), (x_{2T}, y_{2T}), \dots, (x_{NT}, y_{NT})] \quad (34)$$

$$\delta = 1, 2, \dots, \varphi \quad (35)$$

$$k = 1, 2, \dots, L/T$$

$L = \text{toplam çerçeve sayısı}$

$T = \text{her bir } k' \text{ da işlenen çerçeve sayısı}$

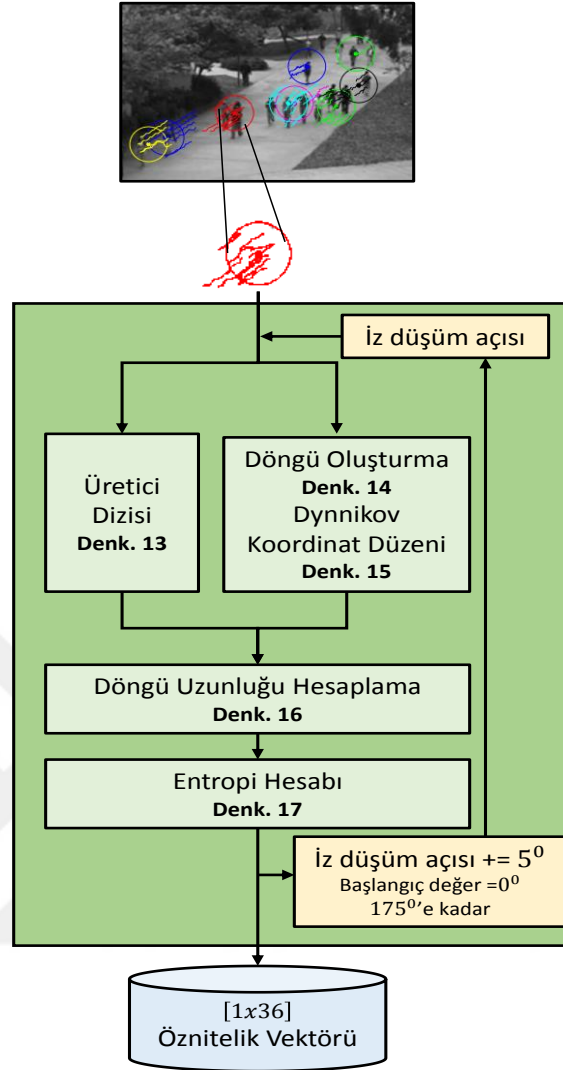
Her bir sahne, işlenen T kadar çerçeveden elde edilen hareket izleri ve sonrasında ortalama kayma ile kümeleme yöntemi ile oluşan kümelerden meydana gelir. Toplamda L tane çerçeveden, her T kadar çerçeve bir bölüm olarak ele alınır ve k ile gösterilir. Her k bölümünde toplam φ tane küme elde edilir ve her bir küme δ ile ifade edilir (35).

2.2.2. Öznitelik Vektörü Hesaplama

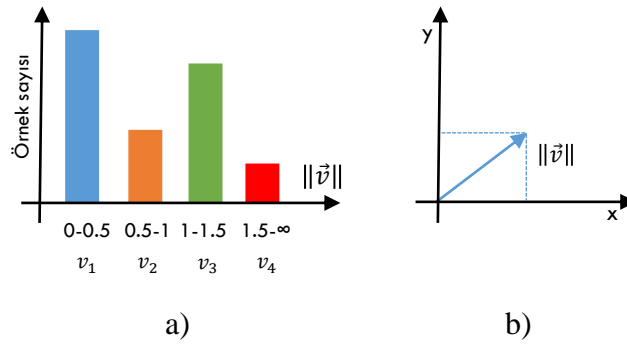
Bu aşamada, tespit edilen hareket kümelerinin öznitelik vektörü hesaplanır. Her bir kümenin aşağıda belirtilen iki yöntem ile hesaplanan değerleri bir araya getirilerek öznitelik vektörü oluşturulur.

- Örgü entropi yöntemi
- Hareket vektörlerinin histogram dağılımı

Örgü entropi yöntemi ile hareket kümesinin davranışını temsil edecek öznitelik vektörünü elde etmek için ilgili kümenin içerisindeki hareket izi grubuna 5^0 derecelik aralıklarla iz düşüm işlemi uygulanır (Şekil 2.15 a). Yani hareket izi grubuna $\beta=36$ farklı açıdan bakılarak izler arasındaki etkileşimler yani çakışma olayları keşfedilir. Bu sayede hareket kümesinin farklı açılara göre davranışının düzensizlik durumu keşfedilir. Farklı açılardaki eksnlere göre iz düşüm işlemi ile elde edilen *çakışma* durumları renkleri ile uyumlu bir şekilde Şekil 2.15 (b – c – d – e)' de gösterilmiştir. Her bir iz düşüm işlemine göre örgü entropi değerinin hesaplanmasının aşamaları Şekil 2.16' de gösterilmiştir. Ayrıca hareket boyunca gerçekleşen çakışma olayları ilgili iz düşüm açısı için özgün değerlerdir. Bu sayede her bir kümenin 36 farklı örgü entropi değeri hesaplanır ve öznitelik vektörü elde edilir (36).



Şekil 2.16. Her bir hareket kümesi için örgü entropi teoremi ile öznitelik vektörü hesaplanmasının işlem basamakları



Şekil 2.17. a) Her bir kümeyi oluşturan hareket vektörlerinin genlik değerine bağlı dağılımı b) Hareket vektörünün büyüklüğü

$$Entropi_{küme_\delta} = [b_1, b_2, b_3 \dots b_{36}] \quad (36)$$

Bu değerler hareket kümesinin 36 farklı açıdan tespit edilmiş, düzensizlik davranışını gösteren sonuçlardır.

Hareket kümesini temsil edecek öznitelik vektörüne hareket vektörlerinin genlik-büyüklik değeri de eklenir (Şekil 2.17 b). Hareket vektörlerinin histogram dağılımına deneysel sonuçlarına göre 4 bölgeye ayırmak uygun görülmüştür (Şekil 2.17 a). Bu işlem sonunda davranışı temsil edecek bir diğer öznitelik vektörü, hareket vektörlerinin büyüklüğüne bağlı olarak $[1 \times 4]$ boyutunda hesaplanır (37).

$$Hız_{küme_\delta} = [v_1, v_2, v_3, v_4] \quad (37)$$

2.2.3. Sınıflandırma

Bu bölümde yerelde ve genelde gerçekleşen anormal durumları tespit ederken kararın nasıl verileceği anlatılacaktır.

Yerelde anormal durum tespiti probleminde sonuca öğrenme modeli kullanılarak varılır. Öncelikli olarak normal davranışlar olarak etiketlenen eğitim veri kümesinden hareket kümeleri elde edilir. Her bir hareket kümesi, örgü entropi yöntemi ve hareket vektörlerinin büyüklüğüne bağlı histogram dağılımından elde edilen öznitelik vektörü ile öğrenme modelinde temsil edilir. Hareket kümelerinin öznitelik vektörleri ile normal davranışın sınıfı oluşturulur. Bu sınıfa “normal sınıf” denir.

Test aşamasında ise, test için belirlenen veri kümesinden hareket kümeleri elde edilir. Her kümenin öznitelik vektörü hesaplanır ($küme_\delta$) ve normal sınıfa olan mahalanobis uzaklığı hesaplanır (38). Bu uzaklık değeri (d), belli bir eşit değer (τ) altında uzaklıkta olan davranışlar normal olay olarak etiketlenirken, eşit değer üzerinde uzaklığa sahip davranışlar anormal olay olarak etiketlenir (39).

$$d = mahalanobis(küme_\delta, normal\ sınıf) \quad (38)$$

$$etiket(küme_\delta) = \begin{cases} anormal, & d > \tau \\ normal, & d \leq \tau \end{cases} \quad (39)$$

Görüntünün bütününde gerçekleşebilecek anormal durumun ya da panik anının varlığına *bbes* değerine göre karar verilmiştir. *bbes* değeri sahnenin yani her bir *k* bölümünün entropi değerini gösteren bir ölçüdür.

bbes değeri iki aşama ile hesaplanır.

1) Her bir *k* anı için elde edilen hareket kümelerinin örgü entropi değerine bağlı öznitelik vektörlerinin ortalaması alınır. Böylece sahnedeki her bir küme bir tek entropi değeri ile temsil edilir (40).

2) Sahnedeki bütün hareket kümelerinin örgü entropi değerlerinin ortalaması hesaplanarak ilgili *k* anı için tek bir *bbes* oluşturulur (41).

Her bir *k* anının *bbes* değeri zaman içerisinde takip edilerek sahnedeki hareketin seyri hakkında bir kanaat oluşturulabilir. Hesaplanan *bbes* değerinin, belli bir eşit değerden (τ) büyük ya da küçük olması sonucu davranışın anormal durum olup olmadığının kararı verilebilir.

Eşit değer (τ) hesaplanması veri kümesine bağlıdır. Çalışmada UMN ve UCF veri kümeleri kullanılır. UMN veri kümesi etiketli bir veri kümesidir. Dolayısıyla UMN veri kümesindeki görüntüler için eşik değeri (τ), ROC eğrileri ile tespit edilebilir.

UCF veri kümesindeki görüntüler için ise ilgili *k* anı için görüntünün *bbes* değeri, diğer *k* anı *bbes* değerleriyle hesaplanan “ortalama+standart sapma” değerinin üzerinde ise anormal durumların gerçekleştiği kararı verilir (42).

$ortalama(bbes) = \text{bütün sahnelerin ortalama } bbes \text{ değeri}$

$std(bbes) = \text{bütün sahnelerin standart sapma değeri}$

$\varphi = \text{toplam küme sayısı}$

$\delta = \text{her bir küme}$

$\tau = ortalama(bbes) + std(bbes)$ (UCF veri kümesi için)

$\tau = ROC \text{ eğrisi ile hesaplanır}$ (UMN veri kümesi için)

$$\omega = \text{ortalama}(\delta_{[b_1, b_2, b_3 \dots b_{36}]}) \quad (40)$$

$$bbes = \frac{\sum_1^{\varphi} \omega}{\varphi} \quad (41)$$

$$\text{etiket}_{\text{sahne}^k} = \begin{cases} \text{anormal}, & \text{bbes}^k > \tau \\ \text{normal}, & \text{diğer durum} \end{cases} \quad (42)$$

2.2.4. Anormal Durum Tespit Etme Sonuçları

Bu bölümde deneylerden elde edilen sonuçlar verilecektir. Bu bölüm iki alt bölüm halinde sunulacaktır. Birincisinde yerel anormal durum tespiti sonuçları, ikincisinde ise genel anormal durum sonuçları yer almaktadır.

2.2.4.1. Yerelde Anormal Durum Tespit Etme

Yöntem UCSD Ped1 - Ped2 [29, 62], veri kümeleri üzerinde sınanmıştır. Literatürde de oldukça fazla tercih edilen veri kümeleridir. Bu sayede önerdiğimiz yöntemin diğer yöntemlere göre başarısı daha sağlıklı bir şekilde yapılabilir.

UCSD Peds1 - Peds2 veri kümesinde iki farklı konumdan senaryolar vardır. Görüntüler 10 fps ve 238x158 piksel özelliklerine sahiptirler. Ayrıca Peds1, her biri 200 çerçeve olmak üzere 34 eğitim - 36 test senaryosuna sahipken, Peds2, her biri 150 - 200 çerçeve arasında değişen 16 eğitim - 12 test senaryosuna sahiptir.

Öğrenme modelini farklı boyutlarda öznitelik vektörleri ile gerçekleştirerek, öznitelik vektörlerinin öğrenme başarısına etkisi test edilmiştir. Bölüm 1.11'de teorik olarak hesaplanan ve eşitlik 36'da nihai olarak elde edilen örgü entropi öznitelik vektörünü farklı açı değerlerine göre iz düşüm işlemleri yapılarak farklı boyutlarda elde etmek mümkündür. Eşitlik 31'de 5⁰'lik açılarla $\beta=36$ boyutla oluşturulan örgü öznitelik vektörünü 15⁰ aralıklarla hesaplandığında $\beta=12$ boyutta, 30⁰ aralıklarla hesaplandığında $\beta=6$ boyutta ve 60⁰ aralıklarla hesaplandığında $\beta=3$ boyutta oluşturulabilir. Deney sonuçları, bahsedilen her bir farklı boyutlardaki öznitelik vektörleri için hesaplanmıştır. Ayrıca hareket vektörlerinin genlik değerine bağlı dağılımından elde edilen öznitelik vektörü (37)'ü de örgü öznitelik vektörüne eklenerek ilgili hareket kümesinin davranışı öğrenme modelinde temsil edilir (43).

$$\beta = 36, 12, 6, 3$$

$$\text{özellik Vektörü}_{\delta}^k = \text{Entropi}_{\text{küme}_{\delta}}^k [b_1, b_2, b_3 \dots b_{\beta}] + \text{Hız}_{\text{küme}_{\delta}}^k [v_1, v_2, v_3, v_4] \quad (43)$$

Formüldeki δ , δ . kümeyi gösterirken, k ise bölüm numarasını gösterir.

Öğrenme modelindeki başarıyı etkileyebilecek diğer önemli parametreler ise her bir bölümde kullanılan çerçeve sayısı-derinliği (t) ve ortalama ile kayma yönteminde kullanılan kümenin yarıçapı (r) değerleridir. Çerçeve sayısı, kaç çerçeve uzunluğu için davranışın tespit edileceği değerdir. Yani (x, y, t) ' de x, y görüntünün boyutları iken t ise çerçeve sayısı-derinliği anlamındadır. Davranışı $t = 10$ çerçeve ya da $t = 20$ çerçeve uzunluğunda tespit ederek öğrenme modelinin başarıyı karşılaştırılabilir. Kümenin yarıçapı ise ne kadar genişlikte bir davranışı tek davranış olarak kabul etme değeridir. $r = 5$ piksel veya $r = 10$ piksel yarıçapı genişliklerine göre elde edilen başarımlar sonuçları karşılaştırılmış ve en uygun değer belirlenmiştir.

Çerçeve-seviyesi başarı değerlendirilmesi AUC-ROC eğrileri ile yapılmıştır. Tablo 2-3'de ve Şekil 2.18' den Şekil 2.25'e kadar yöntemin farklı boyutlarda öznelik vektörü ile test edildiğinde elde edilen sonuçlar verilmiştir.

Sonuçlara göre Peds1 veri tabanı için en başarılı sonuç AUC= 0,927 - ERR=0,14 ile 30^0 'lik açılarla elde edilen Örgü entropi ve Hız 'dan oluşturulan öznelik vektörü ile elde edilmiştir (Örgü_30 + Hız) . Peds2 için ise AUC =0.95 - ERR =0.09 değerleri ile en başarılı sonuç yine aynı öznelik vektörü ile elde edilmiştir.

Bu sonuçlar sayesinde şunlar söylenebilir. 5^0 , 15^0 'lik açılarla iz düşümlere bağlı örgü entropi değerleri davranışı daha fazla boyutta öznelik vektörü ile temsil etmesine rağmen, davranışı 30^0 'lik açılarla ile temsil etmek daha başarılı sonuçlar vermiştir. Ayrıca 60^0 'lik açılarla öznelik vektörünün boyut sayısı 3'e inmiş ve başarı azalmıştır.

Başarı durumunu etkileyen diğer iki faktör ise çerçeve derinliği (t) ve MSC yönteminde kullanılan kümenin yarıçapı (r) değerleridir. Her iki veri tabanı için sonuçlara bakıldığında kümenin yarıçap değerini artırmak başarıyı olumsuz yönde etkilemiştir. Çünkü yarıçap değeri arttıkça kümenin içerisine aldığı davranış genişlemekte, dolayısıyla başarımın azalmasına neden olmaktadır.





Diğer taraftan Peds1 'de davranışı $t=10$ 'ar çerçeve aralıklarla tespit etmek daha başarılı sonuçlar veriyorken, Peds2'de davranışı $t=20$ 'şer çerçeve aralıklarla tespit etmek daha başarılı sonuçlar vermiştir. Bunun nedeni şu şekilde açıklanabilir. Görüntüler

incelendiğinde, Peds1 ve Peds2 veri tabanları arasındaki temel fark Peds1’de çapraz görüş açısıyla kalabalık davranışının görüntüleri alınmakta iken, Peds2’de ise harekete neredeyse dik bir görüş açısıyla görüntüler alınmaktadır. Bu durumda Peds1’de hareket vektörleri, aynı davranış olsa da, kameraya yakın ve uzak olanlarda farklı dağılımlar gösterebilir. Peds2’de ise hareket vektörleri nispeten daha düzgün bir dağılım gösterirler. Dolayısıyla Peds2 deki sonuçların neden daha başarılı olmasını buna bağlı olarak açıklanabilir.

Ayrıca, UCSD veri tabanında, bisiklet ya da kaykay ile zikzak hareket eden kişilerin davranışı izler halinde temsil edilir. Dolayısıyla, izlerin hareket boyunca birbirleriyle yaptıkları çakışma olayına bağlı örgü entropi değerleri ile davranışı temsil etmek daha başarılı sonuçlar vermiştir.

Başarımı etkileyen bir diğer önemli faktör ise, eşit süre zarfında bisikletli, kaykaylı ya da hareketli aracın oluşturduğu hareket izlerinin, normal yürüyüş halindeki yayaların oluşturduğu hareket izlerine nispeten çok daha fazla olmasıdır. Bu durum deneysel sonuçlardan tespit edilmiştir. Dolayısıyla, yoğun hareket izlerinden oluşan hareket kümesinin örgü entropi değeri nispeten daha fazla olur. Bu sayede yayalara göre daha hızlı ve değişken davranışa sahip hareketliler braid entropi yöntemi sayesinde başarılı bir şekilde tespit edilmiştir.





Peds 1 – Veri Kümesi

Şekil 2.18. $r = 5$ piksel, $t = 10$ çerçeveŞekil 2.19. $r = 10$ piksel, $t = 10$ çerçeveŞekil 2.20. $r = 5$ piksel, $t = 20$ çerçeveŞekil 2.21. $r = 10$ piksel, $t = 20$ çerçeve

Tablo 2. Peds1 veri kümesine ait elde edilen sonuçlar


Öznitelik vektörü	$r = 5$ piksel		$r = 10$ piksel	
	$t = 20$ çer.	$t = 10$ çer.	$t = 20$ çer.	$t = 10$ çer.
	AUC-ERR	AUC-ERR	AUC-ERR	AUC-ERR
Hız	0.759-0.31	0.741-0.33	0.707-0.38	0.693-0.37
Örgü_5	0.813-0.27	0.792-0.30	0.732-0.35	0.763-0.30
Örgü_5 + Hız	0.841-0.25	0.834-0.27	0.749-0.32	0.732-0.33
Örgü_15	0.802-0.28	0.845-0.28	0.710-0.36	0.763-0.30
Örgü_15 + Hız	0.811-0.26	0.836-0.28	0.769-0.32	0.789-0.28
Örgü_30	0.827-0.25	0.896-0.21	0.816-0.26	0.826-0.25
Örgü_30 + Hız	0.873-0.23	0.927-0.14	0.799-0.28	0.857-0.21
Örgü_60	0.839-0.26	0.814-0.30	0.706-0.34	0.758-0.30
Örgü_60 + Hız	0.828-0.28	0.825-0.29	0.747-0.33	0.793-0.28

Peds 2 – Veri Kümesi

Şekil 2.22. $r = 5$ piksel, $t = 10$ çerçeveŞekil 2.23. $r = 10$ piksel, $t = 10$ çerçeveŞekil 2.24. $r = 5$ piksel, $t = 20$ çerçeveŞekil 2.25. $r = 10$ piksel, $t = 20$ çerçeve

Tablo 3. Peds2 veri kümesine ait elde edilen sonuçlar


Öznitelik vektörü	$r = 5$ piksel		$r = 10$ piksel	
	$t = 20$ çer.	$t = 20$ çer.	$t = 20$ çer.	$t = 10$ çer.
	AUC-ERR	AUC-ERR	AUC-ERR	AUC-ERR
Hız	0.869-0.25	0.840-0.27	0.668-0.40	0.872-0.20
Örgü_5	0.909-0.19	0.807-0.34	0.732-0.36	0.901-0.18
Örgü_5 + Hız	0.898-0.17	0.811-0.32	0.762-0.30	0.913-0.17
Örgü_15	0.911-0.23	0.839-0.29	0.792-0.28	0.912-0.16
Örgü_15 + Hız	0.9 -0.14	0.853-0.25	0.758-0.32	0.925-0.15
Örgü_30	0.943-0.13	0.902-0.23	0.773-0.30	0.936-0.11
Örgü_30 + Hız	0.95 -0.09	0.927-0.12	0.802-0.28	0.945-0.14
Örgü_60	0.874-0.17	0.881-0.26	0.658-0.41	0.894-0.17
Örgü_60 + Hız	0.858-0.27	0.865-0.26	0.66 -0.38	0.844-0.23



Şekil 2.26. UCSD peds1 veri kümesinden elde edilen DP ve DN sonuçları




Şekil 2.27. UCSD peds1 veri kümesinden elde edilen YN sonuçları




Şekil 2.28. UCSD peds1 veri kümesinden elde edilen YP sonuçları


Şekil 2.26-27-28’de deney sonuçlarından bazı görüntüler gösterilmiştir. Yeşil renk ile gösterilen izler normal davranışları gösterirken, kırmızı renk ile gösterilen izler sistemin anormal olay olarak sınıflandırdığı sonuçlardır. Şekil 2.26’da doğru-pozitif (DP) ve doğru-negatif (DN) sonuçlarına örnekler gösterilmiştir. Şekil 2.27’de sistemin anormal durumları tespit edemeyip normal olay olarak sınıflandırdığı yani yanlış-negatif (YN) sonuçlar gösterilmiştir. Şekil 2.28’de ise sistemin normal olaylara hata yaparak anormal diye sınıflandırdığı yani yanlış-pozitif (YP) sonuçlar yer almaktadır.



Şekil 2.29. UCSD peds2 veri kümesinden elde edilen DP ve DN sonuçları



Şekil 2.30. UCSD peds2 veri kümesinden elde edilen YN sonuçları



Şekil 2.31. UCSD peds2 veri kümesinden elde edilen YP sonuçları

Şekil 2.29-30-31'de UCSD Peds2 veri kümesinden deney sonuçlarından bazı görüntüler gösterilmiştir. Yeşil renk ile gösterilen izler normal davranışları gösterirken, kırmızı renk ile gösterilen izler sistemin anormal olay olarak sınıflandırdığı sonuçlardır. Şekil 2.29'da doğru-pozitif (DP) ve doğru-negatif (DN) sonuçlarına örnekler gösterilmiştir. Şekil 2.30'de sistemin anormal durumları tespit edemeyip normal olay olarak sınıflandırdığı yani yanlış-negatif (YN) sonuçlar gösterilmiştir. Şekil 2.31'de ise sistemin normal olaylara hata yaparak anormal diye sınıflandırdığı yani yanlış-pozitif (YP) sonuçlar yer almaktadır.

Tablo 4. Literatürden bazı sonuçlar ile çalışmamızın karşılaştırılması

Çalışmalar	PEDS1		PEDS2	
	AUC(%)	EER(%)	AUC(%)	EER(%)
MDT-temp [29]	-	22,9	-	27,9
ST-Compositions [36]	-	15	-	13
HOFME [42]	72,7	33,1	87,5	20
OCELM [38]	88,5	18	91,3	12
KUGDA [39]	81,08	23,7	93,75	9,8
Conv AE [86]*	81	27,9	90	21,7
ST-contex [87]	87,2	21	89,1	20
Zhang [88]	85	-	90	-
Conv LSTM [89]*	75,5	-	88,1	-
Detection at 150 fsp [90]	91,8	15	-	-
TCP [91]*	95,7	8	88,4	18
Saligrama [92]	92,7	16	-	-
Önerilen Yöntem	92,7	14	95	9
*, derin öğrenme modeli kullanılan çalışmalar				

Tablo 4’de deney sonuçlarından elde edilen başarı değerlerinin literatürdeki benzer çalışmalarla karşılaştırılması yer almaktadır. Yöntem, diğer çalışmalara nispeten daha başarılı sonuçlar vermiştir. Ayrıca derin öğrenme yöntemleriyle yapılan çalışmalara oldukça yakın ve bazı değerleriyle daha başarılı sonuçlar üretmiştir. Bu başarının nedenleri genel olarak şu şekilde açıklanabilir.

Litetatürdeki çalışmaların birçoğunda, görüntü eşit bölgelere ayrılıp bölgelere düşen hareket vektörlerine bağlı işlemler yapılmıştır. Ancak bir hareket belli bir süre içerisinde birden fazla bölgeleri kapsayacak şekilde bir davranış gösterebilir. Tek bir davranışı bölgelere ayırıp değerlendirmek davranışı eksik yorumlamaya ve hatalı sonuçlar oluşmasına neden olabilir. Bizim çalışmamızda ise, hareket kümelerini konumdan bağımsız ve hareket süresince davranışın tümünü temsil edecek öznitelik vektörü ile elde etmek mümkündür.

2.2.4.2. Görüntünün Genelindeki Anormal Durumu Tespit Etme

Bu bölümde, görüntünün bütününde gerçekleşen anormal durumları tespit etmeye yönelik test sonuçları yer almaktadır. Yöntem UMN ve UCF veri kümeleri üzerinde test edilmiştir.


UMN veri kümesi, 2 si açık mekân, 1'i kapalı mekân olmak üzere 3 farklı lokasyonda 11 farklı senaryodan oluşmaktadır. Her bir görüntü 640x480 piksel ve 30 fps değerlerine sahiptir. Her bir görüntü öncelikle normal davranışla başlarken bir vakit sonra panik halinde koşuşan kişilerin olduğu davranışlardan oluşmaktadır. UCF veri kümesi ise oldukça geniş bir içeriğe sahiptir. Hırsızlık, trafik kazaları, kavga gibi sınıflara ayrılmış toplamda 1900 video bulunmaktadır. Bu çalışmamızda trafik kazaları, patlama ve kavga gruplarına ait videolardan rastgele seçilmiş 25 video üzerinde yöntem test edilmiştir. Her bir görüntü 240x320 piksel boyutundadır ve 30 fps değerine sahiptir.

Bu aşamada çerçeve derinliği (t) ve küme öznitelik vektörünün boyutu (β) gibi farklı iki parametrenin hangi değerler olacağına, sonuçları ne derece değiştirdiği ile ilişkili olarak karar verilecektir. Daha önceki bölümlerde anlatıldığı gibi çerçeve derinliği (t), davranışı toplam kaç çerçevelik bloklar halinde işleneceğinin değeridir. Küme öznitelik vektörünün boyutu(β) ise örgü entropinin kaç derece aralıklarla hesaplanacağına bağlı değerlerdir.


Şekil 2.32'de UMN veri tabanından bir senaryo (Şekil 2.32 a) üzerinde bu iki parametrenin aldığı farklı değerlere göre sonucu nasıl değiştirdiği gösterilmiştir. Şekil 2.32 (c)' de t değerleri $t=15,30,45$ çerçeve değerleri için sonuçlar gösterilmiştir. Sonuçlara göre farklı t değerleri sonuçları ciddi oranda değiştirmemekle birlikte her bir step anı için işlenen çerçeve sayısı azaldıkça davranışı daha hassas değerlerle takip etmek mümkün olmuştur. Ancak t değerini azaltmak belli bir değerden sonra fazlaca işlem yüküne neden olacaktır. Dolayısıyla, bizim sonuçlarımız $t=30$ çerçeve yani 1 sn'lik sürelerle gerçekleşen davranışı incelemek üzere olacaktır. Şekil 2.32 (b)' de ise öznitelik vektörü boyutunun sonuçları nasıl etkilediği grafikler halinde gösterilmiştir. Sonuçlara göre farklı boyutlarda ($\beta= 36,12,6,3$) elde edilen öznitelik vektörlerine göre sonuçların çok ciddi farklılıklar göstermediği tespit edilmiştir.



a)




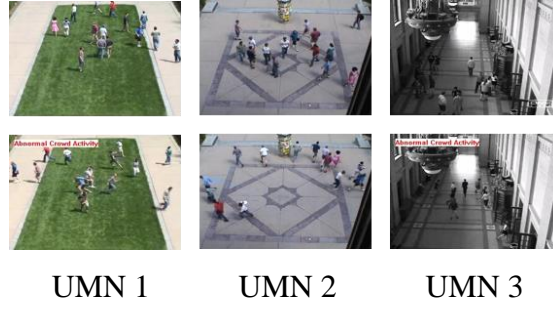


b)



c)

Şekil 2.32. a) UMN veri tabanından normal ve anormal durumların olduğu görüntüler b) Farklı t değerleri için elde edilen grafikler c) Farklı boyutta öznelilik vektörü için elde edilen grafikler



Şekil 2.33. UMN veri tabanındaki görüntülere uygulanan yöntemin sonuçları verilmiştir. a) UMN-1, anormal durum düzensizlik değerleri, eşik değer = 0.3264 b) UMN-2, anormal durum düzensizlik değerleri, eşik değer = 0.2912 c) UMN-3, anormal durum düzensizlik değerleri, eşik değer = 0.2255

Her işlenen t derinliği k anı olarak ifade edilir. Her bir k anı için görüntünün bbs değerine bağlı grafikler oluşturulmuştur. bbs değerlerinin ROC eğrisine bağlı eşit değeri kırmızı çizgi ile gösterilmiştir.

Şekil 2.33'da, yöntemin UMN veri kümesindeki senaryolara uygulandığında elde edilen sonuçlar gösterilmiştir.


Şekil 2.33 (a-b-c)'deki grafiklerde de görüldüğü gibi birbirlerine yakın değerlerle devam eden bbs değerleri belli bir k anından sonra ciddi sapmalar göstermiştir. Bu durum hareketin seyrinde ciddi değişikliklerin olduğunu yani anormal durumların olduğunu ifade edebilir.

Her bir grafiğin keskin referans değerleri grafiğin üzerinde bulunur. Normal olaylar yeşil renk ile gösterilirken, anormal olaylar kırmızı renk ile gösterilmiştir. Grafikler incelendiğinde keskin referans değerlerine oldukça yakın değerlerde başarı sağlanmıştır.

Şekil 2.34'de UMN veri kümesindeki senaryolar ROC grafiklerinden elde edilen değerlere göre eşik değeri belirlenmiş ve başarımları hesaplanmıştır.

Şekil 2.35'de UCF-Suç veri kümesindeki trafik kazaları görüntüleri kullanılarak elde edilen sonuçlar gösterilmiştir. Her bir grafiğin üzerinde görüntünün normal seyir hali ve kazanın gerçekleştiği durumların resimleri yer almaktadır. Grafikler incelendiğinde, belli bir süre de belli bir düzen halinde gerçekleşen olaylar, bir vakit sonra gerçekleşen kaza ile normalin dışına çıkmıştır. Bu durum grafiklerde sapmalar olarak kendini göstermektedir.

Bu çalışmanın amacı kalabalık hareketleri içerisinde, yerelde ve görüntünün tümünde gerçekleşen anormal durumları tespit etmektir. Bu problemin çözümü için izleme algoritmalarını kullanmadan iz tabanlı bir yaklaşım sunulmuştur. Oluşturulan hareket kümeleri FTBE ve hareket vektörlerinin dağılımına bağlı oluşturulan öznelik vektörü ile öğrenme modelinde temsil edilirler. Öğrenme modeli ile yereldeki anormal davranışlar, hesaplanan bbs değeri ile de görüntünün tümündeki anormal durumlar tespit edilir. Yöntemin UMN, UCSD, UCF-Suç veri tabanları ile test edildiğinde ve literatürdeki diğer çalışmalarla karşılaştırıldığında, başarılı sonuçlar ürettiği ve alternatif olarak kullanılabilmesi gösterilmiştir.



Şekil 2.34. UMN veri kümesindeki görüntüler için hesaplanan ROC eğrileri

Tablo 5. UMN veri kümesinden elde edilen sonuçların literatürden farklı çalışmalarla performansının karşılaştırılması

Yöntem	UMN 1	UMN 2	UMN 3
LECM-1 [93]	0.999	0.9667	0.918
LECM-2 [93]	0.9857	0.9572	0.879
STCOG [94]	0.9362	0.9661	0.7759
SR [95]	0.995	0.964	0.975
SRC [32]	0.995	0.974	0.971
MI [96]	0.995	0.98	0.853
HF [97]	0.953	0.964	0.913
HOFO+SVM [98]	0.9845	0.9815	0.9037
HOFO+PCA [98]	0.9992	0.9989	0.9880
FSCB [99]	0.9641	0.975	0.8764
CMA [100]	0.993	0.988	0.969
COV [101]	0.9605	0.9746	0.8628
SS [102]	0.991	0.99	0.951
ChI [103]		0.99	
SF [104]		0.96	
OF [104]		0.84	
Önerilen Yöntem	0.99	0.968	0.916



Şekil 2.35. UCF-Suç veri tabanından görüntüler üzerinde elde edilen sonuçlar

2.3. Kalabalık Davranışlarını Sınıflandırmak

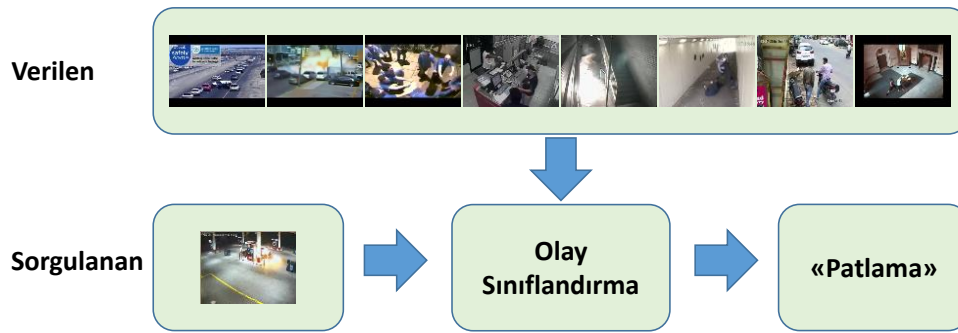
2.3.1. Anormal Olayların Sınıflandırılması

Anormal olayların sınıflandırılması problemi Şekil 2.36’da gösterilen genel aşamalar halinde ele alınır. UCF [61] veri setindeki anormal olaylar sınıflandırma probleminde kullanılacaktır. UCF veri seti “Patlama, kundaklama, kavga, hırsızlık, trafik kazaları, soygun, saldırı, taciz” olmak üzere 8 farklı anormal sınıfı içerir. Sınıflandırma işlemi ile sorgulanan anormal olay görüntüsünün hangi türden bir olay olduğunu belirlemek hedeflenir.

UCF veri tabanında bu çalışmada kullanabildiğimiz görüntü sayılarından daha fazla görüntü vardır. Ancak görüntü elde edilirken kullanılan hareketli kameralar, görüntü üzerine eklenen açıklayıcı bilgiler gibi durumlardan dolayı görüntülerin bazıları çalışmaya dâhil edilmemiştir. Çalışmada kullanılan bazı görüntüler Ek 3’de gösterilmiştir. Her bir görüntü 240×320 piksel çözünürlük değerine sahiptir.

Sınıflandırma probleminin nasıl işleneceği genel aşamaları ile Şekil 2.37’de gösterilmiştir.

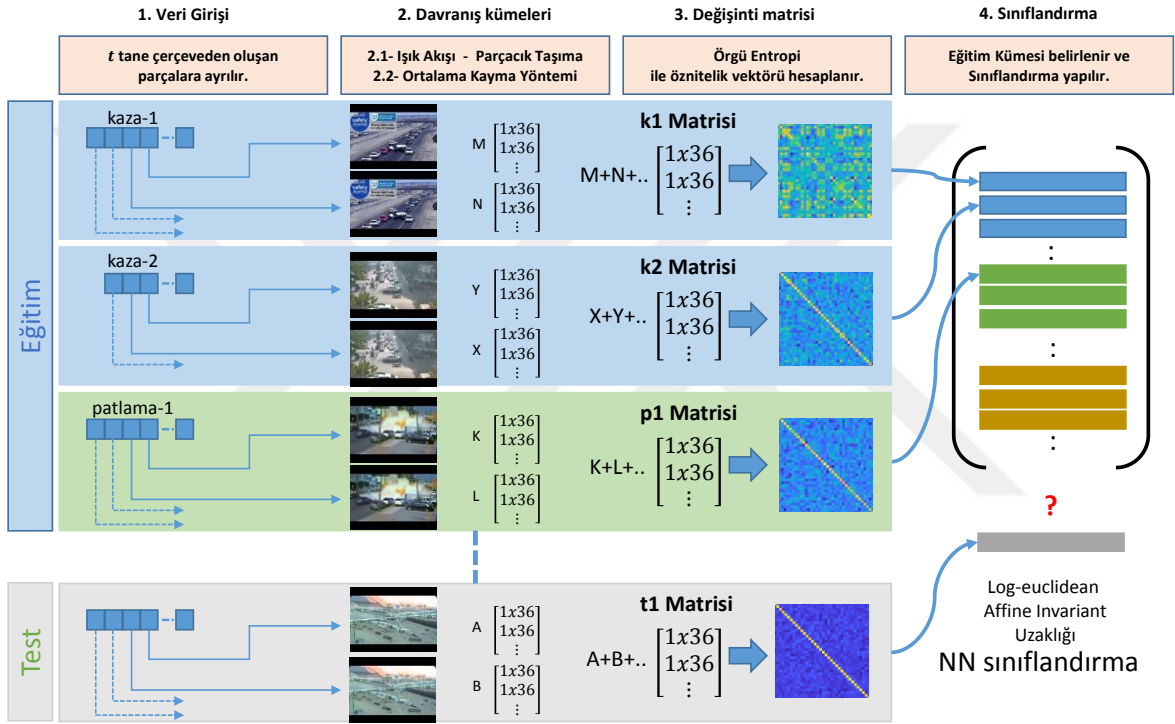
Öncelikli olarak her bir anormal olaya ait görüntü t derinliğinde çerçeveler halinde bloklara ayrılır. Her t sayısınca çerçeve için işlemler gerçekleştirilir. Görüntü her t sayısınca çerçeveden hesaplanan öznitelik vektörlerince temsil edilir.



Şekil 2.36. Anormal olayların sınıflandırılması probleminin genel aşamaları

Sonraki aşamada, t sayısında çerçeve optik akışı, parçacık taşıma ve ortalama-kayma yöntemleri ile işlenerek davranış kümeleri elde edilir. Her bir davranış kümesinin Örgü entropi yöntemi ile 1×36 boyutunda öznitelik vektörü hesaplanır. Bu vektörlerin değişinti matrisleri, ilgili anormal durumun öznitelik vektörü olarak sınıflandırma yönteminde temsil edilirler.

Burada özet olarak bahsedilen her bir aşama ilgili başlık altında detaylıca anlatılacaktır.



Şekil 2.37. Eğitim ve test aşamalarında gerçekleştirilen işlemler

2.3.1.1. Veri Girişi

Farklı türden anormal durumlara ait farklı uzunluktaki video görüntüleri t derinliğinde çerçeve sayısınca, bloklar halinde işlenir. Deneyler sonuçları, $t = 25$ çerçeve değerleri üzerinden hesaplanır.

2.3.1.2. Davranış Kümeleri Belirleme

Her bir t blok için farklı sayıda davranış kümeleri elde edilir. Bu kümeler hareketin ne tür bir davranış ya da olay olduğunun bilgisini taşır.

Davranış kümeleri aşağıda ifade edildiği gibi iki aşama halinde elde edilir.

2.3.1.2.1. Optik Akışı ve Parçacık Taşıma Yöntemleri

Optik akışı yöntemi ile görüntüdeki hareket bilgisi, hareket vektörleri olarak artarda ilerleyen görüntü çerçevelerinden elde edilir. 44 ve 45 denklemlerdeki u ve v , hareket vektörlerini gösterir.

Hareket vektörleri, parçacık taşıma yöntemi ile hareket izlerini oluşturmak için kullanılır. Bu sayede t tane çerçeve süresince gerçekleşen davranış ya da olaylar hareket izleri ile temsil edilir. Görüntünün boyutu $m \times n$ iken N tane parçacık için hareket izleri hesaplanır. $(x_{i(t)}, y_{i(t)})$, t anında i . parçacığın konumunu gösterir.

$$t = 1, 2, \dots, T$$

$$N = m * n$$

$$i = 1, 2, \dots, N$$

$$x_{i(t+1)} = x_{i(t)} + u[x_{i(t)}, y_{i(t)}] \quad (44)$$

$$y_{i(t+1)} = y_{i(t)} + v[x_{i(t)}, y_{i(t)}] \quad (45)$$

N , tane parçacığın konum bilgisi eşitlik 46 den 48 'e gösterilmiştir. Kümenin son elemanı parçacığın geldiği son konumu gösterir. Örneğin, trj_1 parçacığın son konumu (x_{1T}, y_{1T}) iken, trj_N . parçacığın son konumu ise (x_{NT}, y_{NT}) ile gösterilir.

$$trj_1 = \{(x_{11}, y_{11}), (x_{12}, y_{12}), \dots, (x_{1T}, y_{1T})\} \quad (46)$$

$$trj_2 = \{(x_{21}, y_{21}), (x_{22}, y_{22}), \dots, (x_{2T}, y_{2T})\} \quad (47)$$

⋮

$$trj_N = \{(x_{N1}, y_{N1}), (x_{N2}, y_{N2}), \dots, (x_{NT}, y_{NT})\} \quad (48)$$

Bu yöntemlerin detaylı anlatımı Bölüm 1.9-10 'da bulunmaktadır.

2.3.1.2.2. Ortalama Kayma Yöntemi

Ortalama kayma yöntemi sayesinde görüntüdeki hareketler birbirinden bağımsız olaylar olarak elde edilir. Yöntemde kullanılan, davranış kümesinin yarıçapı değeri deneysel olarak belirlenmiştir. Yöntem parçacıkların son konumlarına uygulanır.

$$\text{Ortalama Kayma} [(x_{1T}, y_{1T}), (x_{2T}, y_{2T}), \dots, (x_{NT}, y_{NT})] \quad (49)$$

Bu yöntemin detaylı anlatımı Bölüm 1.13 'de bulunmaktadır.

Sonuç olarak bu yöntem ile her t tane çerçeve süresince gerçekleşen olaylar farklı sayıda davranış kümeleri (θ) olarak elde edilir.

2.3.1.3. Değişinti Matrisleri Arası Uzaklık Ölçüm Metrikleri

Bu aşamada, her biri farklı türden anormal davranış içeren görüntüleri sınıflandırma aşamasında temsil etmek üzere değişinti matrisleri hesaplanır.

Öncelikli olarak elde edilen her bir davranış kümesinin örgü entropi yöntemi ile 1×36 boyutunda düzensizlik değerleri hesaplanır. Bu değerler davranış kümesinin düzensizliğine bağlı öznitelik vektörünü oluşturur.

Şekil 2.37'de kaza 1 görüntüsü için $t = 1$ için M tane davranış kümesi belirlenir. Her bir kümenin $\theta = [1 \times 36]$ boyutunda örgü öznitelik vektörü hesaplanır. Aynı şekilde, $t = 2$ için N tane davranış kümesi belirlenir ve her bir kümenin örgü öznitelik vektörü hesaplanır. Sonuç olarak, Her t anı için elde edilen davranış kümelerinin öznitelik vektörü ile bir matris oluşturulduğunda, kaza 1 görüntüsü için $[M + N + \dots \times 36]$ boyutunda bir öznitelik vektörü hesaplanır.

Farklı uzunlukta görüntülerden farklı sayılarda davranış kümeleri oluşturulur. Şekil 2.37'de gösterildiği gibi, kaza 1 için $[M + N + \dots \times 36]$ boyutta öznitelik vektörü hesaplanırken, kaza 2 için $[X + Y + \dots \times 36]$ ve patlama 1 için $[K + L + \dots \times 36]$ boyutta öznitelik vektörü hesaplanır. Sınıflandırma aşamasında her bir görüntüyü eşit boyutta öznitelik vektörü ile temsil etmek gerektiği için hesaplanan öznitelik vektörünün $[36 \times 36]$ boyutundaki değişinti matrisi ile bu gereklilik yeri getirilir. Dolayısıyla farklı türden anormal davranışlar içeren farklı uzunluktaki görüntüler sınıflandırma yönteminde eşit boyutta değişinti matrisi ile temsil edilirler.

$\mathbf{f} = \theta_{[b_1, b_2, b_3 \dots b_{36}]}$, bir davranış kümesinin örgü entropi ile hesaplanan öznitelik vektörü olarak gösterilir. $F = \{\mathbf{f}_k\}$, davranış kümelerinin öznitelik vektörlerinden oluşan bir kümedir.


Bu durumda değişinti matrisi

$$C := \frac{1}{S-1} \sum_{k=1}^S (\mathbf{f}_k - \mu)(\mathbf{f}_k - \mu)^T \quad (50)$$

olarak hesaplanır. μ , ortalama öznitelik vektörü $\mu = \sum_{k=1}^S \mathbf{f}_k$ ile hesaplanır.

Değişinti matrisi öznitelik vektörün boyutu ile ilgilidir ve $[36 \times 36]$ boyutunda elde edilir. Değişinti matrisi simetrik değerlerden oluşur. Dolayısıyla, $(36^2 + 37)/2$ tane farklı değer sınıflandırma yönteminde kullanılır.

Değişinti matrisini öznitelik vektörü olarak kullanan diğer çalışmalarda önerildiği üzere Öklid uzaklığı yerine Log-Öklid ve Affine-invariant uzaklık metrikleri kullanılmıştır. Bunun nedeni değişinti matrislerinin Riemannian manifoldlar üzerinde bulunmasıdır.



Şekil 2.38. Riemannian manifold üzerinde bulunan değişinti matrislerinin öklid uzayına taşınması

2.3.1.3.1. Log-Öklid Uzaklık Metriği

Log-Öklid ile iki değişinti matrisinin arasındaki uzaklık şu şekilde hesaplanır.

C_1, C_2 iki değişinti matrisi olmak üzere, öncelikle değişinti matrisleri öz vektörlerine ayrılır (51) [105].

$$C = VDV^T \quad (51)$$

Bu ayrışımın sonra değişinti matrisi (52) olarak tanımlanır.

$$\log(C) \triangleq V\tilde{D}V^T \quad (52)$$

Burada \tilde{D} , D matrisinin elemanlarının logaritmalarıyla değiştirilmesinden oluşan bir matristir. Değişinti matrisleri arasındaki uzaklık matris logaritmalar arasındaki farkın Forbenius formu olarak hesaplanır (53).

$$p_1(C_1, C_2) := \|\log(C_1), \log(C_2)\|_F \quad (53)$$

2.3.1.3.2. Affine-Invariant Riemannian Metriği

Değişinti matrisleri arası uzaklığı ölçen bir diğer metrik ise Affine-değişmez Riemannian metriğidir. İlk defa Forstner ve Moonen [60], tarafından geliştirilen yöntem, Tuzel ve arkadaşları tarafından nesne tespiti, takibi ve yüz tanıma çalışmalarında kullanılmıştır [56, 57, 59].


C_1, C_2 iki değişinti matrisi olmak üzere,

$$p_2(C_1, C_2) := \|\log(C_2^{-1}C_1)\|_2 = \sqrt{\sum_{k=1}^d \log_2 \lambda_k(C_1, C_2)} \quad (54)$$

$\log(\cdot)$, matrisin logaritmasını, $\|\cdot\|_2$ ise Forbenius formu ifade eder. $\lambda_k(C_1, C_2)$, değişinti matrislerinin öz değerleridir.

2.3.1.4. Öznitelik Vektörü Bileşenleri

Öznitelik vektörü görüntüden elde edilen değişinti matrisi ve hareket vektörlerinin histogram dağılımında elde edilen vektörlerden oluşur.




Şekil 2.39. Görüntüden elde edilen değişinti matrisi ile hesaplanan öznitelik vektörü

Değişinti matrisi ile öznitelik vektörü hesaplayarak farklı uzunluklardaki görüntüleri aynı uzunlukta vektörlerle öğrenme modelinde temsil edilirler. Değişinti matrisinin boyutu örgü entropi yöntemi ile elde edilen düzensizlik vektörünün boyutuna bağlıdır. Görüntüler farklı uzunluklarda olsa da $f = [36 \times 36]$ boyutunda öznitelik vektörü elde edilir (Şekil 2.39).

Bir diğer öznitelik ise optik akışı ile elde edilen hareket vektörlerinin büyüklük değerinin histogram dağılımına bağlıdır. Histogram 0' dan başlayıp, 0.1 artırarak 1.9'a kadar eşit bölgelere ayrılır. 1.9'dan büyük değerler tek bölgeye dahil edilir. Her bir hareket

kümesinden elde edilen histogram dağılımların değışti matrisi hesaplandığında her bir görüntü için $g = [20 \times 20]$ boyutunda bir diğeri öznitelik vektörü elde edilir (Şekil 2.40).



Şekil 2.40. Optik akışı hareket vektörlerinin histogram dağılımına bağlı öznitelik vektörü

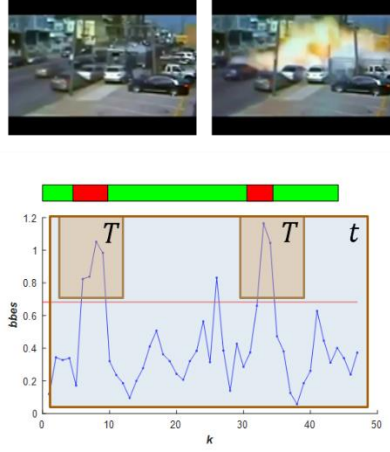
2.3.1.5. Davranış Sınıflandırma Sonuçları

Sınıflandırma yöntemi olarak En Yakın Komşu (NN) algoritması kullanılmıştır. NN yöntemi bilgisayarla görü ve makine öğrenmesi alanlarında sıklıkla kullanılan bir sınıflandırma yöntemidir. Danışmanlı bir sınıflandırma yöntemidir. Öncelikle yöntemde kullanılacak görüntüler ilgili uzayda etiketlenir. Sorgulanacak görüntü, kendisine en yakın görüntünün sınıfına dâhil edilir.

Çalışmamızda, 8 farklı anormal olay içeren görüntüler ile sınıflandırma işlemi gerçekleştirilecektir. Dolayısıyla sorgulanan görüntü bu 8 farklı türden kendisine en yakın görüntünün sınıfı ile etiketlenir.

Görüntüler arasındaki uzaklığı hesaplamak için literatürde birçok uzaklık hesaplama yöntemi vardır. Ancak bu çalışmada öznitelik vektörleri değışinti matrisleri olarak belirlenmiştir. Değışinti matrislerinin birbirlerine olan uzaklıkları Log-Öklid yöntemi ile hesaplanmıştır.

Sonuçlar 3 farklı senaryo ile değerlendirilmiştir. UCF veri tabanındaki 8 farklı sınıf için yapılan sınıflandırma sonuçları ile birlikte bu 8 sınıftan bazılarını davranış benzerliklerine göre gruplayarak 4 sınıfta toplamak üzere sınıflandırma ve her t blok için içerdiği davranışı sınıflandırmak üzere sonuçlar verilmiştir.



Şekil 2.41. Hangi çerçeve bloklarının öğrenme modeline dahil edildiğini gösterir

Ayrıca görüntüyü temsil edecek değişim matrisinin hangi t bloklarının dâhil edilmesiyle elde edileceği şu şekilde belirlenir (Şekil 2.41).

1- Bütün t bloklar; Görüntünün tamamı, yani bütün t bloklarında oluşan davranış kümeleri değişim matrisinin hesaplanmasına dâhil edilirler. Görüntü içerdiği bütün davranışlarıyla sınıflandırma yönteminde temsil edilirler.

2- Anormal olay içeren t bloklar (T); görüntünün tamamını kullanmak yerine anormal davranışların ya da olayların gerçekleştiği t bloklarından elde edilen değişim matrisi ile görüntü sınıflandırma yönteminde temsil edilir.

Anormal davranışların hangi t bloklarında olduğuna ise Bölüm 2.2.4.2'deki görüntünün genelindeki anormal durum tespiti çalışmamızda olduğu gibi karar verilir. Görüntünün artarda gelen t arasında ortalama değer üzerinde düzensizlik değerine sahip t bloklar anormal davranışın gerçekleştiği anlar olarak tespit edilir. Her bir davranış kümesi θ ile gösterilir.

$ortalama(tes) = \text{bütün } t \text{ blokların ortalama örgü entropi değeri}$

$std(tes) = \text{bütün } t \text{ blokların örgü entropi standart sapma değeri}$

$$\mu_{\theta} = ortalama(\theta_{[b_1, b_2, b_3 \dots b_{36}]}) \quad (55)$$

$$tes = \frac{\sum_1^{\varphi} \mu_{\theta}}{\varphi} \quad (56)$$

$$etiket_{sahne^t} = \begin{cases} anormal, & tes^t > ortalama(tes) + std(tes) \\ normal, & diğ er durum \end{cases} \quad (57)$$

UCF veri setindeki farklı türden anormal olaylara ait verilerin eğitim ve test aşamaları için bölünmesi ile oluşan dağılım Tablo 6'da gösterilmiştir. Genel itibari ile yarı yarıya dağılım olacak şekilde sayılar belirlenmiştir.

UCF veri setindeki bazı anormal olaylar davranışsal olarak benzerliklerine göre gruplara ayrılarak sınıflandırma işlemi gerçekleştirilmiştir. Birleştirilmiş davranışların eğitim ve test aşamaları için bölünmesi ile oluşan dağılım Tablo 8'de gösterilmiştir. Genel itibari ile yarı yarıya dağılım olacak şekilde sayılar belirlenmiştir.

Tablo 6. 8 Sınıf İçin Sınıflandırmada Kullanılan Görüntülerin Eğitim-Test Dağılımları

Trafik K.		Kundaklama		Patlama		Kavga		Taciz		Saldırı		Hırsızlık		Soygun	
E	T	E	T	E	T	E	T	E	T	E	T	E	T	E	T
28	28	8	8	19	19	27	27	29	29	34	35	41	42	57	58

E=Eğitim, T=Test

Tablo 7. Sınıflandırmanın Yüzdeler (%) Başarım Sonuçları

NN, % başarım	Trafik K.	Kundaklama	Patlama	Kavga	Taciz	Saldırı	Hırsızlık	Soygun
Örgü + log-Okliid (t)	46.42	50.00	63.15	51.85	62.06	48.57	45.23	43.10
Örgü + log-Okliid (T)	53.57	50.00	63.15	51.85	41.37	42.85	54.76	51.72
Örgü + Affine-Inv (t)	46.42	50.00	63.15	51.85	58.62	45.71	42.85	41.37
Örgü + Affine-Inv (T)	57.14	50.00	63.15	44.44	41.37	42.85	54.76	51.72
Hız + log-Okliid	53.57	37.50	78.94	62.96	48.27	48.57	45.23	55.17
Hız + Affine-Inv	50.00	62.50	57.89	74.07	75.86	45.71	52.38	36.20

t= Bütün çerçeveler kullanıldığında. T=Sadece anormal çerçeveler kullanıldığında

Tablo 8. 4 Sınıf İçin Sınıflandırmada Kullanılan Görüntülerin Eğitim-Test Dağılımları

Trafik Kazaları		Patlama - Kundaklama		Taciz – Saldırı - Kavga		Hırsızlık - Soygun	
E	T	E	T	E	T	E	T
28	28	27	27	90	91	98	100

E=Eğitim. T=Test

Tablo 9. Sınıflandırmanın Yüzdeler (%) Başarım Sonuçları

NN, % başarım	Trafik Kazaları	Patlama - Kundaklama	Taciz – Saldırı - Kavga	Hırsızlık - Soygun
Örgü + log-Okliid (t)	79.16	84.21	62.40	69.73
Örgü + log-Okliid (T)	75.00	78.94	61.60	67.10
Örgü + Affine-Inv (t)	79.16	78.94	65.60	75.00
Örgü + Affine-Inv (T)	75.00	78.94	58.40	65.13
Hız + log-Okliid	73.91	89.47	62.40	67.97
Hız + Affine-Inv	73.91	78.94	67.20	69.28

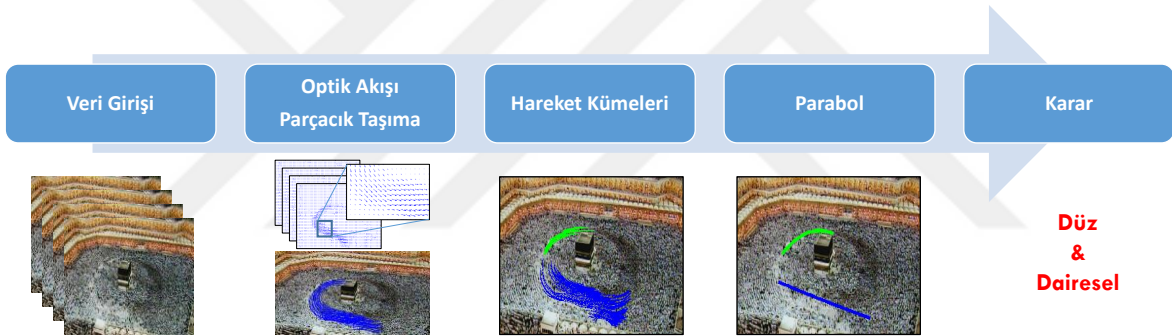
t= Bütün çerçeveler kullanıldığında. T=Sadece anormal çerçeveler kullanıldığında

2.3.2. Kalabalık Hareketlerini Sınıflandırmak

Kalabalık davranış analizi çalışmalarının ilgilendiği ve alternatif çözümler üretebildiği bir diğer konu ise kalabalığın hareketlerini tanımlamak ve daha anlamlı hale getirebilmektir. Kalabalık hareketlerini gözlemleyen güvenlik sistemleri için kalabalık hareketlerini sınıflandırmak ve davranışı açıklayıcı bilgiler sunmak kalabalığın güvenliği ve yönetimi açısından önemlidir.

Tezin bu bölümündeki çalışmasında, kalabalık hareketleri davranışsal bütünlük içerisinde kümelenip elde edilen her bir kümenin sınıflandırılması yapılır. Her bir kümenin “Düz” ya da “Dairesel” davranışa ne nispete yakınlığı hesaplanır.

Çalışmanın genel aşamaları Şekil 2.42’ de gösterilmiştir.



Şekil 2.42. Davranış sınıflandırma çalışmasının genel aşamaları

2.3.2.1. Optik Akışı ve Parçacık Taşıma Yöntemleri

Optik akışı görüntüdeki hareket bilgisini vektörler seviyesinde elde etmek için kullanılan bir yöntemdir. Görüntüdeki hareketlilik piksel seviyesinde hareket vektörleri olarak hesaplanır. Vektörler denklem 56 ve 57’de u ve v olarak gösterilmiştir.

Parçacık taşıma yöntemi ile her bir piksel üzerine yerleştirilen farazi parçacıklar, optik akışı yöntemi ile elde edilen hareket vektörleri değerine göre taşınır ve görüntüdeki hareket bilgisi hareket izleri olarak elde edilir. Görüntünün hareket veri seti hesaplanmış olur.

t tane çerçeve süresince gerçekleşen davranış ya da olaylar hareket izleri ile temsil edilir. Görüntünün boyutu $m \times n$ iken N tane parçacık için hareket izleri hesaplanır. $(x_{i(t)}, y_{i(t)})$. t anında i . parçacığın konumunu gösterir.

$$t = 1, 2, \dots, T$$

$$N = m * n$$

$$i = 1, 2, \dots, N$$

$$x_{i(t+1)} = x_{i(t)} + u[x_{i(t)}, y_{i(t)}] \quad (58)$$

$$y_{i(t+1)} = y_{i(t)} + v[x_{i(t)}, y_{i(t)}] \quad (59)$$

N . tane parçacığın konum bilgisi eşitlik 58'den 60'a gösterilmiştir. Kümenin son elemanı parçacığın geldiği son konumu gösterir. Örneğin. trj_1 parçacığın son konumu (x_{1T}, y_{1T}) iken. trj_N . parçacığın son konumu ise (x_{NT}, y_{NT}) ile gösterilir.

$$trj_1 = \{(x_{11}, y_{11}), (x_{12}, y_{12}), \dots, (x_{1T}, y_{1T})\} \quad (60)$$

$$trj_2 = \{(x_{21}, y_{21}), (x_{22}, y_{22}), \dots, (x_{2T}, y_{2T})\} \quad (61)$$

⋮

$$trj_N = \{(x_{N1}, y_{N1}), (x_{N2}, y_{N2}), \dots, (x_{NT}, y_{NT})\} \quad (62)$$

ve her parçacığın bir araya gelmesiyle oluşan ve görüntüdeki hareket bilgisini temsil eden veri kümesi ise;

$$TRJ_t^{t+T} = \{trj_1, trj_2, trj_3, \dots, trj_N\} \quad (63)$$

olarak hesaplanır.

2.3.2.2. Hareket Kümeleri Belirleme

Ortalama kayma yöntemi sayesinde görüntüdeki hareketler birbirinden bağımsız olaylar olarak elde edilir. Yöntemde kullanılan davranış kümesinin yarıçapı değeri deneysel olarak belirlenmiştir. Yöntem parçacıkların son konumlarına uygulanır.

$$\text{Ortalama Kayma } [(x_{1T}, y_{1T}) \cdot (x_{2T}, y_{2T}) \cdot \dots \cdot (x_{NT}, y_{NT})] \quad (64)$$

Sonuç olarak bu yöntem ile her t tane çerçeve süresince gerçekleşen olaylar farklı sayıda davranış kümeleri (θ) olarak elde edilir.

2.3.2.3. Hareket Kümelerini Parabol ile Temsil Etmek

Bu aşamada, görüntüden elde edilen hareket kümeleri parabol denklemler halinde temsil edilecektir. Bu sayede hareketli alanların tanımlanmasında ve kalabalığın davranışı anlamaya çalışma noktasında bu sonuçlar yardımcı olabilir.



Hareketi parabol olarak ifade etmek şu şekilde olur; parçacık taşıma yöntemi ile hareketlendirilen parçacıkların her bir adımdaki konumu hareketin gerçekleştiği konumlardır. Dolayısıyla hareket kümesinin oluşturan noktaları bir eğri olarak temsil ettiğimizde, hareket kümesini temsil etmiş oluruz. Her bir hareketi oluşturan noktalar kümesini en küçük kareler yöntemini kullanarak bir eğri (curve) olarak ifade edilebiliriz.

2.3.2.4. Hareket Sınıflandırma ve Sonuçları

Her bir hareketi ikinci dereceden bir denklem olarak ifade ettiğimizde, a katsayısının sıfıra yakınlığı-uzaklığı bu hareketin “düz” ya da “daireysel” şekilde bir davranışa yakınlığını nicel olarak ifade edebilir.



$$f(x) = ax^2 + bx + c \quad (65)$$

$$a = \begin{cases} \text{düz.} & \text{eğer } a \cong 0 \\ \text{daireysel.} & \text{eğer değilse} \end{cases} \quad (66)$$




mavi = 0.000786.
yeşil = -0.033997

a)




mavi = 0.001927
yeşil = -0.010793.
kırmızı = 0.000681

b)




mavi = 0.013857
yeşil = 0.040634

c)





mavi = 0.005957
yeşil = -0.009231
kırmızı = 0.032337

d)



mavi = -0.003065
yeşil = 0.002836
kırmızı = -0.079450
cyan = 0.024176
magenta = 0.006983

e)



mavi = 0.019147
yeşil = 0.000424

f)

Şekil 2.43. Hareket kümeleri "düz" ya da "daireysel" davranışlara yakınlığı nispette etiketlenir

Sonuç olarak bu çalışma, kalabalığın görüntü boyunca gösterdiği davranışı nicel olarak ifade etmek ve sınıflandırmak hedeflenmiştir. UCF-davranış [83] veri tabanından aldığımız bazı görüntüler üzerinde yöntemler test edilmiştir. Sonuçlar Şekil 2.43’de gösterilmiştir.

Bu sonuçlar ışığında caddenin ya da kalabalığın davranışı incelendiğinde, hareketin olağan durumlarda beklenen davranış modeli belirlenmiş olur. Bu modelin dışına çıktığını sistemin fark etmesi anormal bir durumun olduğuna işaret edebilir.

Örneğin, Şekil 2.43 (f)’ de trafik akışında tespit edilen ve yeşil renk ile renklendirilen hareket kümesinin davranışı $a = 0.000424$ ile 0’a oldukça yakın bir değerdedir. Bu sonuç hareketin *düz* bir davranış olduğunu gösterir. Bu sonuç caddenin davranışını olağan durumlar içerisinde belli bir süre takip edilmesiyle belirlenen bir modeldir. Farklı zamanlarda modelin değerindeki sapmalar caddede gerçekleşebilecek muhtemel anormal bir duruma işaret edebilir.

3. SONUÇLAR

Kalabalık davranış analizi çalışmaları, kalabalığın davranışını anlamak, yorumlamak için geliştirilen çözüm yöntemleridir. Görüntülerden kalabalık hareketleri ile ilgili ne kadar anlamlı bilgi elde edilse o nispette davranış daha iyi anlaşılacaktır. Kalabalığın davranışını anlamak ve bazı bilgileri sunmak kalabalığın güvenliği ve yönetimi açısından önemlidir.

Bu hedeflerin genel olarak çıktıları şu şekilde sıralanır.

Kalabalık hareketlerinin davranışı modellenir;

- Aynı yönde ilerleyen ve birçok çalışmada bir küme olarak ifade edilen hareketli grubunun içerisinde ne derece bir etkileşim-düzensizlik olduğu bölgesel olarak hesaplanabilir.
- Görüntünün bütünü ele alındığında, hareketli alanlardaki düzenli-düzensiz davranışlar sınıflandırılabilir ve belli zaman aralıkları için caddenin davranışı modellenilebilir. Bu sayede kalabalık hareketinin akışı hakkında genel bir kanaat elde edilir.
- Örgü entropi yöntemi ile hareket izlerinin davranış süresince birbirleriyle oluşturdukları örüntünün düzensizliğe bağlı değeri hesaplanır. Örgü entropi yöntemi davranışa nispeten farklı açılardan bakabilmeyi dolayısıyla oluşan yeni örüntünün düzensizlik değerini hesaplamayı sağlar. Bu sayede davranış farklı açılardan yorumlanabilir.
- Caddenin davranışı belli saat dilimleri için eğitilebilir ve davranış modeli öğrenilebilir. İlgili saat dilimi için beklenen davranışın dışında bir davranış olduğunda sistem bu durumu tespit edebilir.

Anormal durum tespit etme;

- Çalışmamız örgü entropi yöntemini kullanarak yerelde ve globalde gerçekleşen anormal durumları tespit etmeye yönelik hazırlanmıştır.
- İz tabanlı çalışmalara alternatif olarak hazırlanmıştır. Ancak izleme algoritmalarının uygulama zorluklarını gerçekleştirmek yerine, bütüncül bir yaklaşımla, grupların ya da kişilerin görüntü boyunca hareket izlerini elde etmek üzere olacaktır.

- Hareket vektörleri tabanlı çalışmalarda olduğu gibi davranışı belirli alan içerisine sınırlamak değil, belirli bir süre içerisinde, kişi ya da kişilere ait davranışın bütününe göre karar verme imkânı sağlar.
- Yerelde anormal durum tespitini gerçekleştirmek üzere UCSD Peds1 ve Peds2 veri kümeleri kullanılmıştır. Davranış kümelerine farklı açılardan bakarak, örgü entropi yöntemi ile düzensizliğine bağlı ve hareket vektörlerinin büyüklüğüne göre histogram dağılımına bağlı öznelilikler oluşturulur.

$t = 10$ çerçeve ve $t = 20$ çerçeve ile çerçeve derinliği ve $r = 5$ piksel ve $r = 10$ piksel ile davranışı içine alma genişliği olmak üzere değerler belirlenir. Deneylelerden elde edilen sonuçlara göre, en başarılı sonuçlar $AUC = 0,927$ - $ERR = 0,14$ ile 30° lik açılarla elde edilen Örgü entropi ve $Hız$ 'dan oluşturulan öznelilik vektörü ile elde edilmiştir (Örgü_30 + Hız) . Peds2 için ise $AUC = 0,95$ - $ERR = 0,09$ değerleri ile en başarılı sonuç yine aynı öznelilik vektörü ile elde edilmiştir.

- Başarımı etkileyen bir diğer önemli faktör ise, eşit süre zarfında bisikletli, kaykaylı ya da hareketli aracın oluşturduğu hareket izlerinin, normal yürüyüş halindeki yayaların oluşturduğu hareket izlerine nispeten çok daha fazla olmasıdır. Bu durum deneysel sonuçlardan tespit edilmiştir. Dolayısıyla, yoğun hareket izlerinden oluşan hareket kümesinin örgü entropi değeri nispeten daha fazla olur. Bu sayede yayalara göre daha hızlı ve değişken davranışa sahip hareketliler braid entropi yöntemi sayesinde başarılı bir şekilde tespit edilmiştir.
- Yöntemin başarısı literatürde gerçekleştirilen diğer çalışmalarla karşılaştırıldığında nispeten daha başarılı sonuçlar vermiştir. Ayrıca derin öğrenme yöntemleriyle yapılan çalışmalara oldukça yakın ve bazı değerleriyle daha başarılı sonuçlar üretmiştir.

- Globalde anormal durum tespitini gerçekleştirmek üzere UMN ve UCF – anormal olaylar veri kümeleri kullanılmıştır.

Belli t derinliğindeki çerçeve blokları için elde edilen hareket kümelerinin örgü entropi yöntemi ile hesaplanan düzensizlik değerlerinden sahnenin $bbes$ değeri hesaplanır. $bbes$ değerinin belli bir eşik değerin (τ) üstünde olması durumu anormal olayın gerçekleştiğini ifade eder.

UMN veri kümesinde normal ve anormal olayların etiketlidir. Çalışmamızda hesaplanan $bbes$ değerine bağlı ROC eğrileri ile UMN veri kümesi için eşik değerler

hesaplandığında $UMN1=0.99$ AUC, $UMN2=0.968$ AUC ve $UMN3=0.916$ AUC olmak üzere başarımlar elde edilmiştir. bu değerler literatürdeki çalışmalarla karşılaştırıldığında oldukça başarılı olduğu görülmüştür.

UCF veri kümesinde ise anormal-normal olaylar olmak üzere etiketli veriler olmadığı için eşik değeri bütün sahnelerin $ortalama(bbes) + std(bbes)$ değerine göre hesaplanmıştır. Sonuçlar, yersel doğruluk değerleri ile birlikte grafikler halinde sunulmuştur.

Davranış sınıflandırma;

- Anormal olayların sınıflandırılması problemi henüz literatürde çalışılmamış bir konudur. “Patlama, kundaklama, kavga, hırsızlık, trafik kazaları, soygun, saldırı, taciz” olmak üzere 8 farklı anormal davranış sınıflandırılmıştır.
- Her bir anormal davranış görüntüsünün örgü entropi değerine bağlı değişinti matrisi hesaplanır. Bu sayede, görüntü uzunlukları farklı olsa da her bir görüntü öğrenme modelinde eşit boyutta öznitelik vektörü ile temsil edilir. NN sınıflandırma yöntemi ile sınıflandırma gerçekleştirilir.
- Davranış benzerliklerine göre bazı anormal olaylar bir tür olarak değerlendirilip sınıf sayısı 4'e düşürüldüğünde sınıflandırma başarımları belli bir noktaya kadar iyileştirilmiştir.
- Kalabalık hareketleri “dairesel” ya da “düz” davranışlara yakınlığı nispetinde sınıflandırılmıştır.
- Görüntüdeki hareket kümeleri elde edilir ve davranışlar ikinci dereceden denklemler olarak ifade edilir.
- $ax^2 + bx + c$ denklemindeki a katsayısının 0' yakınlığı-uzaklığı davranışın “düz” ya da “dairesel” olduğunu ifade eder.

4. KAYNAKLAR

1. Challenger, R., Clegg, C.W. ve Robinson, M.A., Understanding crowd behaviours: Supporting evidence, The Cabinet Office, 2009.
2. Still, G.K., Crowd safety and Risk analysis, CRC Press, 2014.
3. Musse, S.R. ve Thalmann, D., Computer Animation and Simulation'97, A model of human crowd behavior: Group inter-relationship and collision detection analysis, Springer, 39-51, 1997.
4. Tilly, C., From mobilization to revolution, University of Michigan, 1977.
5. Lofland, J., Protest: Studies of collective behaviour and social movements, Routledge, 2017.
6. Ali, S. ve Shah, M., A lagrangian particle dynamics approach for crowd flow segmentation and stability analysis, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2007, Minneapolis, 1-6.
7. Shao, J., Change Loy, C. ve Wang, X., Scene-independent group profiling in crowd, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2014, Ohio, 2219-2226.
8. Asgary, A., <https://yorku.maps.arcgis.com/apps/webappviewer/index.html?id=e7c52856187642e19bd227865393432c> World Crowd Disasters. 24.11.2019.
9. Wikipedia, https://en.wikipedia.org/wiki/List_of_human_stampedes List of human stampedes. 24.11.2019.
10. Silveira Jacques Junior, J., Musse, S. ve Jung, C., Crowd Analysis Using Computer Vision Techniques, IEEE Signal Processing Magazine, 27, 5 (2010) 66-77.
11. Zhan, B., Monekosso, D.N., Remagnino, P., Velastin, S.A. ve Xu, L.-Q., Crowd analysis: a survey, Machine Vision and Applications, 19, 5-6 (2008) 345-357.
12. Li, T., Chang, H., Wang, M., Ni, B., Hong, R. ve Yan, S., Crowded scene analysis: A survey, IEEE Transactions on Circuits and Systems for Video Technology, 25, 3 (2015) 367-386.
13. Thida, M., Yong, Y.L., Climent-Pérez, P., Eng, H.-I. ve Remagnino, P., Intelligent Multimedia Surveillance, A Literature Review on Video Analytics of Crowded Scenes, 17-36, 2013.
14. Hu, W., Tan, T., Wang, L. ve Maybank, S., A Survey on Visual Surveillance of Object Motion and Behaviors, IEEE Transactions on Systems, Man and Cybernetics, 34, 3 (2004) 334-352.
15. Junior, J.C.S.J., Musse, S.R. ve Jung, C.R., Crowd analysis using computer vision techniques, IEEE Signal Processing Magazine, 27, 5 (2010) 66-77.
16. Zhou, B., Tang, X. ve Wang, X., Coherent filtering: detecting coherent motions from crowd clutters, European Conference on Computer Vision, Ekim 2012, Florence, 857-871.

17. Hu, M., Ali, S. ve Shah, M., Learning motion patterns in crowded scenes using motion flow field, 19th International Conference on Pattern Recognition, Aralık 2008, Florida, 1-5.
18. Hu, M., Ali, S. ve Shah, M., Detecting global motion patterns in complex videos, 19th International Conference on Pattern Recognition, Aralık 2008, Florida, 1-5.
19. Mehran, R., Moore, B.E. ve Shah, M., A streakline representation of flow in crowded scenes, European conference on computer vision, Eylül 2010, Crete, 439-452.
20. Wang, X., Yang, X., He, X., Teng, Q. ve Gao, M., A high accuracy flow segmentation method in crowded scenes based on streakline, Optik, 125, 3 (2014) 924-929.
21. Wu, S. ve Wong, H.S., Crowd motion partitioning in a scattered motion field, IEEE Trans Syst Man Cybern B Cybern, 42, 5 (2012) 1443-1454.
22. Cheriyyadat, A.M. ve Radke, R.J., Detecting dominant motions in dense crowds, IEEE Journal of Selected Topics in Signal Processing, 2, 4 (2008) 568-581.
23. Zhao, X. ve Medioni, G., Robust unsupervised motion pattern inference from video and applications, 13th International Conference on Computer Vision, Kasım 2011, Barcelona, 715-722.
24. Jodoin, P.-M., Benezeth, Y. ve Wang, Y., Meta-tracking for video scene understanding, 10th IEEE International Conference on Advanced Video and Signal Based Surveillance, Ağustos 2013, Krakow, 1-6.
25. Yang, Y., Liu, J. ve Shah, M., Video scene understanding using multi-scale analysis, IEEE International Conference on Computer Vision, Ekim 2009, Kyoto, 1669-1676.
26. Saleemi, I., Hartung, L. ve Shah, M., Scene understanding by statistical modeling of motion patterns, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 2010, San Francisco, 2069-2076.
27. Zhou, B., Wang, X. ve Tang, X., Random field topic model for semantic region analysis in crowded scenes from tracklets, IEEE Conference on Computer Vision and Pattern, Haziran 2011, Colorado, 3441-3448.
28. Zhou, B., Wang, X. ve Tang, X., Understanding collective crowd behaviors: Learning a mixture model of dynamic pedestrian-agents, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2012, Providence, 2871-2878.
29. Li, W., Mahadevan, V. ve Vasconcelos, N., Anomaly detection and localization in crowded scenes, IEEE Transactions on Pattern Analysis Machine Intelligence, 36, 1 (2014) 18-32.
30. Ali, S., Measuring flow complexity in videos, IEEE International Conference on Computer Vision, Aralık 2013, Sydney, 1097-1104.
31. Sodemann, A.A., Ross, M.P. ve Borghetti, B.J., A Review of Anomaly Detection in Automated Surveillance, IEEE Transactions on Systems, Man, and Cybernetics, 42, 6 (2012) 1257-1272.
32. Cong, Y., Yuan, J. ve Liu, J., Abnormal event detection in crowded scenes using sparse representation, Pattern Recognition, 46, 7 (2013) 1851-1864.

33. Wu, S., Wong, H.-S. ve Yu, Z., A Bayesian Model for Crowd Escape Behavior Detection, IEEE Transactions on Circuits and Systems for Video Technology, 24, 1 (2014) 85-98.
34. Kratz, L. ve Nishino, K., Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2009, Florida, 1446-1453.
35. Wang, B., Ye, M., Li, X., Zhao, F. ve Ding, J., Abnormal crowd behavior detection using high-frequency and spatio-temporal features, Machine Vision and Applications, 23, 3 (2011) 501-511.
36. Javan Roshtkhari, M. ve Levine, M.D., An on-line, real-time learning method for detecting anomalies in videos using spatio-temporal compositions, Computer Vision and Image Understanding, 117, 10 (2013) 1436-1452.
37. Bera, A., Kim, S. ve Manocha, D., Realtime Anomaly Detection Using Trajectory-Level Crowd Behavior Learning, IEEE Conference on Computer Vision and Pattern Recognition Workshops, Temmuz 2016, Las Vegas, 1289-1296.
38. Wang, S., Zhu, E., Yin, J. ve Porikli, F., Video anomaly detection and localization by local motion based joint video representation and OCELM, Neurocomputing, 277, 1 (2018) 161-175.
39. Khan, M.U.K., Park, H.-S. ve Kyung, C.-M., Rejecting Motion Outliers for Efficient Crowd Anomaly Detection, IEEE Transactions on Information Forensics and Security, 14, 2 (2019) 541-556.
40. Hu, X., Huang, Y., Gao, X., Luo, L. ve Duan, Q., Squirrel-Cage Local Binary Pattern and Its Application in Video Anomaly Detection, IEEE Transactions on Information Forensics and Security, 14, 4 (2019) 1007-1022.
41. Bertini, M., Del Bimbo, A. ve Seidenari, L., Multi-scale and real-time non-parametric approach for anomaly detection and localization, Computer Vision and Image Understanding, 116, 3 (2012) 320-329.
42. Colque, R.V.H.M., Caetano, C., de Andrade, M.T.L. ve Schwartz, W.R., Histograms of Optical Flow Orientation and Magnitude and Entropy to Detect Anomalous Events in Videos, IEEE Transactions on Circuits and Systems for Video Technology, 27, 3 (2017) 673-682.
43. Yang, H., Cao, Y., Wu, S., Lin, W., Zheng, S. ve Yu, Z., Abnormal crowd behavior detection based on local pressure model, Proceedings of The 2012 Asia Pacific Signal and Information Processing Association Annual Summit and Conference, Aralık 2012, Hollywood, 1-4.
44. Xiong, G., Wu, X., Chen, Y.-l. ve Ou, Y., Abnormal crowd behavior detection based on the energy model, IEEE International Conference on Information and Automation, Ağustos 2013, Ningxia, 495-500.
45. Bobick, A.F. ve Davis, J.W., The recognition of human movement using temporal templates, IEEE Transactions on Pattern Analysis Machine Intelligence, 23, 3 (2001) 257-267.
46. Weinland, D., Ronfard, R. ve Boyer, E., Free viewpoint action recognition using motion history volumes, Computer Vision and Image Understanding, 104, 2-3 (2006) 249-257.

47. Blank, M., Gorelick, L., Shechtman, E., Irani, M. ve Basri, R., Actions as space-time shapes, *IEEE International Conference on Computer Vision*, Ekim 2005, Beijing, 1395-1402.
48. Gorelick, L., Blank, M., Shechtman, E., Irani, M. ve Basri, R., Actions as space-time shapes, *IEEE Transactions on Pattern Analysis Machine Intelligence*, 29, 12 (2007) 2247-2253.
49. Yilmaz, A. ve Shah, M., Actions as objects: A novel action representation, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Haziran 2005, San Diego.
50. Solmaz, B., Moore, B.E. ve Shah, M., Identifying behaviors in crowd scenes using stability analysis for dynamical systems, *IEEE Transactions on Pattern Analysis Machine Intelligence*, 34, 10 (2012) 2064-2070.
51. Lucas, B.D. ve Kanade, T., An iterative image registration technique with an application to stereo vision, *7th International Joint Conference on Artificial Intelligence*, Ağustos 1981, Vancouver.
52. Horn, B.K. ve Schunck, B.G., Determining optical flow, *Artificial intelligence*, 17, 1-3 (1981) 185-203.
53. Sun, D., Roth, S. ve Black, M.J., Secrets of optical flow estimation and their principles, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Haziran 2010, San Francisco, 2432-2439.
54. Laptev, I., On space-time interest points, *International journal of computer vision*, 64, 2-3 (2005) 107-123.
55. Harris, C.G. ve Stephens, M., A combined corner and edge detector, *Alvey vision conference*, Ağustos 1988, Manchester, 10-5244.
56. Tuzel, O., Porikli, F. ve Meer, P., Region covariance: A fast descriptor for detection and classification, *European conference on computer vision*, Mayıs 2006, Graz, 589-600.
57. Tuzel, O., Porikli, F. ve Meer, P., Human Detection via Classification on Riemannian Manifolds, *IEEE Conference on Computer Vision and Pattern*, Haziran 2007, Minneapolis1, 4.
58. Arsigny, V., Fillard, P., Pennec, X. ve Ayache, N., Geometric means in a novel vector space structure on symmetric positive-definite matrices, *An Official Journal of the International Society for Magnetic Resonance in Medicine*, 29, 1 (2007) 328-347.
59. Tuzel, O., Porikli, F. ve Meer, P., Pedestrian detection via classification on Riemannian manifolds, *IEEE Transactions on Pattern Analysis Machine Intelligence*, 30, 10 (2008) 1713-1727.
60. Förstner, W. ve Moonen, B., *Geodesy-The Challenge of the 3rd Millennium*, A metric for covariance matrices, Springer, 299-309, 2003.
61. Sultani, W., Chen, C. ve Shah, M., Real-world anomaly detection in surveillance videos, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2018, Salt Lake City, 6479-6488.

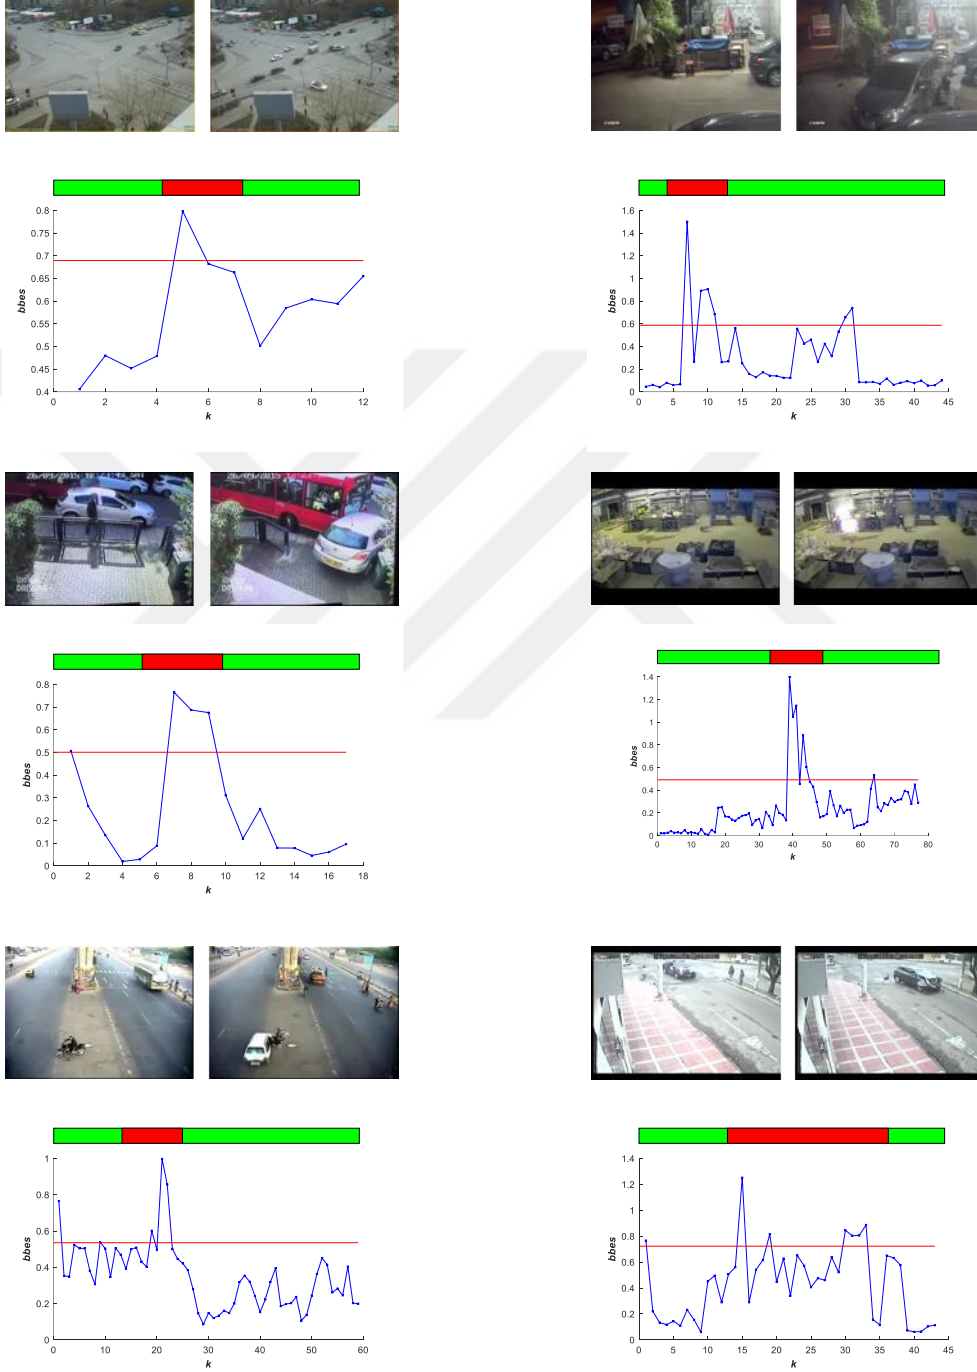
62. Mahadevan, V., Li, W., Bhalodia, V. ve Vasconcelos, N., Anomaly detection in crowded scenes, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 2010, San Francisco, 1975-1981.
63. University of Minnesota, D.o.C.S.a.E., http://mha.cs.umn.edu/proj_events.shtml#crowd UMN Crowd Dataset. 24.11.2019.
64. Krig, S., Computer Vision Metrics, Ground truth data, content, metrics, and analysis, Springer, 247-271, 2016.
65. Grosse, R., Johnson, M.K., Adelson, E.H. ve Freeman, W.T., Ground truth dataset and baseline evaluations for intrinsic image algorithms, IEEE International Conference on Computer Vision, Ekim 2009, Kyoto, 2335-2342.
66. Barron, J.L., Fleet, D.J. ve Beauchemin, S.S., Performance of optical flow techniques, International journal of computer vision, 12, 1 (1994) 43-77.
67. Bouguet ve Jean-Yves, Pyramidal implementation of the affine lucas kanade feature tracker description of the algorithm, Intel Corporation, 5, 1-10 (2001) 4.
68. Brox, T., Bruhn, A., Papenberg, N. ve Weickert, J., High accuracy optical flow estimation based on a theory for warping, European conference on computer vision, Mayıs 2004, Prague, 25-36.
69. Ali, S. ve Shah, M., Floor fields for tracking in high density crowd scenes, European conference on computer vision, Ekim 2008, Marseille, 1-14.
70. Moussafir, J.-O., On computing the entropy of braids, Functional Analysis and Other Mathematics, 1, 1 (2006) 37-46.
71. Thiffeault, J.L., Braids of entangled particle trajectories, Chaos, 20, 1 (2010) 017516.
72. Allshouse, M.R. ve Thiffeault, J.-L., Detecting coherent structures using braids, Chaos: An Interdisciplinary Journal of Nonlinear Science, 241, 2 (2012) 95-105.
73. Allshouse, M.R. Finding Lagrangian structures via the application of braid theory, 2010.
74. Puckett, J.G., Lechenault, F., Daniels, K.E. ve Thiffeault, J.-L., Trajectory entanglement in dense granular materials, Journal of Statistical Mechanics: Theory and Experiment, 2012, 06 (2012) P06008.
75. Budišić, M., Thiffeault ve Jean-Luc, Finite-time braiding exponents, Chaos: An Interdisciplinary Journal of Nonlinear Science, 25, 8 (2015) 087407.
76. Thiffeault, Jean-Luc ve Budisic, M. Braidlab: A software package for braids and loops, 2014.
77. Rasmussen, C.E., The infinite Gaussian mixture model, Advances in neural information processing systems, Kasım 2000, San Diego, 554-560.
78. Comaniciu, D. ve Meer, P., Mean shift analysis and applications, IEEE International Conference on Computer Vision, Eylül 1999, Kerkyra, 1197-1203.
79. Comaniciu, D. ve Meer, P., Mean shift: A robust approach toward feature space analysis, IEEE Transactions on Pattern Analysis Machine Intelligence, 24, 5 (2002) 603-619.

80. Fukunaga, K. ve Hostetler, L., The estimation of the gradient of a density function, with applications in pattern recognition, IEEE Transactions on information theory, 21, 1 (1975) 32-40.
81. Phyu, T.N., Survey of classification techniques in data mining, Proceedings of the International MultiConference of Engineers and Computer Scientists, Mart 2009, Hong Kong, 18-20.
82. Pal, S.K. ve Mitra, P., Pattern recognition algorithms for data mining, Chapman ve Hall/CRC, 2004.
83. Florida, U.o.C., [https://www.crcv.ucf.edu/home/data-sets/ Crowd Behavior Dataset](https://www.crcv.ucf.edu/home/data-sets/Crowd%20Behavior%20Dataset). 24.11.2019.
84. Wang, X., <http://www.ee.cuhk.edu.hk/~xgwang/datasets.html> CUHK Crowd Dataset. 24.11.2019.
85. Zhou, B., Tang, X. ve Wang, X., Measuring crowd collectiveness, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2013, Portland, 3049-3056.
86. Hasan, M., Choi, J., Neumann, J., Roy-Chowdhury, A.K. ve Davis, L.S., Learning temporal regularity in video sequences, IEEE International Conference on Computer Vision, Temmuz 2016, Las Vegas, 733-742.
87. Li, N., Wu, X., Xu, D., Guo, H. ve Feng, W., Spatio-temporal context analysis within video volumes for anomalous-event detection and localization, Neurocomputing, 155, 1 (2015) 309-319.
88. Zhang, Y., Lu, H., Zhang, L. ve Ruan, X., Combining motion and appearance cues for anomaly detection, Pattern Recognition, 51, (2016) 443-452.
89. Luo, W., Liu, W. ve Gao, S., Remembering history with convolutional LSTM for anomaly detection, IEEE International Conference on Multimedia and Expo, Temmuz 2017, Hong Kong, 439-444.
90. Lu, C., Shi, J. ve Jia, J., Abnormal Event Detection at 150 FPS in MATLAB, IEEE International Conference on Computer Vision, Aralık 2013, Sydney, 2720-2727.
91. Ravanbakhsh, M., Nabi, M., Mousavi, H., Sangineto, E. ve Sebe, N., Plug-and-play cnn for crowd motion analysis: An application in abnormal event detection, IEEE Winter Conference on Applications of Computer Vision, Mart 2018, Lake Tahoe, 1689-1698.
92. Saligrama, V. ve Chen, Z., Video anomaly detection based on local statistical aggregates, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2012, Providence, 2112-2119.
93. Sezer, E.S. ve Can, A.B., Anomaly Detection in Crowded Scenes Using Log-Euclidean Covariance Matrix, 13th International Joint Conference on Computer Vision, Ocak 2018, Portugal, 279-286.
94. Shi, Y., Gao, Y. ve Wang, R., Real-time abnormal event detection in complicated scenes, 20th International Conference on Pattern Recognition, Ağustos 2010, Istanbul, 3653-3656.
95. Cong, Y., Yuan, J. ve Liu, J., Sparse reconstruction cost for abnormal event detection, IEEE Conference on Computer Vision and Pattern, Kasım 2011, Barcelona, 3449-3456.

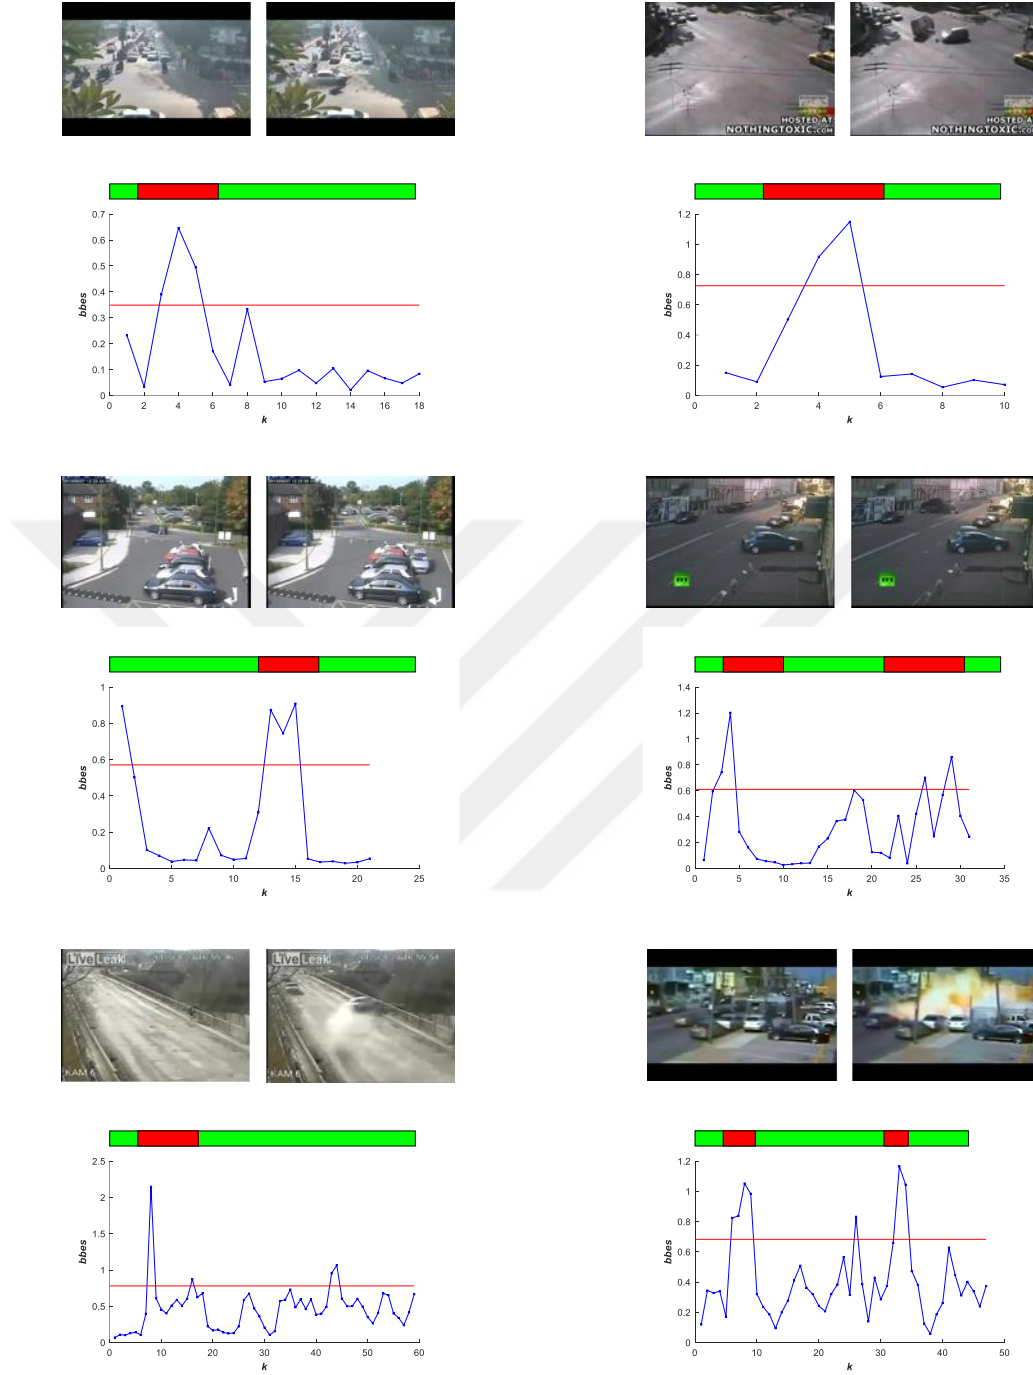
96. Lee, D.-G., Suk, H.-I. ve Lee, S.-W., Crowd behavior representation using motion influence matrix for anomaly detection, 2nd IAPR Asian Conference on Pattern Recognition, Kasım 2013, Okinawa, 110-114.
97. Marsden, M., McGuinness, K., Little, S. ve O'Connor, N.E., Holistic features for real-time crowd behaviour anomaly detection, IEEE International Conference on Image Processing, Eylül 2016, Phoenix, 918-922.
98. Wang, T. ve Snoussi, H., Detection of abnormal events via optical flow feature analysis, Sensors, 15, 4 (2015) 7156-7171.
99. Pennisi, A., Bloisi, D.D. ve Iocchi, L., Online real-time crowd behavior detection in video sequences, Computer Vision and Image Understanding, 144, C (2016) 166-176.
100. Zhang, Y., Lu, H., Zhang, L. ve Ruan, X.J.P.R., Combining motion and appearance cues for anomaly detection, Pattern Recognition, 51, 1 (2016) 443-452.
101. Wang, T., Chen, J. ve Snoussi, H., Online detection of abnormal events in video streams, Journal of Electrical Computer Engineering, 2013, 1 (2013) 20.
102. Hu, Y., Zhang, Y. ve Davis, L., Unsupervised abnormal crowd activity detection using semiparametric scan statistic, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2013, Oregon, 767-774.
103. Wu, S., Moore, B.E. ve Shah, M., Chaotic invariants of lagrangian particle trajectories for anomaly detection in crowded scenes, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 2010, San Francisco, 2054-2060.
104. Mehran, R., Oyama, A. ve Shah, M., Abnormal crowd behavior detection using social force model, IEEE Conference on Computer Vision and Pattern Recognition, Haziran 2009, Florida, 935-942.
105. Arsigny, V., Fillard, P., Pennec, X. ve Ayache, N., Log-Euclidean metrics for fast and simple calculus on diffusion tensors, Magnetic Resonance in Medicine, 56, 2 (2006) 411-421.

5. EKLER

Ek.1 UCF anormal durum veri tabanından sonuçlar




Ek Şekil 1. UCF veri kümesinden bazı görüntüler üzerinde hesaplanır ve anormal durum anlarını gösterir. Kırmızı çizgiler anormal durum için eşik değeri ifade eder ve bbes değerinin ortalama+standart sapma değeridir





Ek Şekil 2. UCF veri kümesinden bazı görüntüler üzerinde hesaplanır ve anormal durum anlarını gösterir. Kırmızı çizgiler anormal durum için eşik değeri ifade eder ve bbes değerinin ortalama+standart sapma değeridir

Ek.2 UCF ve CUHK davranış veri kümelerinden sonuçlar




Ek Şekil 3. Veri kümelerinden 49 farklı senaryo için hesaplanan ve görüntüdeki düzensiz ve düzenli alanların ortalama değerini gösterir

Ek. 3 UCF suç veri tabanından örnek görüntüler

Trafik Kazaları**Soygun****Saldırı****Patlama**

Ek Şekil 4. UCF Anormal veri kümesinden görüntüler

Hırsızlık**Kundaklama****Kavgı****Taciz**

Ek Şekil 5. UCF Anormal veri kümesinden görüntüler

ÖZGEÇMİŞ

12.06.1984 yılında Bayburt'ta doğdu. İlk, orta ve lise eğitimini Bayburt'ta tamamladı. 2008 yılında Ondokuz Mayıs üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri eğitimi bölümünü bitirdi. 2013 yılında TOBB - Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği bölümünde yüksek lisansını tamamladı. 2009 yılından bugüne Gümüşhane Üniversitesi, Kelkit Aydın Doğan Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümünde öğretim görevlisi olarak iş hayatına devam etmektedir.

Yayınlar

SCI veya SCI-Expanded kapsamında yapılan yayınlar

1. Akpulat. M. and M. Ekinci. *Detecting interaction/complexity within crowd movements using örgü entropy*. Springer-Frontiers of Information Technology & Electronic Engineering. 2019. **20**(6): p. 849-861.
2. Akpulat. M. and M. Ekinci. Detecting Local and Global Abnormal Behaviors in Crowd Scenes

Uluslararası Alan Dergi kapsamında yapılan yayınlar

1. Akpulat. M. and M. Ekinci. *Defining Crowd Movement as Parabola and Classifying These Definitions*. International Journal of Applied Mathematics. Electronics Computers. 2016(Special Issue-1): p. 165-169.

Konferanslar kapsamında yapılan yayınlar

1. Akpulat. M. and M. Ekinci. *Determining complexity within the crowd movements*. in *2018 26th Signal Processing and Communications Applications Conference (SIU)*. 2018. IEEE.
2. Akpulat. M. and M. Ekinci. *Observing the Entropy of Crowd Movements*. . in *2017 25th Signal Processing and Communications Applications Conference (SIU)*. 2017. IEEE.

3. Akpulat. M. and M. Ekinici. *Detecting and classifying dominant crowd movements through particle advection. in 2016 24th Signal Processing and Communications Applications Conference (SIU). 2016. IEEE.*
4. Akpulat. M. and M. Ekinici. *Defining Crowd Movement as Parabola and Classifying These Definitions. in 2016 5th International Conference on Advanced Technologies (ICAT'16)*

