

**KALABALIK GÖZETLEME ORTAMLARINDA ANOMALİ
TESPİTİ**

**ANOMALY DETECTION IN CROWDED SURVEILLANCE
SCENES**

EFSUN SEFA SEZER

DOÇ. DR. AHMET BURAK CAN

Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
Bilgisayar Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2017

EF SUN SEFA SEZER' in hazırladığı “**Kalabalık Gözetleme Ortamlarında Anomali Tespiti**” adlı bu çalışma aşağıdaki jüri tarafından **BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**' nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Yrd. Doç. Dr. Murat AYDOS

Başkan



Doç. Dr. Ahmet Burak CAN

Danışman



Yrd. Doç. Dr. Adnan ÖZSOY

Üye



Yrd. Doç. Dr. Fuat AKAL

Üye



Yrd. Doç. Dr. Mehmet DEMİRCİ

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.

(Bu seçenikle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etmeniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- Tezimin/Raporumun 17/07/2019 tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.

- Serbest Seçenek/Yazarın Seçimi

17 / 07 / 2017


(İmza)

Öğrencinin Adı Soyadı



Hayatım boyunca bana destek olan, zor zamanlarımda bile yüzümü

güldüren Anneme....

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

19/06/2017



Efsun Sefa SEZER

ÖZET

KALABALIK GÖZETLEME ORTAMLARINDA ANOMALİ TESPİTİ

Efsun Sefa SEZER

Yüksek Lisans, Bilgisayar Mühendisliği Bölümü

Tez Danışmanı: Doç. Dr. Ahmet Burak CAN

Haziran 2017, 81 sayfa

Kamera güvenlik sistemleri, geniş kullanım alanlarına sahip etkili güvenlik sağlama yöntemlerindedir. Bu sistemlerden elde edilen görüntülerin güvenlik personeli tarafından incelenmesiyle, tehlike içeren durumların belirlenmesi ve gerekli tedbirlerin alınması sağlanmaktadır. Son yıllarda artan teknolojik gelişmelerin kamera maliyetini azaltması, gözetleme sistemlerinin kullanımını arttırarak, büyük miktarda veri elde edilmesine neden olmuştur. Bu verinin insan eli işlenmesi oldukça zahmetli ve zaman alıcıdır. İnsan beyni görsel dikkat modülünün sınırlı bir yapıya sahip olması nedeniyle, insan dikkati belirli süre sonunda büyük düşüş göstermektedir. Bu durum, büyük miktarda verinin insan eli ile analizinde ciddi problemler yaşanmasına sebep olur. Akıllı video gözetim sistemleri, insan gücüne ihtiyacı azaltarak, büyük video verilerinden anlamlı bilginin elde edilmesine yardım etmektedir.

Akıllı video gözetim sistemlerinde önemli hedeflerden biri, görüntülerin etkili şekilde değerlendirilerek anormal ve normal durumların birbirinden ayrılması, ilgili operatöre anormal olaylarla ilgili uyarı verilmesidir. Bu sistemlerin tasarlanmasında çeşitli yöntemler kullanılsa da genel yaklaşım, normal olayların modellenmesi ve modele uymayan anormal durumların belirlenmesi şeklindedir.

Bahsedilen yaklaşımın tercih edilmesinde, anomali tanımının içeriğe göre değişiklik göstermesi, yani belirli bir sahne için anormal kabul edilen durumların bir başka sahnede normal sayılabilmesi ve anormal durumlara ait eğitim örneği elde edilmesinde yaşanan zorluklar rol oynamaktadır.

Bu çalışmada çok parçalı optik akış histogram özneliği ve logaritmik kovaryans matrisleri tek sınıf sınıflandırma yöntemleri ile otomatik anomali tespitinde kullanılmıştır.

Logaritmik kovaryans matrisleri, optik akış tabanlı kinematik öznelikler ve görünüm öznelikleri ile birlikte ilk defa anomali tespitinde kullanılmış ve başarılı sonuçlar elde edilmiştir.

Hareket temsili için ayrı ayrı gradyan veya optik akış tabanlı özneliklerden yararlanan geleneksel yöntemlerin aksine, hareket ve görünüm hakkında bilgi sağlayan iki önemli öznelik türü kovaryans matrisi yardımı ile birleştirilerek kullanılmıştır. Kovaryans matrisleri, Riemannian manifoldunun özel bir türünü oluşturan simetrik pozitif tanımlı matrislerdir ve geleneksel Öklid operasyonları için uygun değildir. Bilindiği üzere bilgisayarlı görü algoritmalarının çoğu Öklid uzayında bulunan veri noktaları için geliştirilmektedir. Bu nedenle elde edilen kovaryans matrisleri logaritmik kovaryans matrislerine dönüştürülerek Öklid uzayına eşlenmiştir.

Anormal durum tespitinde ilk aşama olan model oluşturma işlemi, sadece normal olaylardan elde edilen özneliklerin, tek sınıf sınıflandırma yöntemleriyle (Destek Vektör Makineleri, Destek Vektör Veri Tanımı) kullanılmasıyla yapılmıştır. Bu sayede görülmesi muhtemel olayları temsil eden bir model kurulmuştur. Anomali tespiti ise modele uymayan, farklılık gösteren olayların belirlenmesiyle gerçekleştirilmiştir.

Çalışma kapsamında bir anormal davranış veri kümesi üzerinde gerçekleştirilen deneyler ve önceki çalışmalarla yapılan karşılaştırmalar anormal durum tespitinde başarılı sonuçlar elde edildiğini göstermektedir.

Anahtar Kelimeler: Anomali tespiti, çok parçalı optik akış histogramı, logaritmik kovaryans matrisleri, kalabalık hareket analizi, tek sınıf sınıflandırma.

ABSTRACT

ANOMALY DETECTION IN CROWDED SURVEILLANCE SCENES

Efsun Sefa SEZER

Master of Science, Computer Engineering Department

Supervisor: Assoc. Prof. Ahmet Burak CAN

June 2017, 81 pages

Camera surveillance systems are effective security methods with a wide range of uses. Videos obtained from these systems are examined by the security personnel in order to determine the dangerous situations and take the necessary precautions. Increasing technological developments in recent years have led to reductions in the cost of cameras and an increase in the use of surveillance systems and the amount of video data being acquired. Processing these data manually is very hard and time consuming. The visual attention module of the human brain is limited and thus, human attention shows a great decline after a certain period of time. This is the serious problem in manual analysis of large amounts of data. Intelligent video surveillance systems reduce the need for human power and enable to obtain meaningful information from large amount of video data.

One of the important purpose of intelligent video surveillance systems is to analyse videos effectively to distinguish between normal and abnormal conditions and to alert the relevant operator about abnormal events. Although various methods are used to design intelligent surveillance systems, general approach is modeling normal events and identifying abnormal

situations that do not fit into the model. The reasons for this approach are that the anomaly definition varies according to the content, namely, situations considered abnormal for a particular scene may be considered normal in another scene and the difficulties in finding the abnormal training samples.

In this study, multi-scale histogram of optical flow features (MHOF) and log-Euclidean covariance matrices are used in automatic anomaly detection with single class classification methods. Log-Euclidean covariance matrices are used for the first time to detect anomalies. Unlike traditional methods, which utilize gradient-based or optical flow-based features for motion representation, two important types of features that encode motion and appearance cues are combined with the help of covariance matrix. Covariance matrices are symmetric positive definite (SPD) matrices which form a special model of the Riemannian manifold and are not suitable for traditional Euclidean operations. Most of the computer vision algorithms are developed for data points located in Euclidean space. For this reason, covariance matrices are mapped to Euclidean space by utilizing log-Euclidean framework. The model building process, which is the first step in the detection of abnormal situations, is performed by using features obtained from normal events with single class classification methods (Support Vector Machines, Support Vector Data Description). In the detection process, dissimilar events meaning that do not fit the model are marked as abnormal. Experiments carried out on an anomaly detection benchmark dataset and comparisons made with previous studies within the scope of the study show that successful results are obtained in detecting abnormal situations.

Keywords: Anomaly detection, multi-scale histogram of optical flow, log-Euclidean covariance matrices, crowd motion analysis, one class classification.

TEŞEKKÜR

Bu tezin ortaya çıkmasında bana yardımcı olan, birlikte çalışmaktan mutluluk duyduğum danışmanım Sayın Doç. Dr. Ahmet Burak CAN'a tecrübelerinden yararlanırken göstermiş olduğu hoşgörü ve sabırdan dolayı teşekkür ederim.

Tez metnini inceleyerek biçim ve içerik bakımından olgunlaşmasına katkıda bulunan Sayın Yrd. Doç. Dr. Adnan ÖZSOY'a, Sayın Yrd. Doç. Dr. Mehmet DEMİRCİ'ye, Sayın Yrd. Doç. Dr. Fuat AKAL'a, Sayın Yrd. Doç. Dr. Murat AYDOS'a teşekkür ederim.

Çalışmalarım boyunca bana zaman ayıran, deneyimlerini benimle paylaşan Çağdaş BAŞ ve bu süreçte desteklerini esirgemeyen çalışma arkadaşlarıma teşekkür ederim.

Tanıştığım için kendimi çok şanslı saydığım, değerli arkadaşlarım Yektanurşin DUYAN ve Kübra ÇİÇEKLİ'ye teşekkür ederim.

Hayatımın her anında bana güç veren, destek olan annem ve babama,

Deneyim ve tecrübeleriyle bana yol gösteren, yanımda olan en büyük destekçilerimden biri Hüseyin YAŞAR'a,

ve

Hayatımı derinden etkileyen, kim olacağımı bulmama yardımcı olan ablam Gevher SEZER-YAŞAR'a canı gönülden teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ŞEKİLLER	viii
SİMGELER VE KISALTMALAR	xi
ÇİZELGELER.....	xii
1 GİRİŞ	1
1.1 Motivasyon ve Özgün Değer	2
1.2 Tez Düzeni	3
2 LİTERATÜR ÖZETİ	4
2.1 Kalabalık Sahnelerde Hareket Temsili	4
2.1.1 Akış Temelli Öznitelikler	4
2.1.2 Yerel Uzaysal-Zamansal Öznitelikler	6
2.1.3 Yörünge Öznitelikleri.....	6
2.2 Kalabalık Davranış Analizi.....	6
2.2.1 Bireysel Yaklaşımlar	6
2.2.2 Bütüncül Yaklaşımlar	7
2.2.3 Hibrit Yaklaşımlar	7
2.3 Anomali Tespitinde Kullanılan Sınıflandırma Yöntemleri.....	7
2.3.1 Denetimli Yaklaşımlar.....	8
2.3.2 Yarı Denetimli Yaklaşımlar	8
2.3.3 Denetimsiz Yaklaşımlar	8
2.4 Anomali Tespiti	8
3 KALABALIK GÖZETLEME ORTAMLARINDA ANOMALİ TESPİTİ.....	14
3.1 Logaritmik Öklid Kovaryans Matrisleri (Log-Euclidean Covariance Matrices - LECM)	14
3.1.1 Giriş	14
3.1.2 Optik Akış Hesabı	16
3.1.3 Simetrik – Pozitif Belirli Matrisler için Log-Öklid Metriği.....	21
3.1.4 LECM-1.....	23

3.1.5	LECM-2.....	34
3.2	MHOF Özniteliği.....	35
3.3	Tek Sınıf Sınıflandırma Yöntemleri ile Anomali Tespiti	36
3.3.1	Tek Sınıf Destek Vektör Makineleri (OCSVM - One Class Support Vector Machines).....	37
3.3.2	Destek Vektör Veri Tanımı (SVDD - Support Vector Data Description).....	38
4	DENEYSEL SONUÇLAR.....	40
4.1	Veri Kümesi.....	40
4.2	Performans Metrikleri.....	40
4.3	DeneySEL Sonuçlar	42
4.3.1	SVDD ile Elde Edilen Sonuçlar	42
4.3.2	UMN Veri Kümesi Üzerinde Etiketleme	45
4.3.3	OCSVM ile Elde Edilen Sonuçlar	48
4.3.3.1	LECM-1 + OCSVM.....	48
4.3.3.2	LECM-2 + OCSVM.....	51
4.3.3.3	MHOF + OCSVM	55
4.3.3.4	Önerilen Yöntemin Mevcut Yöntemlerle Karşılaştırılması.....	56
5	BULGULAR VE GELECEĞE YÖNELİK ÖNERİLER	59
	KAYNAKLAR.....	61
	ÖZGEÇMİŞ.....	65

ŞEKİLLER

Sayfa

Şekil 2.1 (a) Optik akışın görselleştirilmesi: Dönen küre, ortada gösterilen optik akış alanını üretir. (b) (c) (d) Sırasıyla optik akış, parçacık akışı ve çizgi akışındaki $t = 0$ ile $t=18$ zaman periyodundaki öznitelik vektörlerinin değişiminin karşılaştırılması. ([4] ve [8]'den alınmıştır.)	5
Şekil 2.2 Lokal ve global anormal olay gösterimi: Her bir elips hareketli bir yayayı temsil eder. (a) Lokal anormal olay : Kırmızı yayanın davranışı komşularından farklılık göstermektedir. (b) Global anormal olay : Sahne genelinde gözlemlenen anormal grup davranışı. ([15]'ten alınmıştır.).....	9
Şekil 3.1 Önerilen anormal durum tespiti algoritmasına genel bakış : Hareket ve görünüm bilgisi kullanılarak oluşturulan kovaryans matrisi logaritmik kovaryans matrisine dönüştürülerek Öklid düzlemine eşlenir. Anomali tespiti tek sınıf sınıflandırma yöntemleri kullanılarak gerçekleştirilir.....	15
Şekil 3.2 Sahne-1 'de normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.	18
Şekil 3.3 Sahne-2' de normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.	19
Şekil 3.4 Sahne-3' te normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.	20
Şekil 3.5 Sahne-1' de normal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	25

Şekil 3.6 Sahne-1'de anormal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	26
Şekil 3.7 Sahne-2'de normal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	27
Şekil 3.8 Sahne-2'de anormal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	28
Şekil 3.9 Sahne-3'te normal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	29
Şekil 3.10 Sahne-3'te anormal olaylar sırasında elde edilen görünüm öznitelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü	30
Şekil 3.11 Kinematik öznitelikler Sahne-1 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri.....	31
Şekil 3.12 Kinematik öznitelikler Sahne-2 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri.....	32
Şekil 3.13 Kinematik öznitelikler Sahne-3 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri.....	33
Şekil 3.14 MHOF özniteliğinin hesaplanması (a) (b) Video üzerinde Horn-Schunck yöntemi ile optik akış hesaplanır. (c) (d) Görüntüler küçük bloklara bölünür ve her blok için MHOF özniteliği elde edilir. Daha sonra görüntü üzerinde küçük bloklardan elde edilen öznitelikler	

birleştirilerek global MHOF özneteliği elde edilir. Yukarıdaki histogramda sağ taraf eşik değerinden büyük kesimleri, sol taraf küçük kesimleri göstermektedir.....	36
Şekil 3.15 Tek sınıf Destek Vektör Makineleri. Başlangıç noktasının ikinci sınıfa ait eleman olduğu varsayılmaktadır. ([46]'den alıntılanmıştır.)	37
Şekil 3.16 Hiperdüzlem tek sınıf Destek Vektör Makinesi (OCSVM), hiperküre Destek Vektör Tanımı (SVDD) ([48]'den alıntılanmıştır.)	39
Şekil 4.1 UMN veri kümesine ait üç farklı sahnede gözlemlenen normal ve anormal durumların gösterimi	41
Şekil 4.2 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-1 + SVDD).....	42
Şekil 4.3 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-2 + SVDD).....	43
Şekil 4.4 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (MHOF + SVDD).....	44
Şekil 4.5 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-1 + OCSVM).....	48
Şekil 4.6 Etiketlerin yeniden düzenlenmesiyle elde edilen üç sahneye ilişkin ROC eğrisi (LECM-1 + OCSVM).....	49
Şekil 4.7 UMN veri kümesinde sahne-1 ve sahne-2'de tespit edilen anormal aktivite örnekleri (LECM-1 + OCSVM)	50
Şekil 4.8 UMN veri kümesi sahne-3'te tespit edilen anormal aktivite örnekleri (LECM-1 + OCSVM).....	51
Şekil 4.9 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-2 + OCSVM).....	52
Şekil 4.10 Etiketlerin yeniden düzenlenmesiyle elde edilen üç sahneye ilişkin ROC eğrisi (LECM-2 + OCSVM).....	53
Şekil 4.11 UMN veri kümesinde sahne-1 ve sahne-2'de tespit edilen anormal aktivite örnekleri (LECM-2 + OCSVM)	54
Şekil 4.12 UMN veri kümesinde sahne-3'te tespit edilen anormal aktivite örnekleri (LECM-2 + OCSVM)	55
Şekil 4.13 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (MHOF + OCSVM).....	55

SİMGELER VE KISALTMALAR

Kısaltmalar

AUC	Area Under the Curve
EER	Equal Error Rate
GMM	Gaussian Mixture Model
KLT	Kanade–Lucas–Tomasi
LDA	Latent Dirichlet Allocation
MDT	Mixture of Dynamic Textures
MRF	Markov Random Field
PCA	Principal Component Analysis
PDF	Probability Density Function
ROC	Receiver Operating Characteristic
SVDD	Support Vector Data Description
SVM	Support Vector Machines
HMM	Hidden Markov Model
UMN	University of Minnesota
STCOG	Spatial-Temporal Co-Occurrence Gaussian Mixture Models
TPR	True Positive Rate
FPR	False Positive Rate

ÇİZELGELER

Sayfa

Çizelge 4.1 UMN veri kümesi etiketleri.....	46
Çizelge 4.2 Anormal olayların ilk görülmeye başlandığı zamanın dikkate alınmasıyla yeniden oluşturulan veri kümesi etiketleri.....	47
Çizelge 4.3 Önerilen yöntemlerin mevcut yöntemlerle ROC eğrileri altında kalan alanlara göre karşılaştırılması (LECM + OCSVM)	58

1 GİRİŞ

Anormal davranış analizi son yıllarda popülerlik kazanan bir araştırma konusu haline geldi. Artan güvenlik kaygısı nedeniyle, güvenlik kameralarının havaalanları, metro istasyonları, alışveriş merkezleri, hastaneler gibi birçok alanda kullanımı sonucu elde edilen büyük miktarda görüntünün incelenmesi sırasında uzun süre ve yoğun çaba harcanması, otomatik gözetim sistemlerini ihtiyaç haline getirmiştir.

Otomatik gözetim sistemlerinde anormal durum tespiti, zorlu problemleri bünyesinde barındırmaktadır. Anomali tanımının belirsiz ve içeriğe göre değişen bir yapıya sahip olması, belirli bir sahne için anormal kabul edilen durumların bir başka sahnede normal olarak ele alınabilmesi, eğitim sırasında anormal durumlara ait örneklerin yeterince olmaması, güvenilir model oluşturulmasını zorlaştırarak anormal olay tespitini güçleştirmektedir. Normal ve anormal durumlar arasındaki sınır belirsizliği ve anormal durumlara ait eğitim örneklerinin elde edilmesinde yaşanan güçlükler nedeniyle; sahnede görülmesi beklenen durumların modellenmesi ve modele uymayan, farklılık gösteren durumların anormal olarak kabul edilmesi, anomali tespitinde genel yaklaşım olarak kabul görmüştür.

Anormal olaylar, sahnede global veya lokal (yerel) olarak gözlemlenebilir [1]:

- 1- Global Anomali : Çeşitli nedenlerle (yangın, patlama) sahne genelinde meydana gelen ani değişiklikler olarak tanımlanır.
- 2- Lokal Anomali : Bireysel davranışların çevresine göre farklılık gösterdiği (kalabalık içerisine aniden giren taşıt, bisikletli gibi) durumlardır.

Kalabalık ve kalabalık olmayan sahnelerde anomali tespiti için çeşitli yaklaşımlar önerilmiştir. Bu çalışmalar bireysel, tümsel ve hibrit yöntemler olmak üzere üç ana başlık altında toplanabilir. Bireysel yaklaşımlar [2] [3], nesnelere tespit ve takibine dayalıdır. Bu nedenle fazla hareket içermeyen, basit sahneler için uygundur. Kalabalık ortamlarda analiz edilmesi gereken çok fazla bileşen bulunmasına bağlı olarak hesaplama maliyetinin artması, kapanma ve gürültü problemleri nedeniyle öznitelik çıkarımının yeterince yapılamaması, bu sahnelerde bireysel yöntemlerin performansını önemli ölçüde düşürmektedir.

Tümsel yaklaşımlar [4] [5], sahneyi oluşturan nesnelere ayrı ayrı incelemek yerine bir bütün halinde ele alır. Bu sayede kalabalık sahnelerde bireysel yaklaşımlara göre daha başarılıdır.

Hibrit yaklaşımlar [6] [7] ise bireysel ve tümsel olmak üzere her iki yöntemden de yararlanır.

Yapılan çalışmalar incelendiğinde, anomali tespitinde sahne hareketini temsil eden optik akış özniteliğinden oldukça sık yararlanıldığı görülmektedir. Bu sayede hareket yönünde ve hızında meydana gelen düzensizliklerin tespiti mümkün kılınmıştır. Fakat tek başına bu özneliğin kullanımı, sadece hareket kaynaklı anormal durumların belirlenmesini sağlarken, görünümünden kaynaklı anomalilerin göz ardı edilmesine neden olmaktadır. Örneğin, insan kalabalığı içerisine aniden giren ve yayalar ile benzer hızda hareket eden taşıtın sadece hareket özneliği kullanılarak tespit edilmesi mümkün değildir. Bu tarz durumlarda görünüm bilgisinin de hesaba katılması, sistem tarafından belirlenen anormal durum çeşidini arttırarak, anomali tespitinin doğru ve güvenilir bir şekilde yapılmasını sağlar.

Bilindiği üzere nesne tanıma veya takibi gibi uygulamalarda, sahne temsili için seçilen özniteliklerin birleştirilerek kullanılmasıyla iyi sonuçlar elde edilmektedir. Benzer yaklaşımın anormal durum tespitinde takip edilmesi, problemin değişken doğası nedeniyle önemlidir.

Bu çalışma kapsamında hem geleneksel yaklaşımlara benzer şekilde optik akış tabanlı öznitelikler, hem de birbirini tamamlayıcı yapıda olan görünüm ve hareket öznitelikleri birlikte anomali tespitinde kullanılmıştır. Optik akış tabanlı öznitelikler olarak, MHOF ve kinematik öznitelikler ile oluşturulan kovaryans matrisleri kullanılmıştır. Görünüm ve hareket kaynaklı anormal durumların tespit edilmesi amacıyla, birbirini tamamlayıcı yapıda olan gradyan ve optik akış tabanlı öznitelikler kovaryans matrisi yardımı ile birleştirilerek kullanılmıştır. Görüntülerden çıkarılan gradyan öznitelikleri, sahne görünümünü temsil ederken, optik akış tabanlı öznitelikler hareket hakkında bilgi sağlamaktadır.

Modelleme işlemi, sadece normal olaylardan elde edilen MHOF ve kovaryans özniteliklerinin, tek sınıf sınıflandırma yöntemlerinden OCSVM (One Class Support Vector Machine) ve SVDD (Support Vector Data Description) ile kullanılmasıyla yapılmıştır. Sonrasında oluşturulan modele uymayan durumlar, anormal olarak işaretlenip sistemin uyarı vermesi sağlanmıştır. Önerilen yaklaşım, nesne tespit ve takibine dayalı olmadığı için kalabalık sahnelerde kullanıma uygun yapıdadır.

1.1 Motivasyon ve Özgün Değer

Bu tez kapsamında, kalabalık sahnelerde anormal durum tespiti yapılmıştır. Nesne tabanlı yaklaşımlarda olduğu gibi, her bir nesneyi izlemek yerine, kalabalık bir bütün halinde ele alınmıştır. Bu sayede, zorlu sahneler olarak kabul edilen kalabalık ortamlarda ortaya çıkan gürültü ve kapanma gibi problemlerin sistem performansını olumsuz etkilemesi

engellenmiştir. Davranış analizi, önce görünüm ve hareket bilgisinin birlikte kullanılmasıyla daha sonra sadece hareket bilgisinden yararlanılarak iki farklı şekilde yapılmıştır.

Kalabalık davranışını uygun şekilde ifade etmek amacıyla geleneksel yaklaşımlardan farklı olarak, hareket ve görünüm öznitelikleri kovaryans matrisi yardımıyla birleştirilerek kullanılmıştır. Karmaşık öznitelikler yerine, birbirini tamamlayıcı yapıda olan bu iki özneliğin beraber kullanımı, hesaplama maliyetini düşürerek efektif bir temsil elde edilmesini sağlamıştır.

Problemin doğası göz önünde bulundurularak (anormal olaylara ilişkin örneklerin elde edilmesinde yaşanan problemler), model öğrenme işleminde sadece normal olaylara ait öznitelikler kullanılmıştır. Sınıflandırma işlemi, basit ve etkili tek sınıf sınıflandırma yöntemlerinden OCSVM ve SVDD kullanılarak yapılmıştır.

1.2 Tez Düzeni

Tezin ana hatları aşağıda belirtilen şekildedir:

İkinci bölümde, anormal olay tespiti üzerine literatür incelenmektedir. Bu amaçla, hareket temsili, kalabalık davranış analizinde kullanılan yaklaşımlar, sınıflandırma yöntemleri ve özellikleri ele alınmıştır.

Üçüncü bölümde, önerilen yaklaşım öncelikle genel hatlarıyla açıklanmış ve görsellerle desteklenmiştir. Bu bölümde, kullanılan öznitelikler ve sınıflandırma yöntemleri üzerine detaylı açıklama yapılmıştır.

Dördüncü bölümde ilk olarak, bu çalışmada kullanılan ve sahne geneli anormal davranışların gözlemlendiği veri kümesi hakkında bilgi verilmiştir. Daha sonra, önerilen yaklaşımlar ile elde edilen deneysel sonuçlara ve diğer çalışmalarla yapılan karşılaştırmalara yer verilmektedir.

Beşinci ve son bölümde ise önerilen yaklaşımın getirdiği yenilikler, zayıf yönleri ve gelecekte yapılması planlanan çalışmalardan bahsedilmiştir.

2 LİTERATÜR ÖZETİ

Kalabalık davranış analizi için çeşitli alanlarda birçok yaklaşım önerilmiştir. Bu yaklaşımlar farklı başlıklar altında incelenebilir.

Bu bölümde literatür dört ana başlıkta incelenecektir:

- Kalabalık sahnelerde hareket temsili
- Kalabalık davranış analizi
- Anomali tespitinde kullanılan sınıflandırma yöntemleri
- Anomali tespiti

2.1 Kalabalık Sahnelerde Hareket Temsili

Hareket bilgisinin tasviri, kalabalık sahne analizinin temelini oluşturmaktır. Kalabalık sahnelerin analizinde ilk aşama, sahnenin uygun öznitelikler yardımıyla temsil edilmesidir. Öznitelikler, sahne yapısını farklı şekilde tanımlamaya imkan veren ve uygulama performansını önemli derecede etkileyen faktör olması nedeniyle büyük önem taşımaktadır.

Temsil düzeyine göre öznitelikler [8], akış temelli öznitelikler, yerel uzaysal-zamansal öznitelikler ve yörüngeler (trajectory) olarak üç grupta toplanır.

2.1.1 Akış Temelli Öznitelikler


Sahne bağlamı ve kalabalık dinamiklerinin geniş yelpazede değişkenlik gösterdiği kalabalık sahnelerde amaç, davranış değişikliklerini anlamının iyi yollarını bulmaktır. Belirtilen problemlerin üstesinden gelmek amacıyla, optik akış tabanlı yöntemler önerilmiştir. Bu grupta yer alan öznitelikler optik akış, parçacık akışı (particle flow) ve çizgi akışı (streak flow) şeklinde sıralanmaktadır.

Optik akış, ardışık görüntüler arasında piksel seviyesinde, parlaklık değişmezlik ilkesi kullanılarak hesaplanır ve bilgisayarlı görü alanında pek çok uygulamada [9] [5] kullanımı mevcuttur. Optik akışın ardışık iki görüntü kullanılarak hesaplanması, bu özneliğin, birçok uygulamada kullanılan uzun menzilli zamansal bağımlılık bilgisinden yoksun olmasına neden olmaktadır [4].

Parçacık akışı (particle flow) [10] [11] kavramı ise sıvı dinamiğinin Lagrangian modeline dayalı olarak önerilmiştir. Parçacık akışı, gridler (ızgara modeli) üzerine konumlandırılmış parçacıkların optik akışa göre hareket ettirilmesiyle hesaplanır. Bu sayede bir parçacığın başlangıç konumunu bir sonraki konumuyla ilişkilendiren yörüngeler elde edilmiş olur.

Parçacık akışında, uzaysal değişimlerin göz ardı edilme ihtimali ve büyük gecikme yaşanması nedeniyle alternatif olarak çizgi akışı önerilmiştir [4]. Bu yöntem, çözümünde optik akış kullanılan birçok probleme uygulanabilir olma özelliğine sahiptir.

Çizgi akışı (streak flow) [4], parçacık akışına benzer şekilde sahnede grid üzerine konumlandırılmış parçacıkların optik akışa göre hareket ettirilmesiyle hesaplanır ve optik akış, parçacık akışı (particle flow) gibi yaygın olarak kullanılan akış tasvirlerinden daha bilgilendirici olabilir. Şekil 2.1’de optik akış, parçacık akışı (particle flow) ve çizgi akışı (streak flow) gösterilmektedir.



Şekil 2.1 (a) Optik akışın görselleştirilmesi: Döner küre, ortada gösterilen optik akış alanını üretir. (b) (c) (d) Sırasıyla optik akış, parçacık akışı ve çizgi akışındaki $t = 0$ ile $t=18$ zaman periyodundaki öznitelik vektörlerinin değişiminin karşılaştırılması. ([4] ve [8]’den alınmıştır.)

2.1.2 Yerel Uzaysal-Zamansal Öznitelikler

Bu gruptaki öznitelikler, hareketi bir bütün olarak ele alır ve yerel-zamanlı dağılımlarını yerel 2 boyutlu bloklara veya 3 boyutlu küplere göre karakterize eder. Bu özniteliklere uzaysal-zamansal gradyan [12] [13] [14] ve histogram fonksiyonları [15] örnek olarak verilebilir. Uzaysal-zamansal gradyan ∇I_i , bloklardaki her bir piksel i için, aşağıdaki şekilde hesaplanır:

$$\nabla I_i = \llbracket I_{i,x} \quad I_{i,y} \quad I_{i,t} \rrbracket^T = \llbracket \frac{\partial I}{\partial x} \quad \frac{\partial I}{\partial y} \quad \frac{\partial I}{\partial t} \rrbracket^T \quad (2.1)$$

Yukarıdaki formülde x, y ve t videoda sırasıyla yatay, dikey ve zamansal boyutları temsil etmektedir. Uzaysal-zamansal gradyan x, y ve t eksenleri boyunca birinci dereceden türev alınarak hesaplanır.

Hareket histogramları uzaysal-zamansal gradyana benzer şekilde, bölümlenmiş alanlar üzerinde tanımlanan hareket bilgisi türüdür. Bu histogramların hata eğilimli yapısı nedeniyle, temeli hareket histogramlarına dayanan daha gelişmiş özellikler önerilmiştir [15] [16]. Cong ve diğerleri [15], hareket bilgisine ek olarak, aynı zamanda mekansal bağlamsal bilgileri de muhafaza eden çok parçalı optik akış histogram (multi-scale histogram of optical flow - MHOF) özniteliğini önermiştir. Çalışmada [15], hareket alanı optik akış ile belirlendikten sonra, 2 boyutlu bloklara veya 3 boyutlu küplere bölünen görüntünün her biriminden çok parçalı (ölçekli) optik akış histogramları elde edilmiştir.

2.1.3 Yörünge Öznitelikleri

Tipik kalabalık hareketi genellikle düzenli ve tekrarlayıcıdır. Bu nedenle kalabalık aktiviteleri, nesnelere yörüngelerinden çıkarılan hareket özelliklerine (nesnelere arasındaki ivme veya hareket enerjisi gibi) dayalı olarak analiz edebilir [8].

2.2 Kalabalık Davranış Analizi

Kalabalık davranış analizi için önerilen çalışmalar, bireysel (nesne tabanlı) yaklaşımlar, bütüncül (tümsel) yaklaşımlar ve hibrit yaklaşımlar olmak üzere üç kategoride incelenir.

2.2.1 Bireysel Yaklaşımlar

Geleneksel yaklaşım olarak kabul edilen bireysel yaklaşımlarda, topluluk davranışlarının modellenmesi için her bir hareketlinin ayrıştırılması ve izlenmesi gerekmektedir.

Kalabalık davranış anlayışında nesne tabanlı bireysel yaklaşımlar, üst düzey olayların saptanmasına izin vermeleri nedeniyle tercih edilirler. Bir başka ifadeyle, farklı senaryolarda

bir bireyin uygunsuz eylemleri nedeniyle ortaya çıkan anormal olayların tespit edilmesinde kullanılırlar. Bu senaryolara, belirli bir yönde kalabalığa karşı hareket eden tek bir kişinin tanımlanması, maç bittikten sonra spor sahasına girmeye çalışan bir kişi gibi potansiyel tehlikeli olay olma ihtimali yüksek olan durumlar örnek verilebilir. Yine benzer şekilde hırsızlık olaylarında, genelde kurbanına arkadan yaklaşan hırsızın algılanması gibi durumlarda nesne tabanlı bireysel yaklaşımlardan yararlanılır. Fakat nesne tespit ve takibinin, kalabalık ortamların değişken yapısı nedeniyle yeterince yapılamaması, bu yöntemlerin kalabalık sahnelere uygulanabilirliğini bir hayli zorlaştırmaktadır. Bu nedenle, bireysel yaklaşımların düşük veya orta derecede kalabalık içeren sahnelerde kullanımı uygundur.

2.2.2 Bütüncül Yaklaşımlar

Bütüncül yaklaşımlar, bireysel yaklaşımların aksine kalabalığı bir bütün halinde ele alır. Bu sayede kapanma ve gürültü gibi zorlu problemleri içeren kalabalık sahnelerde iyi performans gösterirler. Bütüncül yaklaşımlar genellikle ana kalabalık akışı gibi daha genel düzeydeki bilgileri elde etmeye çalışır ve yerel bilgileri göz ardı etmeye eğilimli olurlar. Bireysel farklılığı göz ardı etme ve kalabalığın içindeki herkesin benzer hareket özelliklerine sahip olduğunu düşünme özelliği bu yaklaşımların, belirli bir yönde kalabalığa karşı hareket eden tek bir kişinin tanımlanması, maç bittikten sonra spor alanına girmeye çalışan bir kişi gibi bireysel farklılıkların önemli olduğu senaryolarda kullanımını uygunsuz hale getirmektedir.

2.2.3 Hibrit Yaklaşımlar

Hibrit yaklaşımlar, hem bütüncül hem de nesne tabanlı bireysel tekniklerden yararlanır [17]. Örnek olarak, Krausz ve Bauckhage [6] [7], kalabalık bir sahnede global hareketi temsil etmek amacıyla optik akış histogramından faydalanmıştır. Ardından istatistiksel yöntemler ile davranışlar modellenmiştir. Tehlikeli kalabalık davranış tespiti ise sezgisel kurallar kullanılarak gerçekleştirilmiştir.

2.3 Anomali Tespitinde Kullanılan Sınıflandırma Yöntemleri

Anomali tespitinde kullanılan sınıflandırma yöntemleri, eğitim sırasında anormal ve normal olaylara ait örnek kullanma durumuna göre üç ana gruba ayrılır:

1. Denetimli (Supervised) yaklaşımlar
2. Yarı denetimli (Semi-Supervised) yaklaşımlar
3. Denetimsiz (Unsupervised) yaklaşımlar

2.3.1 Denetimli Yaklaşımlar

Bu grupta bulunan yaklaşımlar, eğitim sırasında normal ve anormal durumlara ait etiketlenmiş veri kullanır ve özellikleri önceden belirlenmiş trafik ihlali tespiti veya düşme [18] tespiti gibi uygulamalarda kullanılır.

2.3.2 Yarı Denetimli Yaklaşımlar

Yarı denetimli yaklaşımlar, eğitim sırasında sadece normal sınıfa ait örneğe ihtiyaç duyar. Bu yaklaşımlarda kendi içinde kural temelli yaklaşımlar ve model tabanlı yaklaşımlar olarak iki gruba ayrılır.

Kural temelli yöntemlerde [14] [1], normal veriler kullanılarak kural oluşturulur ve anomali tespiti, oluşturulan kurala uymayan durumların belirlenmesiyle gerçekleştirilir.

Model tabanlı yaklaşımlar [13], normal olaylar için bir model oluşturmaya çalışır. Belirlenen modele göre düşük olasılık değerine sahip olan örnekler anormal olarak kabul edilir. Örnek olarak Kratz ve Nishino [12], yerel uzaysal-zamansal alanlardan elde edilen gradyan özniteliklerini HMM (Hidden Markov Model) ile kullanarak normal olayları modellemiş, ardından düşük olasılık değerine sahip olayları anormal olarak işaretlemiştir.

2.3.3 Denetimsiz Yaklaşımlar

Bilindiği üzere anormal olayların normal olaylara nazaran meydana gelme olasılığı oldukça düşüktür. Denetimsiz yaklaşımlar, bu özelliği dikkate olarak, eğitim sırasında normal ve anormal olaylara ait veriye ihtiyaç duymadan, olayların olasılık değerleri yardımıyla anomali tespiti yapmaktadır.


2.4 Anomali Tespiti

Anormallik tespiti, son yıllarda kalabalık sahne analizinde yoğun ilgi toplayan bir alan haline gelmiştir. Anormallik tespiti, beklenen davranışa uymayan durumları bulma problemi olarak tanımlanmaktadır ve farklı uygulama alanlarında araştırılan önemli bir konudur. Bu konu, kalabalık sahnelerde çok sayıda kişinin faaliyetlerinin izlenmesi ve sahneye ilişkin yapısal bilgilerin korunması gibi problemleri beraberinde getirmektedir.

Önceki çalışmalar, ilgi düzeyine göre global veya lokal (yerel) anomali tespiti gerçekleştirmektedir [1] [15]. Global anomali yangın, patlama gibi nedenlerle sahnenin genelinde meydana gelen anormal grup davranışlarıdır. Global anomali tespitinde, sahnedeki anomaliyi tespit etmenin yanı sıra, olayların başlangıç ve bitişi arasındaki geçişlerin doğru bir şekilde yapılması da büyük önem taşımaktadır.

Lokal (yerel) anomali, bireysel davranışların çevresine göre farklılık gösterdiği durumları ifade etmektedir. İnsan kalabalığı içerisinde aniden giren taşıt veya metro çıkışına doğru ilerleyen kalabalığa, ters yöne hareket eden hareketli, lokal anormal olay örneklerindedir.

Şekil 2.2’de lokal ve global olarak gözlemlenen anormal olayların yapısı gösterilmiştir.



Şekil 2.2 Lokal ve global anormal olay gösterimi: Her bir elips hareketli bir yayayı temsil eder. (a) Lokal anormal olay : Kırmızı yayanın davranışı komşularından farklılık göstermektedir. (b) Global anormal olay : Sahne genelinde gözlemlenen anormal grup davranışı. ([15]’ten alınmıştır.)

Cong ve diğerleri [1], üç farklı şekilde elde edilen MHOF özneliğini global ve lokal anormal olay tespitinde kullanmıştır. MHOF, iki farklı optik akış histogramının belirli bir eşik değerine göre birleştirilmesiyle oluşturulmaktadır ve standart optik akış histogramına göre daha ayrıntılı şekilde hareketi temsil etmektedir.

Mehran ve diğerleri [19], sosyal güç modelini, kalabalık sahnelerde anormal davranışların saptanması ve lokalize edilmesinde kullanmıştır. Sosyal güç modeli, temeli Newton prensiplerine dayanan matematiksel hareket modelleme yöntemidir. Burada parçacık adveksiyon yöntemi ile optik akış çıkarımı yapıldıktan sonra hesaplanan sosyal kuvvet, LDA (Latent Dirichlet Allocation) ile birlikte anomali tespitinde kullanılmıştır.

Marsden ve diğerleri [20] video temsilinde, kalabalık birliktelik, çatışma, ortalama hareket hızı ve kalabalık yoğunluğunu ifade eden bütünsel özneliklerden yararlanmışlardır. Anomali tespiti, sadece normal olaylara ait örneklerin bulunduğu durumlarda GMM (Gaussian

Mixture Model) kullanılarak yapılmıştır. Normal ve anormal durumlara ait örneklerin birlikte kullanıldığı durumlarda ise iki sınıflı SVM tercih edilmiştir.

Kalabalık birliktelik (crowd collectiveness) özneliği, Zhou ve diğerleri [21] tarafından önerilmiştir ve bir sahnedeki bireylerin birlikte hareket etme derecesi olarak tanımlanır.

Grup içi ve gruplar arası özellikleri ifade etmede kullanılan çatışma (conflict), stabilite (stability), homojenlik (uniformity) gibi öznelikler ise Shao ve diğerleri [22] [23] tarafından literatüre kazandırılmıştır. Shao ve diğerleri [22] [23], önerilen yaygın modellerden oldukça farklı olarak kalabalığı gruplar halinde incelemiştir. Grup içi ve gruplar arası özellikler, birliktelik (collectiveness) [21], stabilite (stability), çatışma (conflict) ve homojenlik (uniformity) olmak üzere dört öznelik kullanılarak ifade edilmiştir. Stabilite özneliği, bir grubun zaman içinde iç topolojik yapıyı koruyup koruyamayacağını gösterirken, çatışma (conflict) gruplar birbirlerine yaklaştığında, gruplar arasındaki etkileşimi / sürtüşmeyi karakterize eder. Homojenlik (uniformity) ise mekansal dağılım açısından bir grubun homojenliğini tanımlar.

Lee ve diğerleri [24], hareket etki matrisiyle global ve yerel (lokal) anormal davranış tespiti yapmaktadır. Burada normal davranışlar düşük hareket etki değerine sahipken, yüksek hareket etki değeri, anormal davranışın ortaya çıktığına işaret etmektedir.

Shi ve diğerleri [25], faz korelasyonu (phase correlation) ile birbiri ardına gelen iki görüntü arasında hareket vektörlerini hesaplamıştır. Bu çalışmada normal olaylar STCOG (spatial-temporal co-occurrence Gaussian mixture models) kullanılarak modellenmiş ve modele uymayan durumlar anormal olarak işaretlenmiştir.

Pennisi ve diğerleri [26], görüntü bölümlenmesine (segmentation) dayanan ve eğitim aşamasına ihtiyaç duymadan gerçek zamanlı çalışan bir yöntem önermiştir. Anomali tespiti, entropi ve TOV (Temporal Occupancy Variation) kullanılarak yapılmıştır.

Mahadevan ve diğerleri [27] [28], sahne görünümü ve dinamiğini kodlayan MDT (Mixture of Dynamic Texture) özneliğini anomali tespitinde kullanmıştır. Sahne dinamiğine ek olarak görünümün temsil edilmesi sayesinde yöntem hareket ve nesne görünümünden kaynaklı anormal durumların tespitini yapabilmektedir. MDT hareket temsilini iyi yapan fakat hesaplanması uzun zaman alan bir özneliktir.

Colque ve diğerleri [29], optik akışın yön ve büyüklük bilgisi ile oluşturulan HOFM (histogram of optical flow orientation and magnitude) özneliğini anomali tespitinde

kullanmıştır. İncelenen durumun anormal olup olmadığına en yakın komşuluğuna bakılarak karar verilmiş. Hız büyüklüğü ve yön bilgisinin elde edilme süreci kompleks işlemler gerektirmediğinden bu çalışma gerçek zamanlı sistemlerde kullanılmaya uygundur. Fakat çalışmanın doku bilgisinden yoksun oluşu tespit edilen anomali çeşidini sınırlamaktadır.

Reddy ve diğerleri [30], sadece hareket bilgisine dayanarak yapılan modellemenin nesnenin boyutu ve görünümünde meydana gelen anomaliyi algılamada yetersiz kaldığı görüşünü savunarak çalışmalarında optik akış bilgisine ek olarak, nesnenin boyut ve doku bilgisini kullanmıştır. Etkin hesaplama sağlamak amacıyla öznitelikler ayrı ayrı modellenmiştir. Sınıflandırma işlemi en fazla iki sınıflandırıcı kullanılarak yapılmıştır. İlk aşamada hız bilgisi kontrol edilmiş, anomali tespit edilmediyse ikinci aşamaya geçilerek boyut ve doku bilgisi birlikte ele alınarak sınıflandırma yapılmıştır.

Ryan ve diğerleri [31], benzer görüş ile yola çıkarak, anormal olaylar ve nesnelere tespit etmek amacıyla, optik akış ve hareket alanının homojenliğini yansıtan doku özniteliklerini GMM (Gaussian Mixture Model) ile kullanmıştır.

Zang ve diğerleri [13], anormal durum tespitini görünüm ve hareket kaynaklı olmak üzere iki kısımda ele almıştır. Olağandışı nesnelere, beklenmedik görünüm, garip pozisyonlar, tanımlanamayan nesne gibi görünüm kaynaklı anormal durumlar için zamansal-uzaysal gradyan özneliği SVDD sınıflandırıcısı ile kullanılmıştır. Hareket kaynaklı anomali tespiti için, istatistiksel histogramlardan yararlanılmıştır. Son kısımda ise görünüm ve hareket kaynaklı anormal durum tespitinden elde edilen sonuçlar birleştirilerek sistemin uyarı vermesi sağlanmıştır.

Wang ve diğerleri [32], anormal durum tespitini, hareket ve görünüm kaynaklı olarak ele alan bir yaklaşım önermiştir. Hareket kaynaklı anormal durumların tespiti için, mekansal olarak lokalize edilmiş optik akış histogram öznitelikleri, bölümlere ayrılmış görüntülerden elde edilerek tek sınıf Destek Vektör Makineleri ile kullanılmıştır. Çalışmada, sistem performansını arttırmak amacıyla anormal ön plan dokusunu ayırt eden, ön plan sınıflandırma yönteminden yararlanılmıştır.

Zhu ve diğerleri [33], birbirini tamamlayıcı yapıda olan görünüm ve hareket özniteliklerini kullanmıştır. Hareket temsili için, optik akış dinamiği hakkında bilgi sağlayan yüksek frekanslı optik akış özneliği (HFOF) ve hareket yönünü gösteren çok parçalı optik akış histogramı (MHOF) kullanılmıştır. Görünüm bilgisi için dinamik dokular (dynamic textures -DT) özneliği seçilmiştir. Anomali tespiti, belirtilen özniteliklerin çoklu çekirdek

öğrenimine (multiple kernel learning - MKL) dayalı sınıflandırıcı ile kullanılmasıyla yapılmıştır.

Mousavi ve diğerleri [17], özellik dedektörü ile belirlenen noktaların takip edilmesiyle elde edilen HOT (histogram of oriented tracklets) özneliğini, öğrenme sırasında anormal durumların kullanılması halinde destek vektör makineleri (SVM) ile sadece normal örneklerin mevcut olduğu durumlarda ise LDA ile kullanılarak anomali tespiti yapmıştır. Bu çalışmada kullanılan HOT özneliği, kalabalık hareketini, hareket büyüklüğü ve yönü kullanılarak oluşturulan iki boyutlu histogram ile ifade etmektedir.

Karmaşık sahnelerde meydana gelen olağandışı olayların belirlenmesi işlemi, yüksek boyutlu özneliklerin kullanılmasına neden olmaktadır [34]. Bu öznelikler ile öğrenim yapılması oldukça zordur ve öğrenilen modelin doğru tahminde bulunma gücünün azalması gibi sorunlara yol açmaktadır. Bu tarz problemlerle başa çıkmak amacıyla seyrek (sparse) yöntemler önerilmiştir. Seyrek temsil, temelde seyrek kodlar eşliğinde sözlük öğrenimi yapılmasıdır. Seyrek yöntemlerin anomali tespitinde kullanılması sırasında izlenen yol; öncelikle veriden öznelik çıkarımı yapılması ve bu öznelikler yardımıyla sözlük oluşturulması şeklindedir. Sonrasında gelen sinyaller sözlükteki az sayıda atomun lineer kombinasyonu şeklinde ifade edilir. Anomali tespiti, anormal ve normal durumlardan oluşan test verilerinin yeniden yapılandırma hatasına bakılarak yapılır.

Cong ve diğerleri [1] [15], normal olaylardan elde edilen yüksek ölçekli optik akış histogram (MHOF) özneliği ile sözlük öğrenimi yapmıştır. Anomali tespiti, test örneğinin sözlük üzerinde hesaplanan maliyetine göre gerçekleştirilmiştir. Normal olaylar için bu maliyet düşük olurken anormal olaylarda yüksek değerler elde edilmesine neden olur.

Huo ve diğerleri [35], benzer şekilde MHOF özneliğinden yararlanmıştır. Fakat Cong ve diğerlerinden [1] [15] farklı olarak burada öznelik çıkarımı yalnızca hareketli pikseller üzerinden yapılmaktadır. Anomali tespiti, çok örnekli sözlük öğrenimi (multi-instance dictionary learning) kullanılarak gerçekleştirilmiştir.

Xu ve diğerleri [36], normal olaylardan çıkardığı dinamik doku öznelikleri yardımıyla öğrenim yaptıktan sonra, seyrek öğrenim katsayısı ve yeniden yapılandırma hatasına bakarak anomali tespiti yapmaktadır.

Lu ve diğerleri [14], görüntüleri örtüşmeyen eşit parçalara bölerek, ard arda gelen beş görüntü içinde karşılık gelen bölgeleri, zamansal-uzaysal küp oluşturacak şekilde birbirine istiflemiştir. Elde edilen 3 boyutlu gradyan öznelikleri üzerinden sözlük öğrenimi

yapılmıştır. Tespit aşamasında ise en küçük karesel hata metodundan yararlanılarak anormal olaylar belirlenmiştir.

Zhu ve diğerleri [37], hareket ve görünüm bilgisini kural tabanlı yaklaşım ile anomali tespitinde kullanmıştır. Çalışmada kullanılan 3 boyutlu optik akış histogramları (3D-HOF), optik akış haritasından hız ve hareket yönü gibi bilgilerin elde edilmesini sağlayarak hareket hakkında bilgi vermektedir. Görünüm bilgisi temsilinde ise gradyan özniteliği tercih edilmiştir. Belirtilen öznitelikler hızlı seyrek sınıflama yöntemiyle anomali tespitinde kullanılmıştır.

Del Giorno ve diğerleri [38], eğitim verisine ihtiyaç duymadan gözetimsiz öğrenme (unsupervised learning) kullanarak, olayların zamansal olarak görünüm sırasından bağımsız bir şekilde anomali tespiti yapmıştır. Klasik yaklaşımlarda olduğu gibi model belirleme işleminden sonra bu yapıya uymayan durumların belirlenmesi yerine videodan elde edilen görüntüler yine video içeriği göz önüne alınarak ayrılabilirlik özelliklerine göre anormal veya normal olarak sınıflandırılmıştır. Video görüntülerinin ayrılabilirlik özelliği, veri akışı üzerinde gerçekleştirilen değişiklik belirleme işlemiyle ortaya çıkartılmıştır.

3 KALABALIK GÖZETLEME ORTAMLARINDA ANOMALİ TESPİTİ

3.1 Logaritmik Öklid Kovaryans Matrisleri (Log-Euclidean Covariance Matrices - LECM)

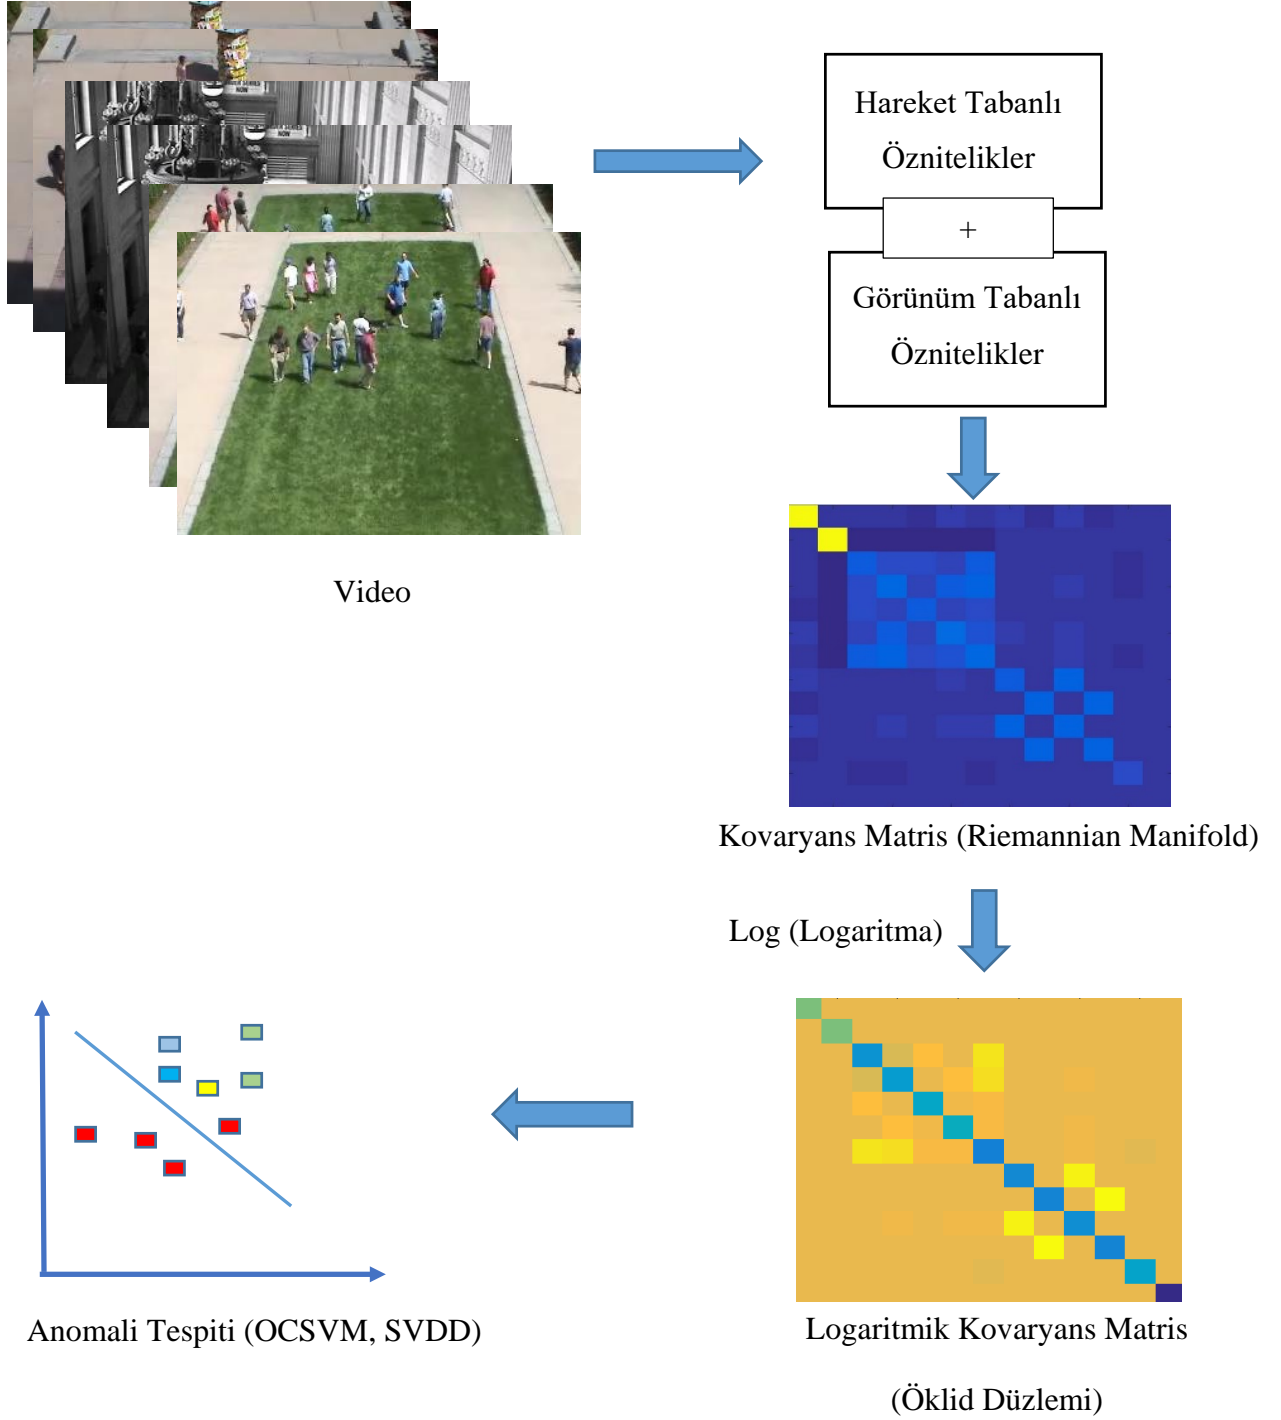
3.1.1 Giriş

Bu çalışma kapsamında, kalabalık ortamlarda sahne genelinde gözlemlenen anormal durumların tespit edilmesi amaçlanmaktadır.

Önerilen yaklaşım aşağıdaki adımlardan oluşmaktadır:

1. Horn-Schunck [39] yöntemi ile video üzerinde optik akış hesabı yapılması,
2. Optik akışın yatay ve düşey bileşenleri, bu bileşenlerin zamana göre birinci dereceden türevleri, literatürde kinematik öznitelikler olarak adlandırılan; vortisite (vorticity), iraksama (divergence) ve gradyan tensör (gradient tensor) özniteliklerinin hesaplanması,
3. Sahne görünümünü kodlayan birinci, ikinci derece gradyanlar ve gradyan büyüklüğünün hesaplanması,
4. Elde edilen özniteliklerin kovaryans matrisi yardımıyla birleştirilmesi,
5. Riemannian manifoldunda bulunan kovaryans matrislerinin, logaritmik kovaryans matrislerine dönüştürülerek, Öklid düzleminde kullanıma uygun hale getirilmesi,
6. Sınıflandırmanın ilk aşaması olan model oluşturma işleminin, sadece normal olaylardan elde edilen öznitelikler ve tek sınıf sınıflandırıcılar (OCSVM, SVDD) kullanılarak yapılması,
7. Anomali tespitinin, oluşturulan modele uymayan durumların belirlenerek, uyarı verilmesi şeklinde gerçekleştirilmesi.

Önerilen yaklaşıma ait algoritma Şekil 3.1'de verilmiştir.



Şekil 3.1 Önerilen anormal durum tespiti algoritmasına genel bakış : Hareket ve görünüm bilgisi kullanılarak oluşturulan kovaryans matrisi logaritmik kovaryans matrisine dönüştürülerek Öklid düzlemine eşlenir. Anomali tespiti tek sınıf sınıflandırma yöntemleri kullanılarak gerçekleştirilir.

3.1.2 Optik Akış Hesabı

Optik akış, hareket hakkında bilgi sağlayan ve bilgisayarlı görüde yaygın kullanım alanına sahip bir kavramdır. Kullanım alanlarına örnek olarak;

- Hareket tanıma
- Harekete dayalı bölümlleme
- Özel efektler oluşturma
- 3 boyutlu yeniden şekil yapılandırma

verilebilir.

Kalabalık sahnelerde hızdan kaynaklı anormal durumları belirlemek amacıyla Horn-Schunck (HS) [39] yöntemi kullanılarak optik akış hesabı yapılmıştır.

Horn-Schunck yönteminde optik akış, parlaklık değişmezlik varsayımından yola çıkılarak hesaplanır. Bu varsayıma göre; t anında elde edilen görüntünün x, y koordinatlarında bulunan noktanın parlaklık değeri $f(x, y, t)$ ile çok kısa bir süre sonra ($t + dt$) anında elde edilen görüntüde, yaklaşık olarak aynı koordinatlarda bulunan noktanın parlaklık değeri $f(x + dx, y + dy, t + dt)$ birbirine eşittir:

$$f(x, y, t) = f(x + dx, y + dy, t + dt) \quad (3.1)$$

Yukarıdaki eşitlik Taylor serisi yardımıyla aşağıdaki forma dönüştürülür:

$$f(x, y, t) = f(x, y, t) + \frac{df}{dx} dx + \frac{df}{dy} dy + \frac{df}{dt} dt \quad (3.2)$$

3.2’de verilen eşitlik düzenlenirse 3.4’te formüle edilen optik akış eşitliği elde edilir,

$$f_x dx + f_y dy + f_t dt = 0 \quad (3.3)$$

$$f_x u + f_y v + f_t = 0 \quad (3.4)$$

3.4’te u ve v optik akışın x ve y eksenlerindeki bileşenlerini ifade etmektedir.

3.4’te verilen optik akış eşitliği iki bilinmeyenli bir denklem olduğu için enerji minimizasyon problemine dönüştürülerek çözülür:

$$\iint \{(f_x u + f_y v + f_t)^2 + \lambda(u_x^2 + u_y^2 + v_x^2 + v_y^2)\} dx dy \quad (3.5)$$

Parlaklık sabitliği
(Brightness constancy)

Düzgünlük kısıtası
(Smoothness constraint)

Enerji fonksiyonundaki (3.5) düzgünlük kısıtası, optik akışta meydana gelen değişimin az miktarda ve düzgün bir şekilde olması gerektiğini belirtir. λ bu durumu düzenleyen düzgünleştirme faktörüdür.

Eşitlik 3.5, resimdeki tüm noktalar tarafından sağlanması gereken bir minimizasyon problemini ifade etmektedir ve çözümü aşağıdaki şekildedir:

$$\iint \{(f_x u + f_y v + f_t)^2 + \lambda(u_x^2 + u_y^2 + v_x^2 + v_y^2)\} dx dy \quad (3.5)$$

↓ **MINİMUM**

$$(f_x u + f_y v + f_t)f_x + \lambda(\Delta^2 u) = 0$$

$$(f_x u + f_y v + f_t)f_y + \lambda(\Delta^2 v) = 0 \quad (3.6)$$

↓

$$(f_x u + f_y v + f_t)f_x + \lambda(u - \bar{u}) = 0$$

$$(f_x u + f_y v + f_t)f_y + \lambda(v - \bar{v}) = 0 \quad (3.7)$$

3.6'da Δ Laplace operatörünü, 3.7' de \bar{u} ve \bar{v} ortalama u ve v değerlerini ifade etmektedir.

Horn-Schunck (HS) yöntemi kullanılarak, UMN olağandışı kalabalık etkinliği veri kümesi [40] üzerinde hesaplanan optik akışlar aşağıda belirtilen şekilde verilmiştir:

- Sahne-1 normal ve anormal durumlar sırasında optik akış gösterimi : Şekil 3.2
- Sahne-2 normal ve anormal durumlar sırasında optik akış gösterimi : Şekil 3.3
- Sahne-3 normal ve anormal durumlar sırasında optik akış gösterimi : Şekil 3.4



Şekil 3.2 Sahne-1’de normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.

(a) Görüntü- 1742



(b) Görüntü-1807



(c) Görüntü-2298




(d) Görüntü- 2604



(e) Görüntü- 4606



(f) Görüntü-4806



Şekil 3.3 Sahne-2’de normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.

(a) Görüntü- 5634



(b) Görüntü- 6192



(c) Görüntü- 6000



(d) Görüntü- 6872



(e) Görüntü- 6994



(f) Görüntü- 7693



Şekil 3.4 Sahne-3'te normal ve anormal durumlar sırasında, Horn-Schunck yöntemi ile elde edilen optik akışların gösterimi (a) (c) (e) Normal olaylar sırasında elde edilen optik akışlar (b) (d) (f) Anormal olaylar sırasında elde edilen optik akışlar. Anormal olaylar sırasında elde edilen akış vektörleri, normal olaylar sırasında elde edilenlere göre daha büyük değerlere sahiptir.

3.1.3 Simetrik – Pozitif Belirli Matrisler için Log-Öklid Metriği

Kovaryans matrisi, her bir özellikteki varyansı, farklı özellikler arasındaki kovaryansı kodlayan simetrik ve pozitif belirli bir matristir.

Kovaryans temelli öznitelikler, Tuzel ve diğerleri [41] tarafından nesne tespiti ve doku sınıflandırması amacıyla bilgisayarlı görüye kazandırılmıştır. Sonrasında nesne takibi, yüz tanıma, hareket tanıma gibi pek çok alanda başarılı şekilde uygulanmıştır.

$I(x, y, t)$ bir video dizisi, $F = \{f_k\}_k^n$ çıkarılan öznitelik kümesi ve bu kümenin boyutu n olmak üzere, kovaryans matrisi aşağıdaki şekilde tanımlanır:

$$C_t = \frac{1}{n-1} \sum_{k=1}^n (f_k - \mu)(f_k - \mu)^T \quad (3.8)$$

Burada μ ortalama öznitelik vektörüdür 3.9'daki gibi hesaplanır:

$$\mu = \frac{1}{n} \sum_{k=1}^n f_k \quad (3.9)$$

Kovaryans matris kullanımı birçok avantaja sahiptir:

- Çeşitli öznitelikleri kaynaştırmak için kullanılan basit ve etkili bir yaklaşımdır.
- Düşük boyutlu bir tanımlayıcıdır ve hesaplandığı bölgenin boyutundan bağımsızdır. Boyutu sadece içerisinde kullanılan öznitelik sayısına göre değişiklik göstermektedir.

Yukarıda sıralanan avantajlar kovaryans matris temelli yaklaşımları cazip hale getirmekle birlikte, kovaryans matrislerinin Riemannian manifoldunda bulunması ve Öklid düzleminde gerçekleştirilen işlemler için uygun olmaması önemli bir sorun teşkil etmektedir. Kovaryans matrislerini Öklid operasyonları için uygun hale getirmek amacıyla Arsingny ve diğerleri [42], log-Öklid metriğini önermiştir. Bu metriğe göre, öncelikle kovaryans matrisine tekil değer ayrışımı (Singular Value Decomposition) uygulanarak üç matristen oluşan aşağıdaki yapı elde edilir:

$$C_t = U \Sigma U^T, \quad (3.10)$$

3.10'da verilen U birimdik (orthonormal) matristir, Σ negatif olmayan gerçek sayılardan oluşan kare matristir ve özdeğerleri (eigenvalues) köşegenlerinde barındırır.

İkinci adımda matrisin logaritması alınır. Bu durumda kovaryans matrisin yeni gösterimi,

$$C_t^{log} = \log(C_t) = U \Sigma' U^T, \quad (6.11)$$

şeklinde elde edilir. Formülde Σ' özdeğerleri $(\lambda_1, \lambda_2, \dots, \lambda_d)$ içeren kare diyagonal matrisi ifade etmektedir. Buna göre, Öklid düzlemine aktarılmış olan kovaryans matrisin son hali 3.12'de gösterildiği gibidir:

$$\log(C_t) = U \text{Diag}(\log(\lambda_1), \dots, \log(\lambda_d)) U^T \quad (3.12)$$

Kovaryans matrisin simetrik bir matris olması nedeniyle, $d \times d$ boyutunda bir kovaryans matris üzerinde yarı vektörelleştirme gerçekleştirilerek $\frac{d(d+1)}{2}$ boyutunda öznitelik vektörü elde edilir.

Kalabalık sahnelerde anormal durum tespiti ile ilgili çalışmalar incelendiğinde, optik akış tabanlı özniteliklerden oldukça çok sık yararlanıldığı görülmektedir. Sadece optik akış tabanlı öznitelikler kullanılarak önerilen yaklaşımlar, düzensiz hız, ters yönde hareket gibi anormal durumları tespit edilebilirken, görünümünden kaynaklı anomalilerin belirlenmesinde yetersiz kalmaktadır.

Literatür incelendiğinde hareket tanıma için yaygın olarak gradyan ve optik akış tabanlı özniteliklerin birlikte kullanıldığı görülmektedir. Birbirini tamamlayıcı yapıda olan bu iki öznitelik sırasıyla görünüm, hareket hakkında bilgi vermektedir ve beraber kullanıldığında iyi sonuçlar elde edilmesini sağlamaktadır. Benzer yaklaşımın anormal durum tespitinde takip edilmesi görünüm ve hareket kaynaklı anormal durumların belirlenmesini sağlayarak, akıllı sistemlerin güvenilirliğini artırır.

Bu çalışmada logaritmik kovaryans matrisi (LECM), önce hareket ve görünüm ipuçları yardımıyla (LECM-1) daha sonra sadece hareket bilgisi (LECM-2) ile oluşturularak anomali tespitinde kullanılmıştır. Hareket bilgisi için optik akış tabanlı özniteliklerden yararlanılmıştır. Görünüm bilgisi ise gradyan tabanlı öznitelikler yardımıyla temsil edilmiştir.

3.1.4 LECM-1

Video görüntüleri üzerinde $(x; y; t)$ piksel konumundan çıkarılan, gradyan (g) ve optik akışa (o) dayalı özelliklerin kombinasyonu şeklinde oluşturulan öznitelik vektörü $f(x, y, t)$ aşağıda belirtilen formdadır:

$$f(x, y, t) = [x, y, t, g, o]^T \quad (3.13)$$

$$g = \left[|I_x|, |I_y|, |I_{xx}|, |I_{yy}|, \sqrt{I_x^2 + I_y^2} \right] \quad (3.14)$$

$$o = \left[u, v, \frac{\partial u}{\partial t}, \frac{\partial v}{\partial t}, \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right), \left(\frac{\partial v}{\partial x} - \frac{\partial u}{\partial y} \right) \right] \quad (3.15)$$

g kümesinde I gri seviyede görüntü olmak üzere x, y eksenleri boyunca elde edilen birinci dereceden türevler; I_x, I_y ve ikinci dereceden türevler; I_{xx}, I_{yy} şeklindedir. $\sqrt{I_x^2 + I_y^2}$ ise gradyan büyüklüğüne karşılık gelmektedir.

UMN veri kümesinde üç farklı sahnede normal ve anormal durumlar sırasında elde edilen görünüm tabanlı öznitelikler aşağıda belirtilen şekilde verilmiştir:

- Sahne-1 normal ve anormal durumlar : Şekil 3.5 ve Şekil 3.6
- Sahne-2 normal ve anormal durumlar : Şekil 3.7 ve Şekil 3.8
- Sahne-3 normal ve anormal durumlar : Şekil 3.9 ve Şekil 3.10

o optik akış tabanlı özniteliklerin kümesinde u, v optik akışın yatay ve düşey bileşenlerini $\frac{\partial u}{\partial t}, \frac{\partial v}{\partial t}$ yatay ve düşey bileşenlerin zamana göre türevini, son iki eleman sırasıyla akış alanının mekansal farklılığını temsil eden ıraksama (divergence) ve vortisiteyi (vorticity) [43] ifade etmektedir. Optik akış hareketi temsil etmede kullanılan önemli bir öznitelik türüdür ve literatürde sayısız çalışmada kullanımı mevcuttur. Ali ve Shah [43], optik akış tabanlı kinematik öznitelikleri hareket tanıma amacıyla kullanmıştır. Bu öznitelikler vortisite (vorticity), ıraksama (divergence), simetrik ve asimetric alanlar (symmetric and asymmetric fields), gradyan tensörü (gradient tensor features), gerinim ve dönüş tensörü hızı (rate of strain and spin tensor features) şeklinde sıralanmaktadır. Kinematik terimi, önerilen özniteliklerin nesnenin kütesine etki eden kuvvetlerden bağımsız olduğunu ve yalnızca hareket bilgisini yakaladığını vurgulamaktadır [43].

Burada LECM-1'in oluşturulmasında, vortisite (vorticity) ve ıraksama (divergence) kinematik özniteliklerinden yararlanılmıştır.

İraksama (divergence), akış alanının mekansal farklılığıdır ve her bir piksel konumunda aşağıdaki şekilde tanımlanır:

$$Div(x, y, t) = \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) \quad (3.16)$$

Eşitlik 3.16'da $\frac{\partial u}{\partial x}$ optik akışın yatay bileşeninin x eksenine göre birinci dereceden türevini, $\frac{\partial v}{\partial y}$ ise optik akışın düşey bileşeninin y eksenine göre birinci dereceden türevini ifade etmektedir.

Vortisite (vorticity), akış alanı düzlemine dikey ekseninde yerel dönüşün ölçüsüdür [43] ve aşağıdaki şekilde hesaplanır:

$$Vor(x, y, t) = \left(\frac{\partial v}{\partial x} - \frac{\partial u}{\partial y} \right) \quad (3.77)$$


Eşitlik 3.17'de $\frac{\partial v}{\partial x}$ optik akışın düşey bileşeninin x eksenine göre birinci dereceden türevini, $\frac{\partial u}{\partial y}$ ise optik akışın yatay bileşeninin y eksenine göre birinci dereceden türevini ifade etmektedir.

UMN veri kümesinde üç farklı sahnede, normal ve anormal durumlar sırasında elde edilen ıraksama (divergence), vortisite (vorticity) özniteliklerine ait görseller aşağıda belirtilen şekilde verilmiştir:


- Sahne-1 normal ve anormal durumlar : Şekil 3.11
- Sahne-2 normal ve anormal durumlar : Şekil 3.12
- Sahne-3 normal ve anormal durumlar : Şekil 3.13




a) I (Görüntü-20)




b) $I_x = \frac{\partial I}{\partial x}$




c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$



e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$




f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$


Şekil 3.5 Sahne-1'de normal olaylar sırasında elde edilen görünüm öznelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü




a) I (Görüntü-516)




b) $I_x = \frac{\partial I}{\partial x}$




c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$



e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$




f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$


Şekil 3.6 Sahne-1’de anormal olaylar sırasında elde edilen görünüm öznelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü




a) I (Görüntü-4288)




b) $I_x = \frac{\partial I}{\partial x}$



c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$



e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$




f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$


Şekil 3.7 Sahne-2’de normal olaylar sırasında elde edilen görünüm öznetelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü




a) I (Görüntü-5421)




b) $I_x = \frac{\partial I}{\partial x}$



c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$



e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$




f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$


Şekil 3.8 Sahne-2’de anormal olaylar sırasında elde edilen görünüm öznelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü



a) I (Görüntü-7184)




b) $I_x = \frac{\partial I}{\partial x}$




c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$



e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$




f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$


Şekil 3.9 Sahne-3'te normal olaylar sırasında elde edilen görünüm öznelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü




a) I (Görüntü-6187)




b) $I_x = \frac{\partial I}{\partial x}$




c) $I_y = \frac{\partial I}{\partial y}$



d) $I_{xx} = \frac{\partial^2 I}{\partial x^2}$

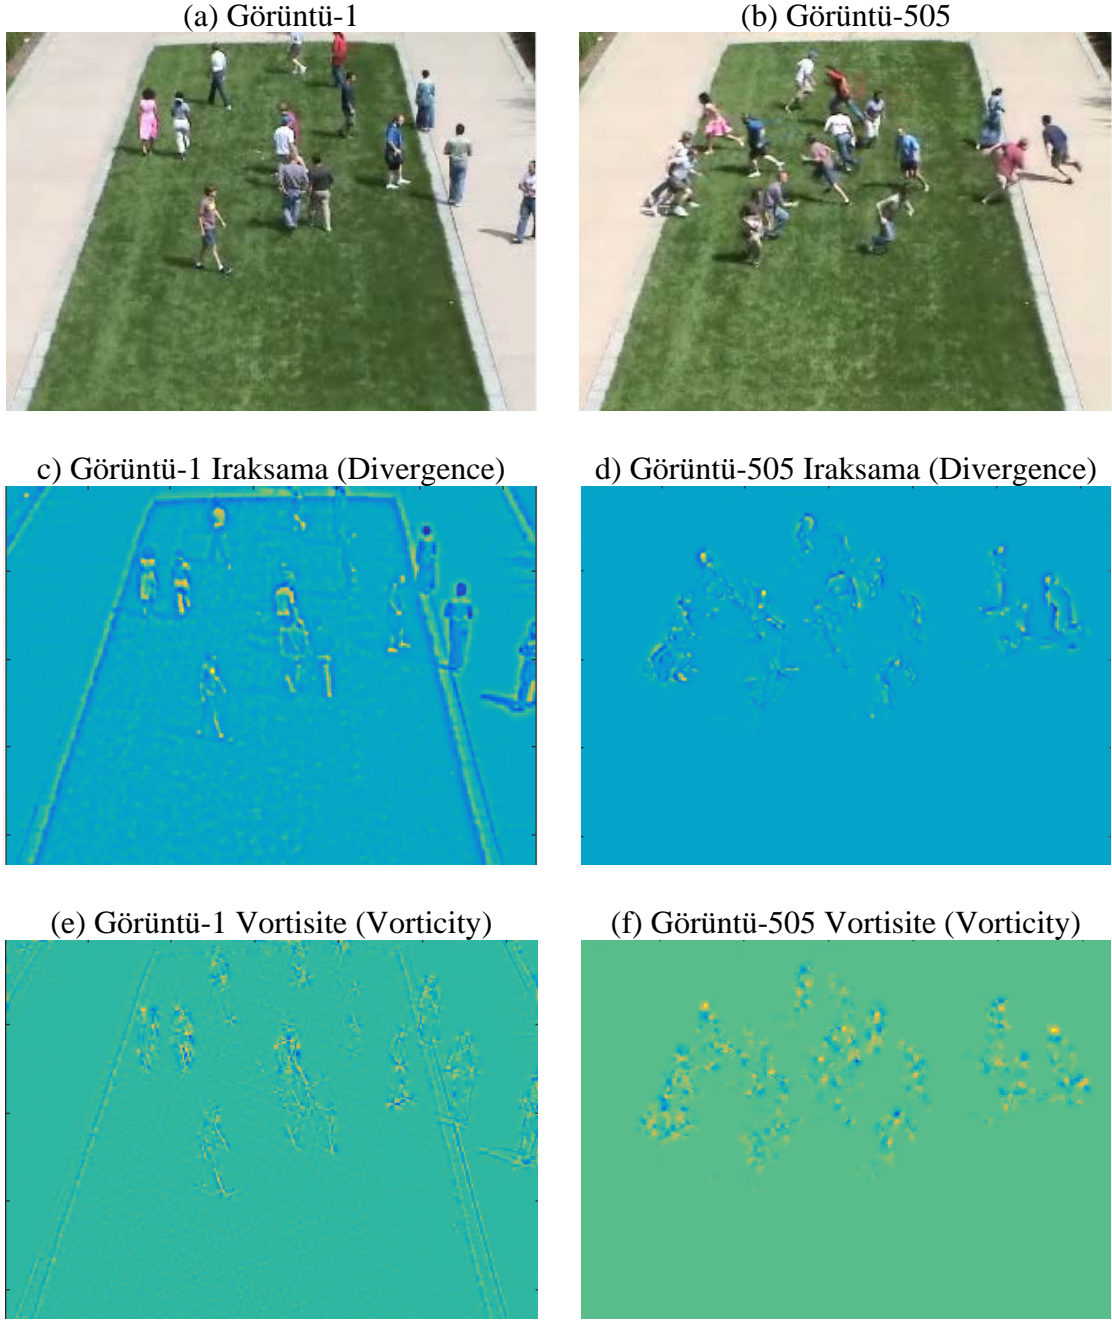


e) $I_{yy} = \frac{\partial^2 I}{\partial y^2}$

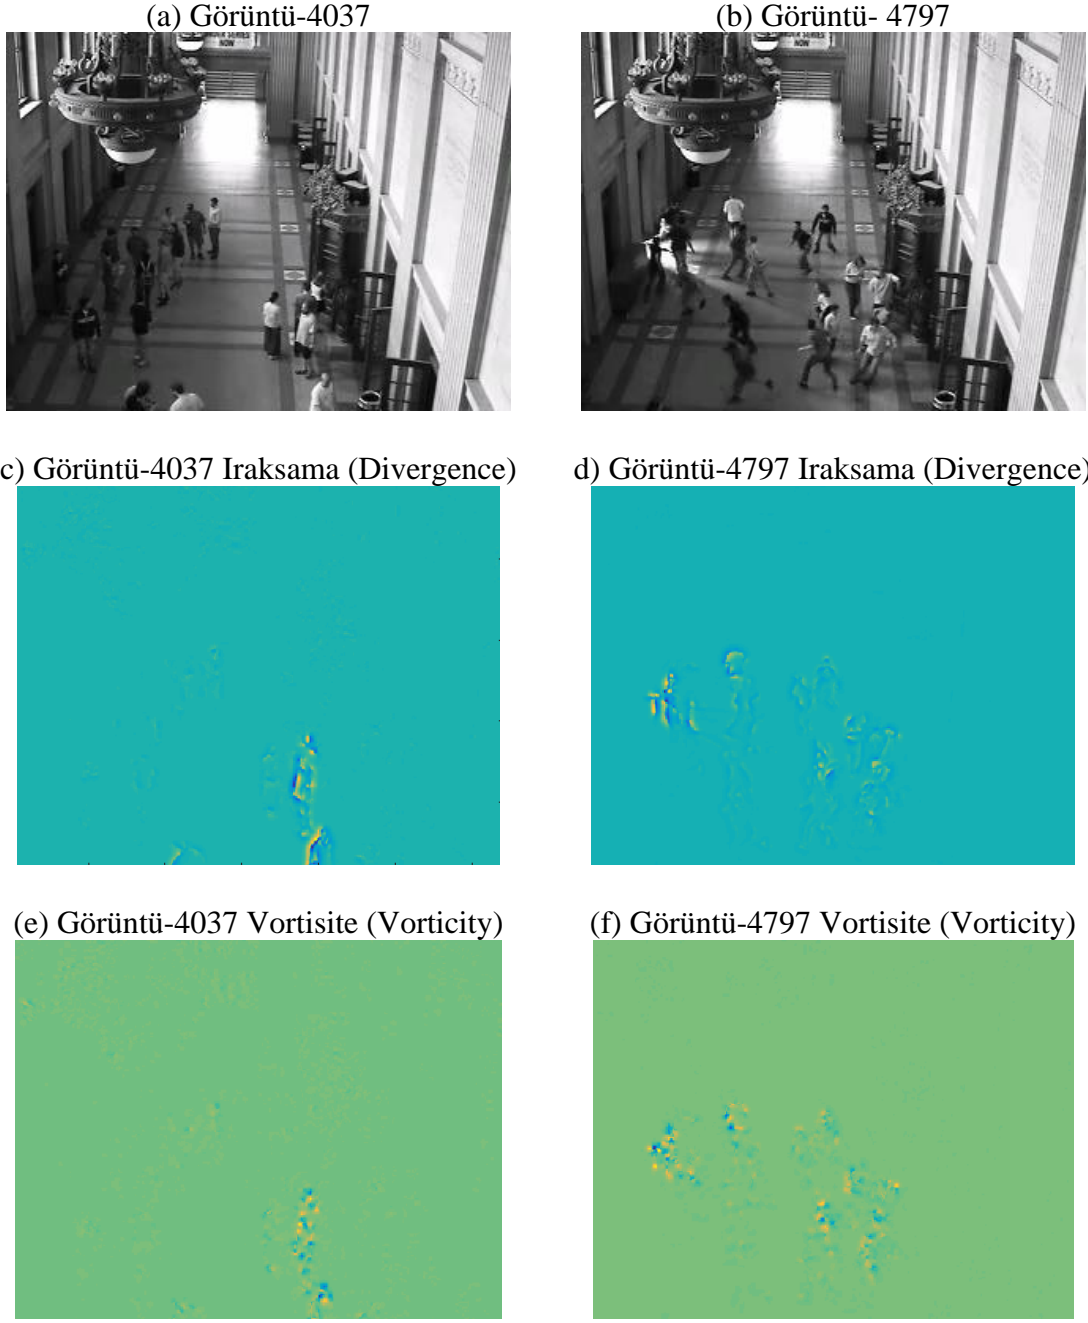


f) $\sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$

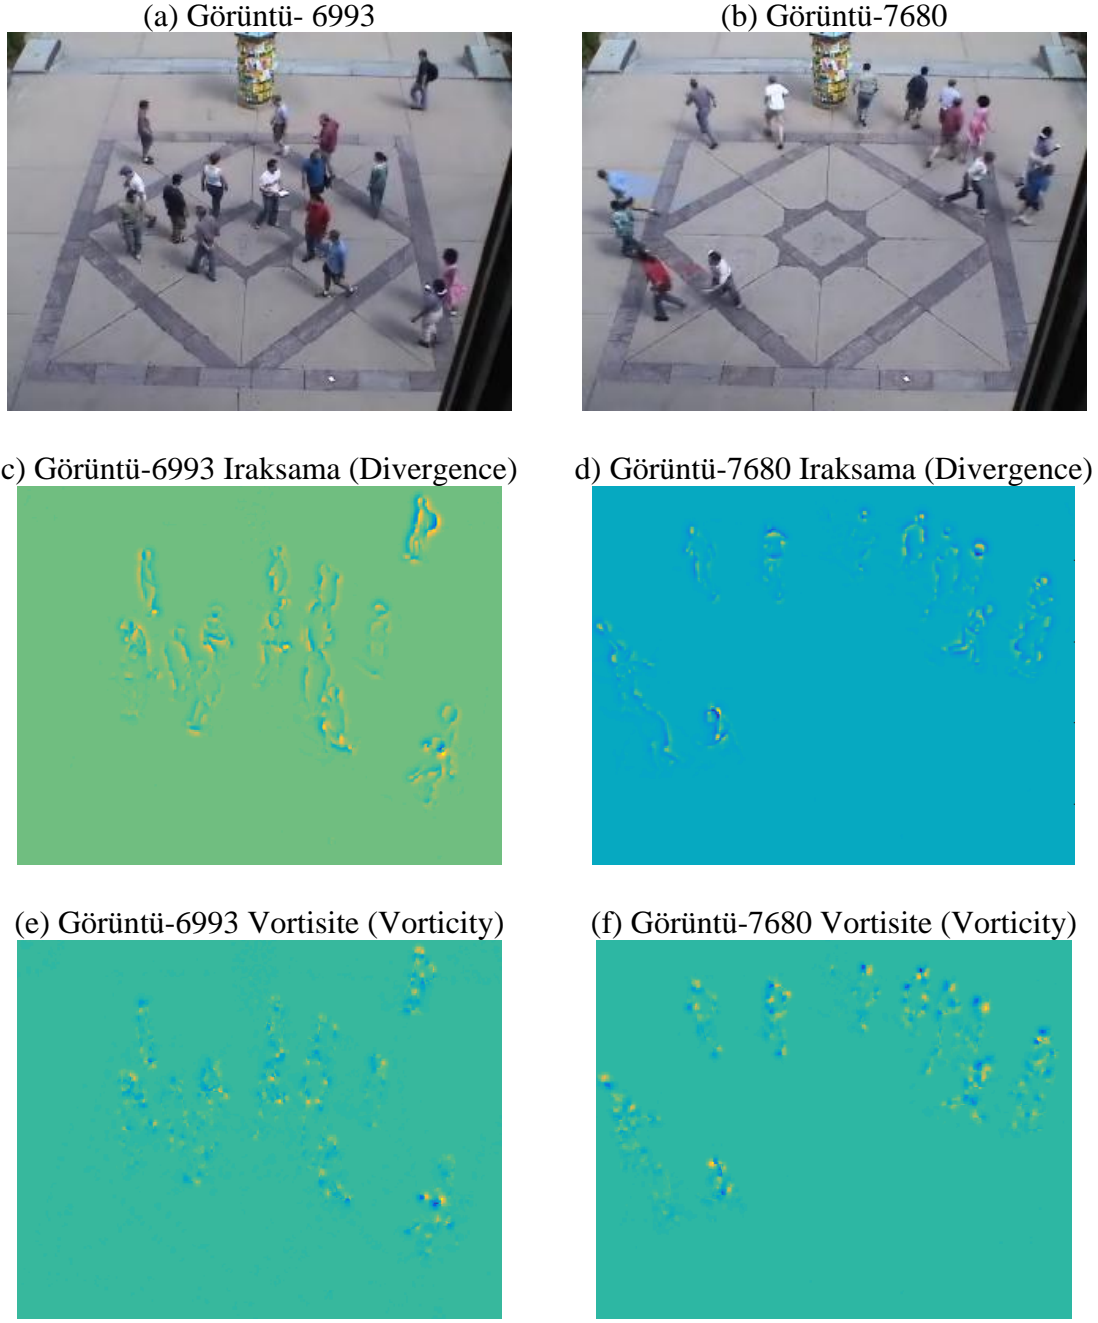
Şekil 3.10 Sahne-3'te anormal olaylar sırasında elde edilen görünüm öznelikleri (b) x eksenine göre birinci dereceden türev (c) y eksenine göre birinci dereceden türev (d) x eksenine göre ikinci dereceden türev (e) y eksenine göre ikinci dereceden türev (f) Gradyan büyüklüğü



Şekil 3.11 Kinematik öznitelikler Sahne-1 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen iraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen iraksama ve vortisite öznitelikleri



Şekil 3.12 Kinematik öznitelikler Sahne-2 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen iraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen iraksama ve vortisite öznitelikleri



Şekil 3.13 Kinematik öznitelikler Sahne-3 (a) Normal görüntü (b) Anormal görüntü (c) (e) Normal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri (d) (f) Anormal olaylar sırasında elde edilen ıraksama ve vortisite öznitelikleri

3.1.5 LECM-2

Burada kovaryans matrisi, sadece optik akış tabanlı özniteliklerin kullanılmasıyla oluşturulmuştur. LECM-1'den farklı olarak tensör değişmezleri olarak ifade edilen (*Gten*, *Sten*) kinematik özniteliklerden yararlanılmıştır. Benzer yaklaşım, hareket tanıma amacıyla Guo ve diğerleri [44] tarafından takip edilmiştir. Guo ve diğerleri [44], kovaryans tabanlı tanımlayıcıları, en yakın komşuluk ve seyrek doğrusal temsile dayalı sınıflama yöntemleri ile hareket tanımda kullanmıştır.

Video görüntüleri üzerinde (x ; y ; t) piksel konumundan çıkarılan, optik akışa dayalı özniteliklerin kombinasyonu şeklinde oluşturulan öznitelik vektörü $f(x, y, t)$ aşağıda belirtilen formdadır:

$$f(x, y, t) = \left[x, y, t, u, v, \frac{\partial u}{\partial t}, \frac{\partial v}{\partial t}, Div, Vor, Gten, Sten \right]^T \quad (3.18)$$

u , v sırasıyla optik akışın yatay ve dikey bileşenlerini $\frac{\partial u}{\partial t}$, $\frac{\partial v}{\partial t}$ yatay ve dikey bileşenlerin zamana göre türevini, *Div* ıraksama (divergence), *Vor* vortisiteyi (vorticity) ifade etmektedir. *Gten*, *Sten* optik akışın gradyan tensörü ve gerinim tensörü hızı (the rate of strain tensor) kullanılarak türetilen kinematik özniteliklerdir.

Optik akışın gradyan tensörü $\nabla u(x, y, t)$, uzamsal konumlardan elde edilen 2×2 boyutunda bir matristir [43] ve aşağıdaki şekilde tanımlanır.

$$\nabla u(x, y, t) = \begin{pmatrix} \frac{\partial u}{\partial x} & \frac{\partial u}{\partial y} \\ \frac{\partial v}{\partial x} & \frac{\partial v}{\partial y} \end{pmatrix} \quad (3.19)$$

3.19'da $\frac{\partial u}{\partial x}$, $\frac{\partial u}{\partial y}$ sırasıyla optik akışın yatay bileşeninin x ve y eksenine göre birinci dereceden türevini, $\frac{\partial v}{\partial x}$, $\frac{\partial v}{\partial y}$ ise optik akışın dikey bileşeninin x ve y eksenine göre birinci dereceden türevini ifade etmektedir.

Gerinim tensörü hızı (the rate of strain tensor) $S(x, y, t)$ olmak üzere, 3.20'de gösterildiği gibi hesaplanır.

$$S(x, y, t) = \frac{1}{2} (\nabla u(x, y, t) + \nabla u(x, y, t)^T) \quad (3.20)$$

G_{ten} , S_{ten} öznitelikleri, optik akışın gradyan tensörü $\nabla u(x, y, t)$ ve gerinim tensörü hızı $S(x, y, t)$ kullanılarak aşağıdaki gibi hesaplanır:

$$G_{ten}(x, y, t) = \frac{1}{2} \left(tr^2(\nabla u(x, y, t)) - tr(\nabla^2 u(x, y, t)) \right) \quad (3.21)$$

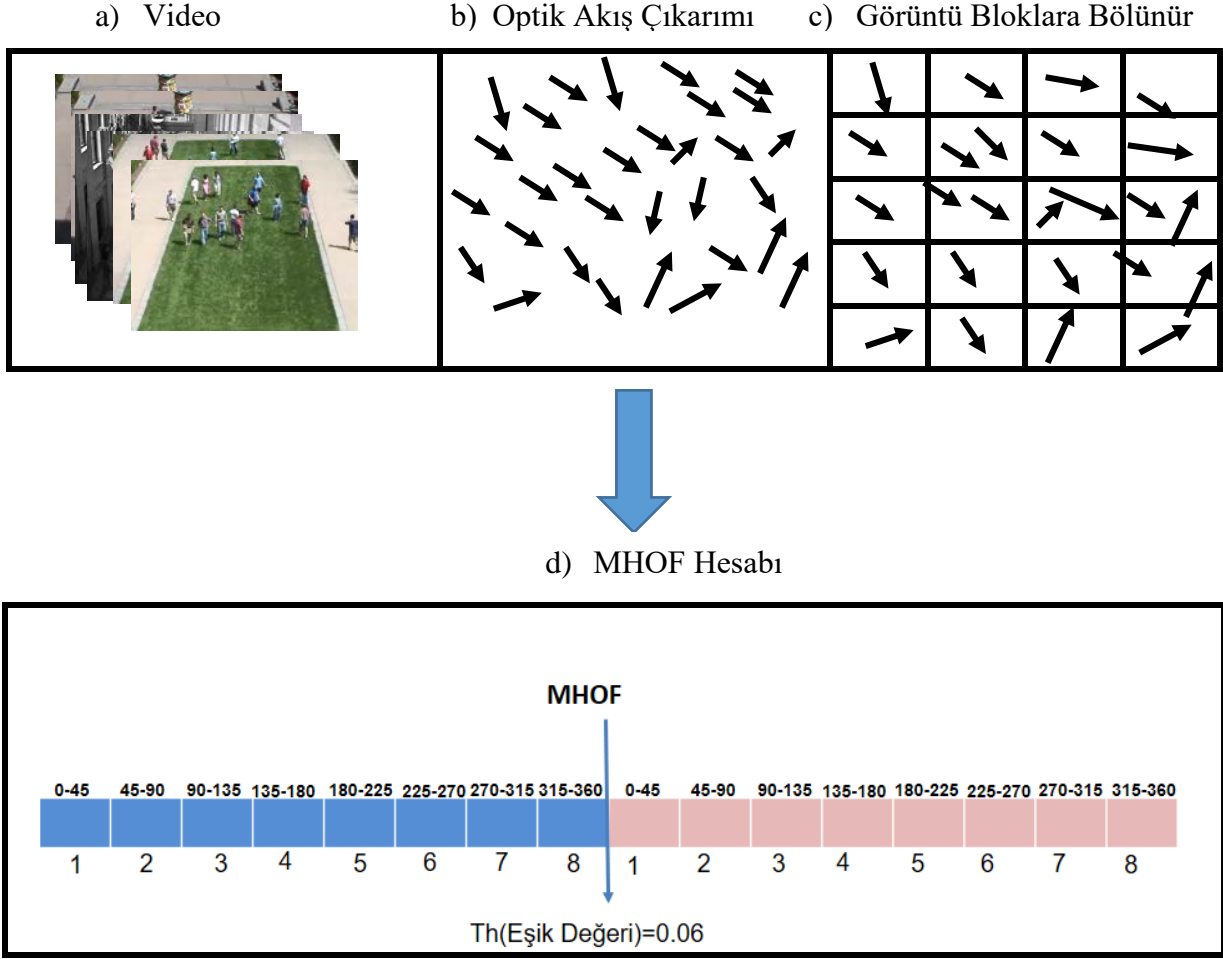
$$S_{ten}(x, y, t) = \frac{1}{2} \left(tr^2(S(x, y, t)) - tr(S^2(x, y, t)) \right) \quad (3.22)$$

Yukarıdaki eşitliklerde (3.21 ve 3.22) $tr(\cdot)$ izleme işlemini gösterir.

3.2 MHOF Özniteliği

MHOF özniteliği, ilk olarak Cong ve diğerleri [15] tarafından önerilmiştir. Cong ve diğerleri [15], bu özniteliği kural tabanlı yaklaşım ile global ve lokal anormal olay tespitinde kullanmıştır. MHOF özniteliği, belirli bir eşik değerine göre iki veya daha fazla optik akış histogramının birleştirilmesiyle oluşturulmaktadır. Bu sayede optik akış histogramına göre daha ayrıntılı hareket temsili sunmaktadır. Bu çalışmada MHOF özniteliği, kural tabanlı yaklaşımlara göre daha basit ve hesaplama maliyeti düşük olan tek sınıf sınıflandırıcılar ile global anomali tespitinde kullanılarak performansı incelenmiştir.

MHOF, görüntünün bloklara bölünmesi ve her bir bloktan elde edilen MHOF özniteliklerinin birleştirilmesiyle oluşturulur. Blok sayısı elde edilmek istenen bilgiye göre belirlenir. Ayrıntılı olarak hareket bilgisi incelenmek isteniyorsa blok sayısı fazla tutulur. Şekil 3.14'te MHOF özniteliğinin hesaplanması sırasında izlenen adımlar verilmiştir. Buna göre video üzerinde Horn-Schunck yöntemi ile optik akış hesabı yapıldıktan sonra görüntü bloklara ayrılır. Her bir blok üzerinden MHOF özniteliği hesaplanarak son adımda birleştirilir. Bu çalışmada görüntüler [15] çalışmasına benzer şekilde 4x5 bloklar halinde incelenmiştir. Sonuç olarak, 320 (4*5*16) boyutunda öznitelik vektörü elde edilmiştir. Asıl çalışmada [15] kullanılan eşik değeri (Th) 1 olarak belirlenmiştir. Deneyler sırasında bu değer in ortalama hızdan genelde büyük olması nedeniyle, çok parçalı histogramda eşik değerinden büyük kısımların çoğunlukla boş kaldığı gözlemlenmiştir. Detaylı ve tutarlı temsil elde etmek amacıyla çeşitli eşik değerleri ile deneme yapılmış ve 0.06 değerinde karar kılınmıştır. Bu sayede eşik değerinden önceki ve sonraki histogramın dengeli yapıda olması sağlanmıştır.



Şekil 3.14 MHOFF özneliğinin hesaplanması (a) (b) Video üzerinde Horn-Schunck yöntemi ile optik akış hesaplanır. (c) (d) Görüntüler küçük bloklara bölünür ve her blok için MHOFF özneliği elde edilir. Daha sonra görüntü üzerinde küçük bloklardan elde edilen öznelikler birleştirilerek global MHOFF özneliği elde edilir. Yukarıdaki histogramda sağ taraf eşik değerinden büyük kesimleri, sol taraf küçük kesimleri göstermektedir.

3.3 Tek Sınıf Sınıflandırma Yöntemleri ile Anomali Tespiti


Tek sınıf sınıflandırma yöntemlerinin anormal durum tespitinde tercih edilmesinin temel sebebi, anormal olayların çeşitli sayıda olması ve bu durumları yansıtan örneklerin toplanmasında yaşanan zorluklardır. Normal durumlara ait örneklerin elde edilmesi, anormal durumlara göre çok daha kolay olduğu için anomali tespitinde yaygın yaklaşım, sahnede görülmesi muhtemel olayların modellenmesi ve modele uymayan durumların anormal olarak kabul edilmesi şeklindedir. Tek sınıf sınıflandırma yöntemlerinden SVDD ve

OCSVM’de, öncelikle normal verilerin dağılımı incelenir. Normal verilerin yoğunlukta olduğu bölge belirlendikten sonra, test verilerinin bu dağılımın içinde bulunma veya bulunmama durumuna göre anomali tespiti yapılır. SVDD normal verileri küresel alan ile çevreleyerek temsil ederken, OCSVM veriyi başlangıç noktasından, maksimum marjinle çizilen hiperdüzlem ile ayırır.

3.3.1 Tek Sınıf Destek Vektör Makineleri (OCSVM - One Class Support Vector Machines)

Tek sınıf SVM sadece pozitif (bu çalışma için normal durumlar) örneklerin bulunduğu durumlarda kullanılan sınıflandırma yöntemidir. Burada amaç, normal örneklere benzeyen durumların diğer tüm sınıflardan ayrılmasını sağlamaktır.

Schölkopf ve diğerleri [45], bu amaçla klasik SVM metodolojisini, tek sınıf sınıflandırma problemine uyarlayan bir yöntem önermiştir. Bu yöneme göre, veriler öncelikle çekirdek (kernel) kullanılarak başka bir düzleme aktarılır. Sınıflandırma işleminde başlangıç noktasına (origin) ikinci sınıfın tek bir üyesiymiş gibi muamele yapılır. Ardından gevşeme parametreleri (relaxation parameters) kullanılarak bir sınıfın görüntüsü, başlangıç noktasından standart iki sınıflı SVM teknikleri kullanılarak ayrılır. Bu durum Şekil 3.15’te gösterilmiştir.



Şekil 3.15 Tek sınıf Destek Vektör Makineleri. Başlangıç noktasının ikinci sınıfa ait eleman olduğu varsayılmaktadır. ([46]’den alıntılanmıştır.)

Bu yaklaşımda; veri kümesinin, öznitelik uzayında P olasılık dağılımına sahip olduğu varsayılınsın. Amaç bu öznitelik uzayında basit bir S alt kümesi belirlenmesi ve P' den gelen bir test noktasının S' nin dışına çıkma ihtimalinin önceden belirlenmiş bir değerle $v \in (0,1)$ sınırlandırılmasıdır. Bu durumun çözümü, bir f fonksiyonunun S ile gösterilen alt küme sınırlarında pozitif, S dışında kalan alanlarda ise negatif değer üretecek şekilde belirlenmesiyle sağlanır.

Schölkopf ve diğerlerinin [45] tanımına göre, f fonksiyonu pozitif (normal) durumların çoğunu temsil eden olabildiğince küçük bir alanda $+1$ değeri üretirken, diğer kısımlarda -1 değerine sahiptir.

$$f(x) = \begin{cases} +1, & x \in S \\ -1, & x \in \bar{S} \end{cases} \quad (3.23)$$

Buna göre x_1, x_2, \dots, x_l tek sınıf X' e ait öznitelik kümesinin, $\phi : X \rightarrow H$ çekirdek kullanılarak başka düzleme eşlenmesiyle, normal örneklerin diğerlerinden ayrılma işlemi aşağıdaki karesel programlama probleminin çözümüyle sağlanır:

$$\min \frac{1}{2} \|w\|^2 + \frac{1}{vl} \sum_{i=1}^l \xi_i - \rho, \quad (3.24)$$

$$(w \cdot \phi(x_i)) \geq \rho - \xi_i \quad i = 1, 2, \dots, l \quad \xi_i \geq 0 \quad (3.25)$$

Karar fonksiyonu $f(x)$,

$$f(x) = \text{sign} \left((w \cdot \phi(x)) - \rho \right) \quad (3.26)$$

eğitim setinde bulunan x_i örnekleri için pozitif olacaktır.

3.3.2 Destek Vektör Veri Tanımı (SVDD - Support Vector Data Description)

Destek Vektör Veri Tanımı (SVDD), Tax ve Duin [47] tarafından önerilmiştir. SVDD ile normal veriler, en küçük yarıçapa sahip küresel bir alan ile ifade edilir. Belirlenen alanın dışında kalan noktalar ise anormal durum olarak kabul edilir.


Buna göre SVDD'de temel yaklaşım, x_1, x_2, \dots, x_n eğitim kümesini öznitelik alanına eşleyerek verilerin çoğunu dahil eden olabildiğince küçük bir küresel alan aramaktır.

Bu durum ařađıdaki gibi formüle edilebilir:

$$\min_{R,c,\xi} R^2 + C \sum_1^n \xi_i, \quad (3.27)$$

$$\|\phi(X_i) - c\| \leq R^2 + \xi_i, \quad i = 1,2,3, \dots, n \quad (3.28)$$

R çizilen küresel alanın yarıçapını, C düzgün karar sınırı çizimi ile eğitim noktalarının doğru şekilde sınıflandırılması arasındaki dengeyi ifade etmektedir. Şekil 3.16'de OCSVM ve SVDD'ye ait görseller verilmiştir.



Şekil 3.16 Hiperdüzlem tek sınıf Destek Vektör Makinesi (OCSVM), hiperküre Destek Vektör Tanımı (SVDD) ([48]'den alıntılanmıştır.)

4 DENEYSEL SONUÇLAR

Bu bölümde, ilk olarak kullanılan anormal davranış veri kümesi UMN (University of Minnesota) [40] ayrıntılı olarak incelenmiş ve performans metrikleri hakkında bilgi verilmiştir. Ardından farklı şekilde oluşturulan LECM ve MHOF özniteliklerinin SVDD, OCSVM sınıflandırıcıları ile kullanılmasıyla elde edilen sonuçlar gösterilmiş ve diğer çalışmalarla karşılaştırma yapılmıştır. Anormal durum tespiti için önerilen yaklaşımların, UMN veri kümesi üzerindeki performansı, ROC (Receiver Operating Characteristic) eğrisi ve AUC (Area Under The Curve) metriği kullanılarak değerlendirilmiştir.

Son kısımda ise önerilen yöntemin güçlü ve zayıf yanları tartışılarak, gelecekte yapılması planlanan çalışmalara değinilmektedir.

4.1 Veri Kümesi

Önerilen yöntemin performansını ölçmek amacıyla UMN veri kümesi kullanılmıştır. UMN veri kümesi 1 adet iç ve 2 adet dış mekan sahnesinden olmak üzere toplamda 11 video ve 7739 (frame) görüntüden oluşmaktadır. Her video, normal davranışlar ile başlar ve kaçışma anormal davranışıyla sonlanır. Üç sahnedeki normal ve anormal durumlara ilişkin örnekler, Şekil 4.1’de gösterilmiştir. Görüntüler 320×240 çözünürlüktedir ve deneyler sırasında orijinal boyutlarında kullanılmıştır. Her bir sahne için görüntü aralıkları aşağıdaki gibidir;

- Sahne 1 : 1 — 1453
- Sahne 2 : 1454 — 5597
- Sahne 3 : 5598 — 7739

4.2 Performans Metrikleri

Elde edilen sonuçlar üzerinde nicel analiz yapmak amacıyla ROC (Receiver Operating Characteristics) eğrisi ve ROC eğrisi altındaki alanı ifade eden AUC (Area Under Curvature) performans metriği kullanılmıştır. AUC metriği, farklı sınıflandırma yöntemlerinin karşılaştırılmasında kullanılan uygun bir yöntemdir. AUC değeri, rastgele sınıflandırıcı için 0.5 iken, ideal olan sınıflandırıcılarda 1 değerine sahiptir.

ROC eğri çizimi ve eğri altı alanı (AUC) hesabı için, gerçek pozitif oranı (TPR) ve yalancı pozitif oranı (FPR) belirlenmelidir. Bu amaçla, UMN veri kümesi etiketlerine göre, yanlış pozitif (FP), gerçek pozitif (TP), yanlış negatifler (FN) ve gerçek negatifler (TN) belirlenerek, aşağıda belirtilen formüle göre TPR ve FPR değerleri hesaplanmıştır.

$$TPR = \frac{TP}{TP + FN} \quad (4.1)$$

$$FPR = \frac{FP}{FP + TN} \quad (4.2)$$



Şekil 4.1 UMN veri kümesine ait üç farklı sahnede gözlemlenen normal ve anormal durumların gösterimi


4.3 Deneysel Sonular

Bu b3l3mde SVDD ve OCSVM sınıflandırma y3ntemleri ile elde edilen sonular tartiřılmıştır.

4.3.1 SVDD ile Elde Edilen Sonular


Burada LECM-1, LECM-2 ve MHOF 3z nitelikleri ile SVDD sınıflandırıcısı kullanılarak modeller eęitilmiş ve modelin bařarımı ROC eęrileri ve AUC metrięi ile 3l3lmeye alışılmıştır. Bu kesimdeki deneylerde, normal ve anormal olay ieren g3r3nt3ler belirlenirken, UMN veri k3mesi 3zerindeki referans etiketler dikkat alınmıştır.

SVDD sınıflandırıcısının, g3r3n3m ve hareket bilgisi yardımıyla oluřturulan LECM-1 3z nitelięi ile kullanılmasıyla elde edilen ROC eęrisi ve AUC deęerleri Őekil 4.2’de verilmiştir. Rastgele sınıflandırıcı ile elde edilen AUC deęerinin 0.5 olduęu ve 3nceki alışmaların [13] [15] [26] bu veri k3mesi 3zerinde her bir sahnede 0.87-0.99 aralıęında sonular elde ettięi g3z 3n3ne alındıęında, SVDD ile bařarı saęlanamadıęı g3r3lmektedir.




Őekil 4.2 UMN veri k3mesi etiketlerine g3re 3 sahneye iliřkin ROC eęrisi (LECM-1 + SVDD)

SVDD sınıflandırıcısının, sadece hareket bilgisi yardımıyla oluşturulan LECM-2 özniteliği ile kullanılmasıyla elde edilen ROC eğrisi ve AUC değerleri Şekil 4.3'te verilmiştir. Sonuçlar incelendiğinde, rastgele sınıflayıcı ile elde edilen AUC değerine (0.5) Sahne-2 ve Sahne-3'te erişilemediği görülmektedir. Ayrıca son zamanlarda yapılan çalışmalarla [13] [15] [26] Sahne-1'de 0.96-0.99 aralığında sonuçlar elde edilmesi, önerilen yöntem ile başarı sağlanamadığını göstermektedir.



Şekil 4.3 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-2 + SVDD)

SVDD sınıflandırıcısının, optik akış tabanlı MHOF özniteliği ile kullanılmasıyla elde edilen ROC eğrisi ve AUC değerleri Şekil 4.4'te verilmiştir. Daha önce de belirtildiği gibi, AUC değeri sınıflama yöntemlerinin başarımını ölçmede kullanılan yaygın bir yöntemdir ve bu değer rastgele bir sınıflayıcı için 0.5'tir. MHOF özniteliğinin SVDD sınıflandırma yöntemiyle kullanılmasıyla elde edilen sonuçlar rastgele sınıflayıcıya ait AUC değerine göre değerlendirildiğinde, yöntemin özellikle ikinci ve üçüncü sahnede oldukça başarısız olduğu ortaya çıkmaktadır.



Şekil 4.4 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (MHOF + SVDD)

ROC eğrilerinden ve AUC değerlerinden görüleceği gibi, SVDD sınıflandırıcısının MHOF ve LECM öznitelikleri ile kullanılmasıyla iyi sonuçlar elde edilememiştir. Normalde rastgele bir sınıflayıcı ile AUC değeri 0.5 civarlarında olması gerekirken, bu değerden kötü sonuçlar elde edilmiştir. Sonuçların iyileştirilmesi adına parametre optimizasyonu yapılmış, fakat gelişme sağlanamamıştır.

4.3.2 UMN Veri Kümesi Üzerinde Etiketleme

Literatürde anormal durum etiketlerinin oluşturulması sırasında dikkate alınan başlangıç ve bitiş noktaları üzerine çelişki yaşanmaktadır. Bu durum, UMN veri kümesinde de görülmektedir. Veri kümesi incelendiğinde, anormal olayların başlangıcını gösteren etiketlerin oldukça geç verildiği görülmektedir. Özellikle üçüncü sahnede, anormal olay başlangıç etiketi, anormal olayların bitişine doğru verilmiştir.

Bu durumun tartışmalı bir konu olması [13] ve kesin doğru cevabın olmaması nedeniyle, bu çalışmada normal ve anormal durum etiketlerinin, anormal olayların ilk görülmeye başlandığı zaman dikkate alınarak tekrar oluşturulması gerekmiştir. UMN veri kümesi etiketleri ve bu çalışmada oluşturulan etiketler, Çizelge 4.1 ve Çizelge 4.2’de verilmiştir. Bundan sonraki kesimde, OCSVM ile yapılan deneyler, hem orijinal UMN veri kümesi etiketlerine göre, hem de yeniden oluşturulan etiketlere göre yapılmıştır.

Sahne	Normal Olay Aralığı	Anormal Olay Aralığı
Sahne-1	1 - 525	526 - 615
	616 - 1330	1331 - 1440
	1441 - 1453	-----
Sahne-2	1454 - 1806	1807 - 1986
	1987 - 2605	2606 - 2685
	2686 - 3220	3221 - 3430
	3431 - 3939	3940 - 4019
	4020 - 4808	4809 - 4930
	4931 - 5423	5424 - 5597
Sahne-3	5598 - 6196	6197 - 6236
	6237 - 6884	6885 - 6914
	6915 - 7701	7702 - 7721
	7722 - 7739	-----

Çizelge 4.1 UMN veri kümesi etiketleri

Sahne	Normal Olay Aralığı	Anormal Olay Aralığı
Sahne-1	1 – 480	481 - 615
	616 - 1298	1299 - 1440
	1441 - 1453	----
Sahne-2	1454 - 1766	1767 - 1986
	1987 - 2563	2564 - 2685
	2686 – 3177	3178 - 3430
	3431 - 3909	3910 - 4019
	4020 – 4767	4768 - 4930
	4931 - 5387	5388 - 5597
Sahne-3	5598 - 6147	6148 - 6236
	6237 - 6831	6832 - 6914
	6915 - 7647	7648 - 7721
	7722 - 7739	-----


Çizelge 4.2 Anormal olayların ilk görülmeye başlandığı zamanın dikkate alınmasıyla yeniden oluşturulan veri kümesi etiketleri

4.3.3 OCSVM ile Elde Edilen Sonular

Bu alıřma kapsamında gerekleřtirilen global anomali tespitinde en iyi sonular, OCSVM sınıflandırıcısı kullanılarak elde edilmiřtir. zellikle grnm ve hareket ipularının birlikte kullanılmasıyla oluřturulan LECM-1 znetelięi ve OCSVM kombinasyonu, en iyi sonuların elde edildięi durumdur. Bu kombinasyon ile anormal durumlar grlmeye bařlandığı ilk andan itibaren tespit edilmiřtir. Ayrıca normal ve anormal durumlar arasında bařarılı řekilde geiř saęlanmıřtır. Deneyler sırasında, OCSVM bařarımının genel olarak SVDD'ye gre yksek olduęu gzlemlenmiřtir. Bu oran OCSVM ve SVDD ile elde edilen en iyi sonular baz alındığında, Sahne-1'de %38, Sahne-2'de %30, Sahne-3'te ise %47 dzeyindedir. Bu duruma, SVDD ile belirlenen kresel alanın normal ve anormal olaylar arasındaki sınır ayırımını yapamaması neden olmaktadır.

4.3.3.1 LECM-1 + OCSVM

nerilen yaklařımın orijinal veri kmesi etiketlerine gre deęerlendirilmesiyle,  farklı sahne iin elde edilen ROC eęrisi ve AUC deęerleri řekil 4.5'te verilmiřtir. AUC deęerleri bařarılı sonular elde edildięini gstermektedir. Burada nerilen yaklařım anormal olaylar sırasında, veri kmesi etiketlerine gre daha erken uyarı vermektedir.




řekil 4.5 UMN veri kmesi etiketlerine gre  sahneye iliřkin ROC eęrisi (LECM-1 + OCSVM)

Etiketlerin anormal durumların ilk gözlemlendiği noktaya göre yeniden düzenlenmesiyle elde edilen ROC eğrisi ve AUC değerleri Şekil 4.6'da gösterilmiştir. En yüksek AUC değerine sahip sonuç ilk sahnede elde edilmiştir. Bu durum, ilk sahnede hareket temsilinde kullanılan özneliklerin doğru bir şekilde çıkarımından kaynaklanmaktadır.

İkinci videonun kapalı alanda çekilmiş olması, bu sahnenin ilk sahneye göre daha zorlu bir yapıya sahip olmasına neden olmaktadır. Belirtilen problem ikinci sahnede, özneliklerin çıkarımını olumsuz şekilde etkileyerek, yöntemin performansını düşürmektedir. Üçüncü sahne ise ikinci en yüksek AUC değerinin elde edildiği sahnedir.

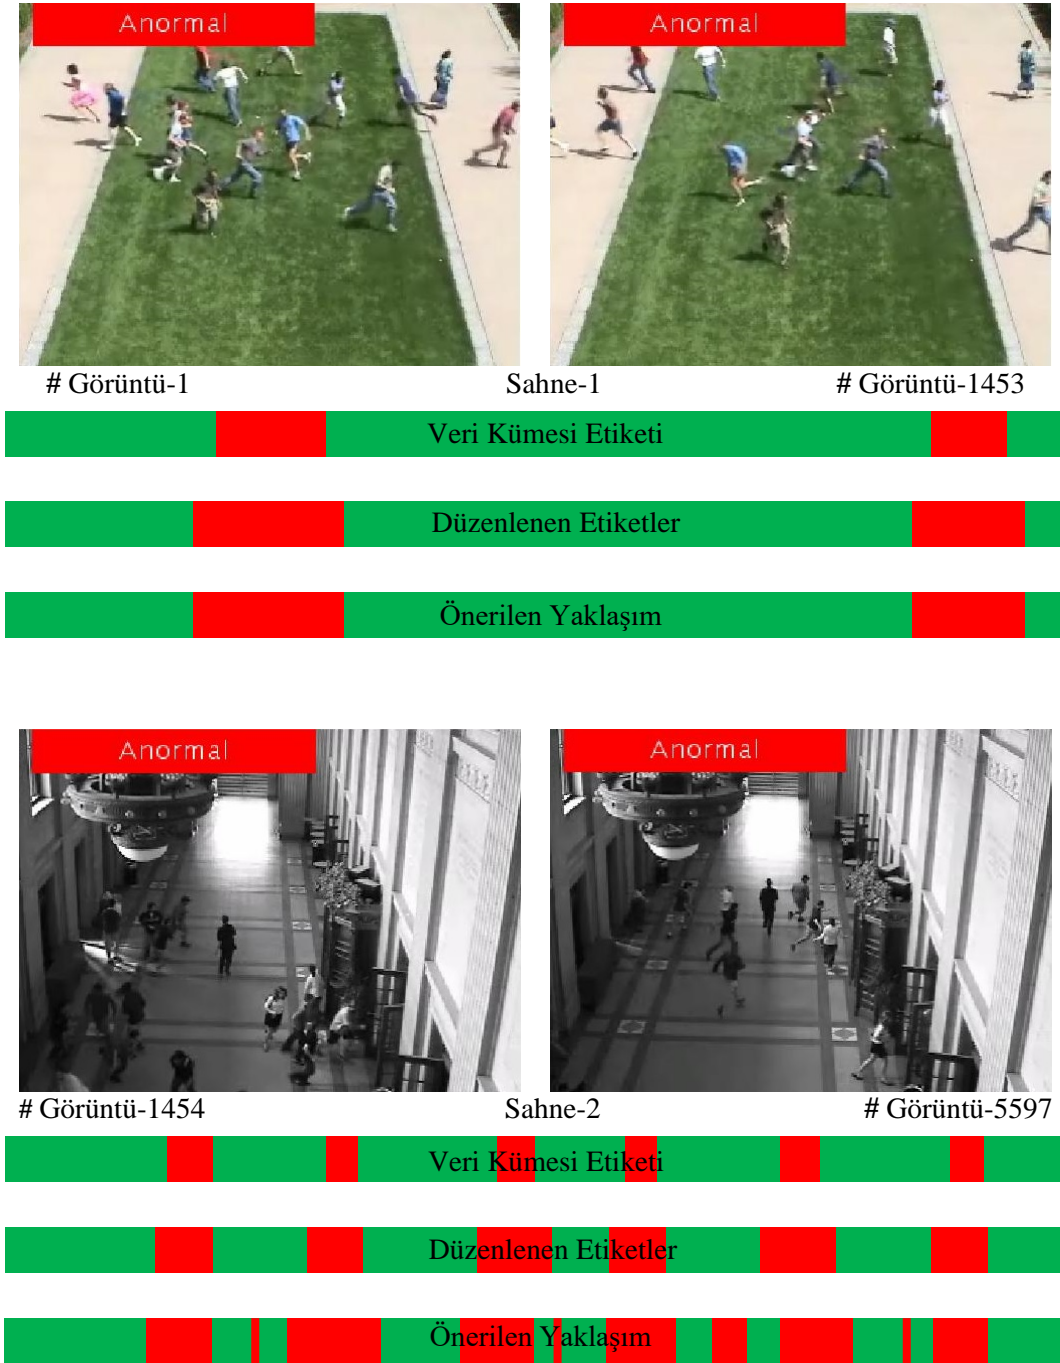
Düzenlenen etiketlere göre verilen sonuçların, veri kümesi etiketleri baz alınarak elde edilen sonuçlara göre yüksek olması, önerilen yöntemin düzenlenen etiketlere benzer şekilde anormal durumları ilk görüldüğü andan itibaren tespit etmesinden kaynaklanmaktadır.



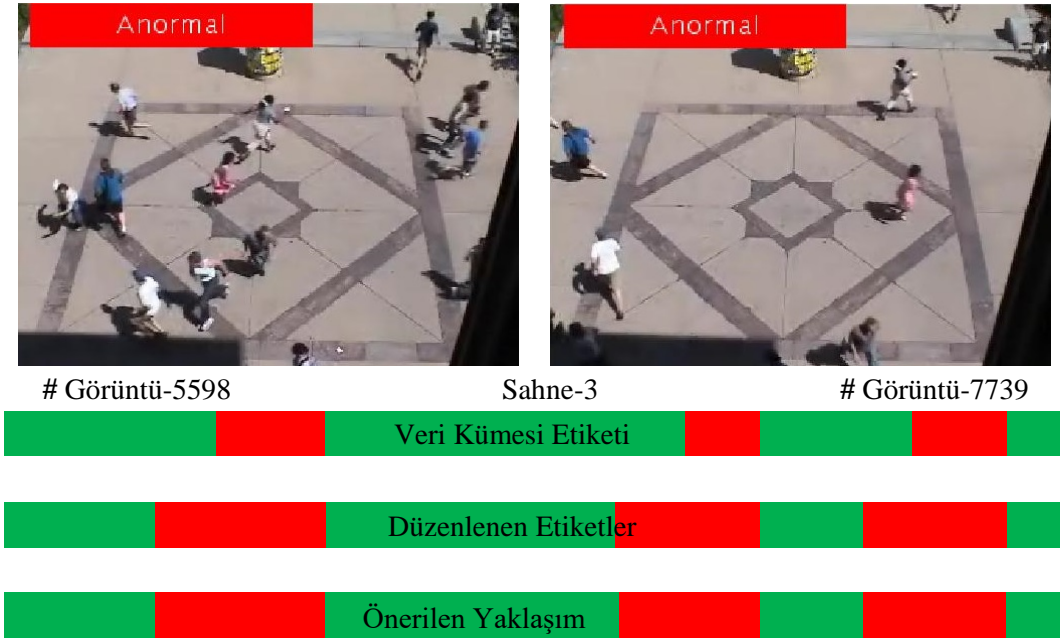
Şekil 4.6 Etiketlerin yeniden düzenlenmesiyle elde edilen üç sahneye ilişkin ROC eğrisi (LECM-1 + OCSVM)

Önerilen yöntem ile elde edilen sonuçlar, çalışmada kullanılan etiketlerle birlikte (Sahne-1 ve Sahne-2) Şekil 4.7'de ve Şekil 4.8'de (Sahne-3) verilmiştir. Sonuçlar incelendiğinde,

Sahne-2'nin kapalı ortamda çekilmiş görüntülerden oluşması ve ışııkta meydana gelen deęişimler nedeniyle, sistemin yanlış zamanlarda uyarı verdiği görülmektedir. Bu durum, Sahne-2'deki başarımın Sahne-1 ve Sahne-3'e göre daha düşük olmasına neden olmuştur. Deneysel sonuçlar, LECM-1 özniteliğinin OCSVM ile kullanılmasıyla başarılı sonuçlar elde edildiğini göstermektedir. Sonuçlar ayrıca, önerilen yöntemin genel olarak, anormal durumların başlangıç ve bitişini doğru şekilde belirlediğini ortaya koymaktadır.



Şekil 4.7 UMN veri kümesinde sahne-1 ve sahne-2'de tespit edilen anormal aktivite örnekleri (LECM-1 + OCSVM)




Şekil 4.8 UMN veri kümesi sahne-3'te tespit edilen anormal aktivite örnekleri (LECM-1 + OCSVM)

4.3.3.2 LECM-2 + OCSVM


Sadece hareket bilgisi kullanılarak oluşturulan LECM-2 özneliğinin OCSVM ile birlikte kullanılmasıyla elde edilen sonuçların, orijinal veri kümesi etiketlerine göre değerlendirilmesiyle çizilen ROC eğrisi ve AUC değerleri Şekil 4.9'da verilmiştir.

Sonuçlar incelendiğinde, LECM-1 özneliği ile daha yüksek AUC değerleri elde edildiği görülmektedir. Bu durum, birbirini tamamlayıcı yapıda olan görünüm ve hareket özneliklerinin birlikte, kalabalık davranışını daha iyi temsil etmesiyle açıklanabilir.



Şekil 4.9 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (LECM-2 + OCSVM)


Veri kümesindeki etiket tutarsızlığı nedeniyle, etiketlerin düzenlenmesiyle sonuçlar yeniden değerlendirilmiştir. Bu duruma ait ROC eğrisi ve AUC değerleri Şekil 4.10'da görülmektedir.



Şekil 4.10 Etiketlerin yeniden düzenlenmesiyle elde edilen üç sahneye ilişkin ROC eğrisi (LECM-2 + OCSVM)

Elde edilen sonuçlar ve çalışmada kullanılan etiketler Şekil 4.11 (Sahne-1 ve Sahne-2) ve Şekil 4.12'de (Sahne-3) verilmiştir.


LECM-1 özniteliği, LECM-2 özniteliğine göre anormal ve normal olaylar arasındaki sınır geçişi daha iyi yapmaktadır. Özellikle ikinci sahnede, LECM-2 özniteliği anormal olayların bitişini doğru şekilde tespit edememektedir. Sonuçlar ayrıca, hareket ve görünüm ipuçlarını birleştirmenin tespit doğruluğunu geliştirerek aynı zamanda yanlış alarmın azaltılabileceğini ortaya koymaktadır.



Şekil 4.12 UMN veri kümesinde sahne-3'te tespit edilen anormal aktivite örnekleri (LECM-2 + OCSVM)

4.3.3.3 MHOF + OCSVM

Optik akış tabanlı MHOF özneliğinin OCSVM ile kullanılmasıyla elde edilen ROC eğrisi ve AUC değerleri Şekil 4.13'de verilmiştir. MHOF özneliği ile anomali tespitinde istenen düzeyde başarımlar sağlanamamıştır. Bu nedenle, sahnelerde gözlemlenen anormal durumlar diğer yöntemlerdeki gibi ayrıntılı şekilde gösterilmemiştir.



Şekil 4.13 UMN veri kümesi etiketlerine göre üç sahneye ilişkin ROC eğrisi (MHOF + OCSVM)

4.3.3.4 Önerilen Yöntemin Mevcut Yöntemlerle Karşılaştırılması

Bu çalışmada, iki farklı şekilde oluşturulan logaritmik kovaryans öznitelikleri OCSVM sınıflandırıcısı ile otomatik anormal olay tespitinde kullanılmış ve başarılı sonuçlar elde edilmiştir. Önerilen yaklaşım ile elde edilen AUC değerleri, önceki çalışmalar ile Çizelge 4.3'de karşılaştırılmıştır.

LECM-1 özniteliği LECM-2'ye göre, ilk ve son sahnede %1, ikinci sahnede ise yaklaşık olarak % 4 oranında daha yüksek başarı elde edilmesini sağlamıştır. Bu durum, LECM-1'de hareket ve görünüm bilgisinin birlikte kullanılmasından kaynaklanmaktadır.

LECM-1 üç sahnede STCOG [25] çalışmasına göre daha yüksek AUC değerine sahip sonuçlar üretmiştir. Bu durum Sahne-1'de %6, Sahne-2'de %14 oranında olmak üzere belirgin şekilde ortaya çıkmaktadır.

SR [1] çalışması, sadece ikinci sahnede LECM-1'e %5 oranında üstünlük sağlamıştır. Burada, hareket bilgisine dayalı özniteliğin (MHOF) kural tabanlı sözlük öğrenme yöntemiyle kullanıldığı yaklaşımın [1], önerilen yaklaşıma göre daha karmaşık yapıda olduğu göz önünde bulundurulmalıdır.

LECM-1, MHOF özniteliğinin hareketli pikseller üzerinden çıkarıldığı kural tabanlı MIDL [35] yaklaşımını üç sahnede de geçmiştir. LECM-1 ile Sahne-1'de %10, Sahne-2'de %16, Sahne-3'te ise %1 oranında gelişme sağlanmıştır. LECM-1'de görüntü farkları ile ön plan çıkarımı yapılmamaktadır. Bu nedenle anomali tespitinde kullanılmaya daha uygun yapıdadır.

Hareket etki matrisi MI [24], LECM-1'e sadece üçüncü sahnede %1 oranında üstünlük sağlamaktadır. Sahne-1 ve özellikle Sahne-2'de, önerilen yaklaşım başarılıdır. Sahne-2'de önerilen yöntem ile %6 oranında gelişme sağlanmıştır.

Çizelgede bütünsel yaklaşım HF [20] ve optik akış tabanlı yöntemlerle HOFO [49] karşılaştırılmalarına yer verilmektedir. LECM-1 ile üç farklı sahnede HF [20] yaklaşımına üstünlük sağlanmıştır.

Wang ve Snoussi [49] çalışmalarında, HOFO özniteliğini SVM ve PCA olmak üzere iki farklı sınıflama yöntemiyle anomali tespitinde kullanmıştır. HOFO özniteliği PCA sınıflama yöntemiyle kullanıldığında, SVM'ye göre Sahne-1 ve Sahne-2 'de %1, Sahne-3'te ise %8 oranında gelişme sağlamıştır.

HOFO özniteliğinin PCA ile kullanılmasıyla [49] elde edilen sonuçlar LECM-1'e göre yüksek başarıma sahiptir. Bu durum, PCA sınıflama yönteminin kullanımıyla ilgilidir.

Gerçek zamanlı çalışan ve görüntü bölümlemesine dayalı FSCB [26], LECM-1'i sadece üçüncü sahnede yaklaşık olarak %1 oranında geçmektedir. Sahne-1, Sahne-2'de önerilen yöntem sırasıyla %3 ve %4 oranında üstünlük sağlamaktadır.

Son kısımda ise hareket ve görünüm bilgisinden yararlanan CMA [13], sadece optik akıştan yararlanan OF [19] ve sosyal güç SF [19] ile yapılan karşılaştırmalar verilmiştir.

LECM-1, hareket ve görünüm bilgisini birlikte kullanan CMA [13] yaklaşımını sadece ilk sahnede geçmektedir. CMA [13] Sahne-2'de %5, Sahne-3'te %2 oranında daha başarılı sonuçlar üretmiştir.

Mehran ve diğerleri [19] çalışmalarında, her bir sahneye özgü sonuçları belirtmedikleri için genel sonuçlar çizelgeye eklenmiştir.

Yöntemler	Sahne-1	Sahne-2	Sahne-3
(Önerilen Yaklaşım) LECM-1	0.9990	0.9180	0.9667
(Önerilen Yaklaşım) LECM-2	0.9857	0.8790	0.9572
STCOG [25]	0.9362	0.7759	0.9661
SR [1]	0.995	0.975	0.964
MI [24]	0.995	0.853	0.98
HF [20]	0.953	0.913	0.964
HOFO+SVM [49]	0.9845	0.9037	0.9815
HOFO+PCA [49]	0.9992	0.9880	0.9989
MIDL [35]	0.8927	0.7541	0.9482
FSCB [26]	0.9641	0.8764	0.9750
CMA [13]	0.993	0.969	0.988
SF [19]	0.96		
OF [19]	0.84		

Çizelge 4.3 Önerilen yöntemlerin mevcut yöntemlerle ROC eğrileri altında kalan alanlara göre karşılaştırılması (LECM + OCSVM)

5 BULGULAR VE GELECEĞE YÖNELİK ÖNERİLER

Bu çalışmada iki farklı şekilde oluşturulan logaritmik kovaryans matrisleri ve MHOF öznitelikleri global anomali tespitinde kullanılmıştır. En iyi sonuçlar, görünüm ve hareket bilgisinin kovaryans matrisi ile birleştirilmesiyle elde edilmiştir. Hareket temsili için optik akış tabanlı kinematik öznitelikler, görünüm temsili için gradyan tabanlı öznitelikler seçilmiştir. Bu sayede anomali tespitini sadece hareket özniteliklerinden yararlanarak gerçekleştiren yaklaşımların aksine, görünüm ve hareket öznitelikleri beraberce ele alınmıştır.

Bu çalışma, iki önemli yeniliği bünyesinde barındırmaktadır. Birincisi, literatürde hareket tanıma amacıyla kullanılan kinematik öznitelikler, ilk defa anomali tespitinde kovaryans matrisi yardımıyla kullanılmıştır. İkinci yenilik ise, Riemannian manifoldunda bulunan kovaryans matrislerinin, logaritmik Öklid metriği yardımıyla Öklid düzlemine aktarılması ve böylece sınıflama işlemlerinde kullanılabilmesidir.

Logaritmik kovaryans öznitelikleri, tek sınıf sınıflandırıcı (OCSVM) ile etkili şekilde kullanılmıştır. Bu sayede yöntemin, literatürdeki karmaşık çalışmalardan farklı olarak basit ve efektif bir yapıya sahip olması sağlanmıştır. Ayrıca nesne tespiti, takibine dayalı bir çalışma olmadığı için kalabalık sahnelerde kullanımı uygundur ve anomali tespiti sırasında herhangi bir eşik değeri ayarı yapılmasına ihtiyaç duyulmamaktadır.

Anomali tespiti için tasarlanmış sistemlerde, normal olaylardan anormal olaylara geçiş anlarının doğru şekilde belirlenmesi ve anormal olaylarla ilgili gecikme yaşanmadan, ilgililere uyarı verilmesi büyük önem taşımaktadır. Bu anlamda, önerilen yaklaşım ile anormal durumların görülmeye başlandığı andan itibaren yüksek doğruluk oranıyla uyarı verilmesi sağlanmıştır. Ayrıca yöntem, normal ve anormal olaylar arasındaki sınır geçişini başarılı şekilde yapmaktadır.

Gelecekte, kovaryans matrislerinin görüntüler üzerinde yerel alanlardan elde edilmesi sağlanarak, önerilen yaklaşımın yerel anormal durumların gözlemlendiği sahnelerde kullanıma uygun hale getirilmesi amaçlanmaktadır.

Uygulanması planlanan bir diğer çalışma ise videolar üzerinde dikkat çeken bölgelerin (visual saliency) belirlenmesi ve bu bölgelerin anomali tespitinde kullanılmasıdır. Dikkat çeken bölgeler, bilgisayarlı görüde nesne tanıma, nesne sınıflandırma, ön plan bölümlenme, anomali tespiti gibi birçok uygulamada kullanılmaktadır. Anormal durumların sahnede farklı ve göze çarpan olaylar olma özelliği, dikkat çeken bölgeleri anomali tespitinde kullanıma

elveriřli hale getirmektedir. Dikkat eken blgeler ile anomali tespiti iin, ncelikle logaritmik kovaryans matrisleri, dikkat eken blgeleri belirlemek amacıyla kullanılabilir ve bu blgeler yardımı ile anormal durumlar tespit edilebilir.

Anormal durum tespiti, akıllı video tespiti sistemlerinin nemli bir bileřeni olarak gelecekte de ihtiya duyulacaktır. Gnmzde henz, gnlk hayatta pratik kullanıma dnřmř bařarılı anormal durum tespit sistemlerinin fazla olmadığı grlmektedir. Anormal durumun sahneye, baėlama baėlı olarak deėiřebilmesi, genel amalı bir sistem geliřtirmeyi zorlařtırmaktadır. Bu nedenle, gnmzde pratik uygulamaya gemiř sistemler daha ok zel birkaç durumun tespitine odaklanmıřtır. Gnlk hayatta karřılařılabilecek durumların eřitliliėi dřnldėnde, anormal durum tespiti iin gelecekte de kapsamlı alıřmalara ihtiya vardır.

KAYNAKLAR

- [1] Y. Cong, J. Yuan, and J. Liu, "Sparse reconstruction cost for abnormal event detection," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, **2011**, pp. 3449–3456.
- [2] X. Wang, X. Ma, and W. E. L. Grimson, "Unsupervised Activity Perception in Crowded and Complicated Scenes Using Hierarchical Bayesian Models," *IEEE Trans. Pattern Anal. Mach. Intell.*, **2009**.
- [3] B. Zhou, X. Wang, and X. Tang, "Understanding collective crowd behaviors: Learning a Mixture model of Dynamic pedestrian-Agents," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, **2012**.
- [4] R. Mehran, B. E. Moore, and M. Shah, "A Streakline Representation of Flow in Crowded Scenes," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 6313 LNCS, no. PART 3, **2010**, pp. 439–452.
- [5] Y. Benabbas, N. Ihaddadene, and C. Djeraba, "Motion pattern extraction and event detection for automatic visual surveillance," *Eurasip J. Image Video Process.*, vol. **2011**, pp. 1–15, 2011.
- [6] B. Krausz and C. Bauckhage, "Analyzing pedestrian behavior in crowds for automatic detection of congestions," in *Proceedings of the IEEE International Conference on Computer Vision*, **2011**, pp. 144–149.
- [7] B. Krausz and C. Bauckhage, "Loveparade 2010: Automatic video analysis of a crowd disaster," *Comput. Vis. Image Underst.*, **2012**.
- [8] T. Li, H. Chang, M. Wang, B. Ni, R. Hong, and S. Yan, "Crowded Scene Analysis: A Survey," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 25, no. 3, pp. 367–386, Mar. **2015**.
- [9] M. Hu, S. Ali, and M. Shah, "Learning motion patterns in crowded scenes using motion flow field," in *2008 19th International Conference on Pattern Recognition*, **2008**, pp. 1–5.
- [10] S. Wu, B. E. Moore, and M. Shah, "Chaotic invariants of Lagrangian particle trajectories for anomaly detection in crowded scenes," in *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, **2010**, pp. 2054–2060.
- [11] S. Ali and M. Shah, "A Lagrangian Particle Dynamics Approach for Crowd Flow Simulation and Stability Analysis," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, **2007**.
- [12] L. Kratz and K. Nishino, "Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models," in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, **2009**, pp. 1446–1453.
- [13] Y. Zhang, H. Lu, L. Zhang, and X. Ruan, "Combining motion and appearance cues for anomaly detection," *Pattern Recognit.*, vol. 51, pp. 443–452, **2016**.
- [14] C. Lu, J. Shi, and J. Jia, "Abnormal Event Detection at 150 FPS in MATLAB," *Comput. Vis. (ICCV), 2013 IEEE Int. Conf.*, pp. 2720–2727, **2013**.

- [15] Y. Cong, J. Yuan, and J. Liu, "Abnormal event detection in crowded scenes using sparse representation," *Pattern Recognit.*, vol. 46, no. 7, pp. 1851–1864, Jul. **2013**.
- [16] T. Wang and H. Snoussi, "Histograms of optical flow orientation for abnormal events detection," in *IEEE International Workshop on Performance Evaluation of Tracking and Surveillance, PETS*, **2013**, pp. 45–52.
- [17] H. Mousavi, S. Mohammadi, A. Perina, R. Chellali, and V. Mur, "Analyzing tracklets for the detection of abnormal crowd behavior," in *Proceedings - 2015 IEEE Winter Conference on Applications of Computer Vision, WACV 2015*, **2015**, pp. 148–155.
- [18] V. Vishwakarma, C. Mandal, and S. Sural, "Automatic Detection of Human Fall in Video," in *Pattern Recognition and Machine Intelligence*, Berlin, Heidelberg: Springer Berlin Heidelberg, **2007**, pp. 616–623.
- [19] R. Mehran, A. Oyama, and M. Shah, "Abnormal crowd behavior detection using social force model," in *2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, CVPR Workshops 2009*, **2009**, pp. 935–942.
- [20] M. Marsden, K. McGuinness, S. Little, and N. E. O'Connor, "Holistic features for real-time crowd behaviour anomaly detection," in *2016 IEEE International Conference on Image Processing (ICIP)*, **2016**, vol. 2016–August, pp. 918–922.
- [21] B. Zhou, X. Tang, H. Zhang, and X. Wang, "Measuring Crowd Collectiveness," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 8, pp. 1586–1599, Aug. **2014**.
- [22] J. Shao, C. C. Loy, and X. Wang, "Learning Scene-Independent Group Descriptors for Crowd Understanding," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 27, no. 6, pp. 1290–1303, Jun. **2017**.
- [23] J. Shao, C. C. Loy, and X. Wang, "Scene-Independent Group Profiling in Crowd," in *2014 IEEE Conference on Computer Vision and Pattern Recognition*, **2014**, pp. 2227–2234.
- [24] D. G. Lee, H. Il Suk, and S. W. Lee, "Crowd behavior representation using motion influence matrix for anomaly detection," in *Proceedings - 2nd IAPR Asian Conference on Pattern Recognition, ACPR 2013*, **2013**, pp. 110–114.
- [25] Y. Shi, Y. Gao, and R. Wang, "Real-Time Abnormal Event Detection in Complicated Scenes," in *2010 20th International Conference on Pattern Recognition*, **2010**, pp. 3653–3656.
- [26] A. Pennisi, D. D. Bloisi, and L. Iocchi, "Online real-time crowd behavior detection in video sequences," *Comput. Vis. Image Underst.*, vol. 144, pp. 166–176, **2016**.
- [27] V. Mahadevan, W. Li, V. Bhalodia, and N. Vasconcelos, "Anomaly detection in crowded scenes," *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, pp. 1975–1981, **2010**.
- [28] Weixin Li, V. Mahadevan, and N. Vasconcelos, "Anomaly Detection and Localization in Crowded Scenes," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 1, pp. 18–32, Jan. **2014**.
- [29] R. V. H. M. Colque, C. A. C. Junior, and W. R. Schwartz, "Histograms of Optical Flow Orientation and Magnitude to Detect Anomalous Events in Videos," in *2015 28th SIBGRAPI Conference on Graphics, Patterns and Images*, **2015**, vol. 2015–Octob, pp. 126–133.

- [30] V. Reddy, C. Sanderson, and B. C. Lovell, "Improved anomaly detection in crowded scenes via cell-based analysis of foreground speed, size and texture," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, **2011**.
- [31] D. Ryan, S. Denman, C. Fookes, and S. Sridharan, "Textures of optical flow for real-time anomaly detection in crowds," in *2011 8th IEEE International Conference on Advanced Video and Signal Based Surveillance, AVSS 2011*, **2011**, pp. 230–235.
- [32] S. Wang, E. Zhu, J. Yin, and F. Porikli, "Anomaly Detection in Crowded Scenes by SL-HOF Descriptor and Foreground Classification," pp. 3387–3392, **2016**.
- [33] X. Zhu, J. Liu, J. Wang, Y. Fang, and H. Lu, "Anomaly detection in crowded scene via appearance and dynamics joint modeling," in *2012 19th IEEE International Conference on Image Processing*, **2012**, pp. 2705–2708.
- [34] M. Sabokrou, M. Fathy, M. Hoseini, and R. Klette, "Real-time anomaly detection and localization in crowded scenes," *2015 IEEE Conf. Comput. Vis. Pattern Recognit. Work.*, pp. 56–62, **2015**.
- [35] J. Huo, Y. Gao, W. Yang, and H. Yin, "Abnormal Event Detection via Multi-Instance Dictionary Learning," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 7435 LNCS, **2012**, pp. 76–83.
- [36] J. . Xu, S. . Denman, S. . Sridharan, C. . Fookes, and R. . b Rana, "Dynamic Texture reconstruction from sparse codes for unusual event detection in crowded scenes," in *MM'11 - Proceedings of the 2011 ACM Multimedia Conference and Co-Located Workshops - JMRE 2011 Workshop, J-MRE'11*, **2011**, pp. 25–30.
- [37] Z. Zhu, J. Wang, and N. Yu, "Anomaly detection via 3D-HOF and fast double sparse representation," in *Proceedings - International Conference on Image Processing, ICIP*, **2016**, vol. 2016–August, pp. 286–290.
- [38] A. Del Giorno, J. A. Bagnell, M. Hebert, A. Del Giorno, J. Andrew Bagnell, and M. Hebert, "A discriminative framework for anomaly detection in large videos," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, **2016**, vol. 9909 LNCS, pp. 334–349.
- [39] B. K. P. Horn and B. G. Schunck, "Determining optical flow," *Artif. Intell.*, vol. 17, no. 1–3, pp. 185–203, Aug. **1981**.
- [40] "Unusual crowd activity dataset of University of Minnesota." [Online]. Available: http://mha.cs.umn.edu/proj_events.shtml#crowd. [Accessed: **31-May-2017**].
- [41] O. Tuzel, F. Porikli, and P. Meer, "Region Covariance: A Fast Descriptor for Detection and Classification," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 3952 LNCS, **2006**, pp. 589–600.
- [42] V. Arsigny, P. Fillard, X. Pennec, and N. Ayache, "Geometric Means in a Novel Vector Space Structure on Symmetric Positive-Definite Matrices," *SIAM J. Matrix Anal. Appl.*, vol. 29, no. 1, pp. 328–347, Jan. **2007**.
- [43] S. Ali and M. Shah, "Human action recognition in videos using kinematic features and multiple instance learning.," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 32, no.

- 2, pp. 288–303, Feb. **2010**.
- [44] Kai Guo, P. Ishwar, and J. Konrad, “Action Recognition From Video Using Feature Covariance Matrices,” *IEEE Trans. Image Process.*, vol. 22, no. 6, pp. 2479–2494, Jun. **2013**.
- [45] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, “Estimating the Support of a High-Dimensional Distribution,” *Neural Comput.*, vol. 13, no. 7, pp. 1443–1471, Jul. **2001**.
- [46] L. M. Manevitz, M. Yousef, N. Cristianini, J. Shawe-Taylor, and B. Williamson, “One-Class SVMs for Document Classification,” *J. Mach. Learn. Res.*, vol. 2, pp. 139–154, **2001**.
- [47] D. M. . Tax and R. P. . Duin, “Support vector domain description,” *Pattern Recognit. Lett.*, vol. 20, no. 11–13, pp. 1191–1199, Nov. **1999**.
- [48] T. Wang, “Abnormal Detection in Video Streams via One-class Learning Methods,” University of Technology of Troyes, **2014**.
- [49] T. Wang and H. Snoussi, “Detection of Abnormal Events via Optical Flow Feature Analysis,” *Sensors*, vol. 15, no. 4, pp. 7156–7171, Mar. **2015**.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Efsun Sefa SEZER

Doğum Yeri : Erzincan

Medeni Hali : Bekar

E-posta : efsun.sezer@hacettepe.edu.tr

Adresi : Hacettepe Üniversitesi Bilgisayar Mühendisliği Bölümü Beytepe/ANKARA

Eğitim

Lise : Adıyaman Lisesi

Lisans : Çukurova Üniversitesi

Yabancı Diller

İngilizce

İş Deneyimi

2014 – Halen : Hacettepe Üniversitesi Bilgisayar Mühendisliği Bölümü,
Araştırma Görevlisi

Deneyim Alanları

Görüntü İşleme, Bilgisayarlı Görü, Makine Öğrenmesi

Tezden Üretilmiş Projeler ve Bütçesi

Tezden Üretilmiş Yayınlar

Tezden Üretilmiş Tebliği ve/veya Poster Sunumu ile Katıldığı Toplantılar



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ

ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 07/07/2017

Tez Başlığı / Konusu: Kalabalık Gözetleme Ortamlarında
Anomali Tespiti

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam ...81... sayfalık kısmına ilişkin, 07/07/2017 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 3. 'tür.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Tarih ve İmza

Adı Soyadı: Efsun Sefa ŞEKER
Öğrenci No: 114120936
Anabilim Dalı: Bilgisayar Mühendisliği
Programı: Yüksek Lisans
Statüsü: Y.Lisans Doktora Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.

Doç. Dr. Ahmet Bural CAN
(Unvan, Ad Soyad, İmza)