



# **Kalabalık Ortam Video Gözetleme Uygulamalarında Anomali Tespiti**

**Program Kodu: 1001**

**Proje No: 112E141**

Proje Yürütücüsü:  
**Doç. Dr. Alptekin Temizel**

Araştırmacı:

Y.Doç. Dr. Tuğba Taşkaya Temizel

Bursiyerler:

Cihan Öngün

Ayşe Elvan Gündüz

Ferhat Kutlu

Figen Beken

KASIM 2014  
ANKARA



## Önsöz

Güvenlik kameralarının sayıları ve video gözetleme sistemlerinin kullanıldığı alanlar gün geçtikçe artmaktadır. Olağandışı olayların anında tespiti ve gerekli önlemlerin en kısa zamanda alınması özellikle insanların yoğun olduğu yerlerde önem arz etmektedir. Bu görüntülerinin operatörler tarafından 24/7 izlenerek takip edilmesi maliyet olarak yüksektir. Ayrıca operatörlerin tüm kameraları birlikte izleyerek olayları gerçek zamanlı değerlendirmesi artan kamera sayısı ile imkansız hale gelmiş ve gerektiğinde operatörleri uyaracak otomatik analiz sistemlerine ihtiyaç duyulmaya başlanmıştır. Halihazırdaki çoğu sistem kişilerin ayrı ayrı takibine dayanır ve kural bazlıdır. Bu nedenle kişilerin ayrı ayrı takip edilemediği kalabalık görüntülerinde yeterli başarıyı sağlayamamaktadır ve kullanıcıdan önceden aykırılık durumlarının tanımlanmasını gerektirmektedir. Bu projede güvenlik kameraları ile gözlemlenen kalabalık görüntüleri üzerinde güç algılanan aykırılıkları herhangi bir sabit kural kümesi kullanmadan otomatik olarak saptayan ve operatörleri uyaran akıllı bir çerçeve geliştirilmiştir. Geliştirilen çerçeve halihazırdaki veri kümelerinin yanı sıra proje kapsamında kayıt edilen kalabalık görüntüleri ve üretilen simülasyon verileri üzerinde test edilerek başarıyı gösterilmiştir.

Proje TÜBİTAK 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme programı kapsamında (proje no: 112E141) desteklenmiştir.

## İçindekiler

Özet	İv
Abstract	vi
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	1
3. GEREÇ VE YÖNTEM	9
3.1. Kalabalık Simülasyonlarının Hazırlanması	10
3.2. Kalabalık Videolarının Kaydedilmesi	12
3.3. Kalabalık Yoğunluğunun Tespiti ve Yoğunluğa Uygun Model Seçilmesi	13
3.4. Kalabalık Videolarında Bölgesel Davranışların Kümelenmesi	15
3.5. Davranışların Zaman-Uzamsal Modellenmesi ve Aykırılık Tespiti	24
3.6. Kaynaklar	29
4. BULGULAR VE TARTIŞMA/SONUÇ	31
Ekler	33

## Şekil Listesi

Şekil 1. Bölgesel davranışların kümelenmesi yöntemi için akış şeması	15
Şekil 2. Test videosundan örnek kareler.	16
Şekil 3. Test videosunun FTLE çıktıları.	17
Şekil 4. Anomali içeren kümelerin tespiti.	18
Şekil 5. Test videolarından örnek kareler.	19
Şekil 6. 2 farklı anomali bölgesini gösteren test videosundan alınan örnek kare	21
Şekil 7. Stadyum (ID#7) videosunda 10 tümleştirme sayısı için (a) kümeleme sonuçları, (b) anomali içeren kümeler	21
Şekil 8. Stadyum (ID#7) videosunda 1 tümleştirme sayısı için (a) kümeleme sonuçları, (b) anomali içeren kümeler.	23
Şekil 9. Fight videosu için anomali içeren kümeler (a) tümleştirme sayısı 1 için, (b) tümleştirme sayısı 10 için.	23
Şekil 10. Yöntem akış şeması.	24
Şekil 11. 3 zaman dilimi için açılmış, 5 zincirli CHMM.	26
Şekil 12. Literatürdeki Yöntemlerin ve Önerilen Yöntemin ROC Eğrisi Grafiği.	29

## Tablo Listesi

Tablo 1. Test videoları sonuçları.	19
Tablo 2. Küme sayısı, Küme Boyutu ve Ortalama Azami değerler.	22

## Özet

Video görüntüsünde belirgin nesnelere olduğunda, nesne-bazında izleme ve gösterim ile normal davranışlardan sapmalar hesaplanarak aykırılıklar tespit edilebilir. İzdiham durumlarında oluşan düzensiz hareketler, kavgalar, ani hareketlilikler ya da insanlar tarafından fırlatılan nesnelere aykırılıklara örnektir. Nesne sayısı az olduğunda nesnelere takip edilerek yörüngeleri ve hızları gibi özelliklerin değerlendirilmesi ile bu tip aykırılıkların tespitlerinin yapılması mümkündür. Fakat nesne sayısı arttığında olağandışı olayların tespiti oluşan kapatmalar ve yörünge kesikliklerinden dolayı nesne-bazında izleme ve gösterim ile güçtür. Ayrıca birden fazla nesnenin olduğu senaryolarda, nesne tabanlı gösterim öğrenmeyi ve çıkarım yapmayı güçleştiren karmaşık bir model yapısına yol açar.

Kalabalık görüntülerindeki aykırılık tespiti için yakın zamanda piksel tabanlı gösterim teknikleri kullanılmaya başlanmıştır. Bu tekniğe dayalı çözümler birçok nesnenin bulunduğu görüntülerde kabul edilebilir bir başarı vermektedir. Fakat hesaplama yükleri nedeniyle gerçek zamanlı sistemler için kullanılması güçtür. Ayrıca literatürdeki yöntemler zamana bağlı değişkenlik gösteren ortama bağlı aykırılıkları ele almamaktadırlar.

Bu projede uzam ve zamana göre değişkenlik gösteren aykırılık örüntülerini herhangi bir öncü kural kümesi kullanmadan öğrenip tespit edebilen piksel tabanlı analiz ve gösterim tekniklerine dayalı bir yöntem geliştirilmiştir. Önerilen yöntem kalabalık yoğunluğunun tespiti ve yoğunluğa uygun model seçilmesi, kalabalık videolarında bölgesel davranışların kümelenmesi, davranışların zaman-uzamsal modellenmesi ve aykırılık tespiti aşamalarından oluşur.

Bu çalışmada piksel tabanlı analiz ORB öznitelikleri kullanılarak yapılmıştır. Bu öznitelikler yardımı ile kalabalık yoğunluğuna göre sınıflandırma sağlanır ve uygun model seçilir. Bölgesel davranışların kümelenmesi için optik akış metodu ile hız ve yön bilgisi alınmasının ardından bu bilgiler Finite Time Lyapunov Exponents (FTLE) kullanılarak hız ve yöne bağlı olarak değerler tablosuna dönüştürülür ve bu tablo yardımıyla aykırılık gösteren bölgeler tespit edilebilir. Ayrıca farklı karakteristiğe sahip davranış bölgeleri Coupled Hidden Markov Model (CHMM) kullanılarak zaman-uzamsal olarak modellenir ve aykırılıkların tespiti sağlanır.

Önerilen yöntemler halihazırdaki mevcut açık veri kümelerinin yanı sıra proje kapsamında kayıt edilen gerçek video görüntülerinde ve oluşturulan simulasyon verileri üzerinde ve denenerek sonuçlar referans bilgileri ile karşılaştırılmıştır.



## **Abstract**

Object-based tracking and representation techniques can be used to detect anomalies by detecting the deviations from the normal behavior when there are distinctly visible objects in the video scene. When the number of objects is few, anomalies can be detected by tracking objects. But when the number of objects to be tracked increases, detection of events becomes problematic due to occlusions. Furthermore, when there is high number of objects, object-based representation results in a complex model that results in difficulties in learning and inference.

Recently, for anomaly detection in crowd videos, pixel-based techniques have started to be used. But, due to their high computational complexity, these techniques can not be used in real-time applications. Also, the methods in the literature do not take time and context dependent anomalies into account.

In this project, a method based on pixel based analysis and representation techniques that can learn and detect spatio-temporal anomalies without any prior ruleset has been developed. Proposed method consists of: detection of crowd density and choosing the appropriate model based on detected density, clustering of local behavior in crowd videos, spatio-temporal modelling of the behaviors and anomaly detection.

Pixel based analysis is done by using ORB features, crowd is classified according to its density and an appropriate model is selected. For modelling the local behavior, after obtaining the velocity and direction information, this information is transformed using Finite Time Lyapunov Exponents (FTLE) and the anomalous locations can be detected. Areas with different behavioral characteristics are modelled with Coupled Hidden Markov Model (CHMM) and anomalies are detected.

Proposed methods have been tested on open datasets as well as on recorded video and simulation datasets. The results have been compared to those into the literature.

## 1. GİRİŞ

Kalabalık gözetleme sistemlerinde, aykırılık tespiti algoritmalarının videonun özellikleri dikkate alınarak çalıştırılması önemlidir. Algoritmaların uygun seçilmemesi, başarıyı düşürmekte ve yanlış uyarıların üretilmesi ile sonuçlanabilmektedir. Kalabalık yoğunluğunun az olduğu ve kişilerin tespit ve takibinin mümkün olduğu durumlarda tespit ve takip temelli algoritmaların çalıştırılması uygunken yoğunluğun fazla olduğu durumlarda bütüncül algoritmaların kullanılması tercih edilmektedir. Bu çalışmada kişilerin ayrı ayrı tespit ve takibinin güç olduğu kalabalık videolarında aykırılıkların tespiti için bütüncül bir yaklaşım önerilmektedir. Kalabalık içerisinde gözlemlenebilecek aykırılıklara bir grubun koşması, kavgalar ve insanların birbirine yabancı nesnelere fırlatması örnek olarak verilebilir.

Projenin amacı kalabalık videolarının farklı bölgelerinde gözlemlenen aykırı davranışları kümelendirmek ve bu bölgelerde aykırılık tespitini önceden belirlenmiş kurallar gerektirmeden yapabilecek bir yöntem ortaya koymaktır.

Proje faaliyetleri temel olarak literatür taraması, kalabalık videolarının kaydedilmesi, kalabalık simülasyonlarının hazırlanması, kalabalık yoğunluğu tespiti, kalabalık davranışlarının uzamsal kümelmesi ve yenilikçi aykırılık tespiti yöntemlerinin geliştirilmesi ve geliştirilmiş olan yöntemlerin deneysel olarak doğrulanmasından oluşur.

## 2. LİTERATÜR ÖZETİ





Anomali, veri içerisinde normal davranışa uymayan desen olarak tanımlanır. Olağandışılık belirlemesi yasa dışı işlemlerin belirlenmesi, yaşlı bakımı, video gözetleme gibi birçok uygulama alanında uzun süredir üzerinde çalışılmakta olan bir konudur (Loy vd., 2011). Olağandışı olayların belirlenmesi için birçok farklı teknik kullanılmaktadır. Bu teknikler, sınıflandırma tabanlı, kümeleme tabanlı, en yakın komşuluk tabanlı, görüngenel (spectral) ve istatistiksel yöntemler olarak gruplanabilir. Uygulanacak yöntem araştırılan anomalinin türüne bağlıdır. Anomaliler bir gözlemin verinin kalanına göre olağandışı yani aykırı gözlem olması durumunda noktasal anomali, sadece belirli bir bağlam içinde incelendiğinde olağandışı olup aksi durumda normal olması durumunda bağlamsal anomali, gözlemler bireysel olarak normal olabileceği halde biraraya geldiklerinde verinin kalanına göre olağandışı olması durumunda kolektif anomali olarak nitelendirilebilir. Sınıflandırma tabanlı yöntemde, işaretlenmiş eğitim verisi kullanılarak sınıflandırıcı eğitilir ve bir test verisi geldiğinde, bu sınıflayıcı kullanılarak veri normal veya olağandışı olarak sınıflandırılır. Kümeleme tabanlı yöntemde, verinin herhangi bir kümeye girmemesi, herhangi bir kümeye dahil edilmesine rağmen küme merkezine uzak olması ya da dahil olduğu kümenin boyutunun veya yoğunluğunun küçük olmasına göre anomali belirlenir. En yakın komşuluk tabanlı yöntemlerde, bir benzerlik veya uzaklık ölçütü kullanılarak verinin en yakın komşuluğuna olan uzaklığı ölçülerek anomaliler belirlenir. Görüngenel yöntemde, veri normal ve olağandışı olayların birbirinden önemli ölçüde farklılaşacağı bir alt uzaya gömülür. Son olarak istatistiksel yöntemde, veriye istatistiksel bir model uyarlanır ve yeni gelen verinin bu dağılım tarafından yaratılmış olması olasılığının düşük olması durumunda bu veri anomali olarak belirlenir. İstatistiksel yöntemler parametrik ve parametrik olmayan (non-parametric) olmak üzere ikiye ayrılır. Parametrik yöntemler verinin temel dağılımını bildiğini kabul edip parametreleri verilen veriden tahmin ederken, parametrik olmayan yöntemler verinin temel dağılımını bildiğini farzetmez (Chandola vd., 2009).



Video verisinde farklı türlerde anomaliler oluşabilir. Tek bir nesnenin davranışındaki olağandışılık genelde o nesnenin yörüngesi, hızı gibi özneliklerinin olağan davranıştan sapmasıyla ortaya çıkar. Örneğin, bir nesnenin normalden hızlı hareketi veya daha önce gözlemlenmemiş bir yörünge izlemesi bir anomalidir. İlkel davranışların birleşmesiyle oluşan karmaşık davranışların sergilendiği durumlarda ise bu ilkel aktivitelerin sıralamasından veya sürelerinden kaynaklanan anomaliler ortaya çıkabilir. Buna örnek olarak bir mağazada ödeme yapmak ve mağazadan çıkmak olağan senaryosunun dışında bir gözlem (ödeme yapmadan çıkmak gibi) anomali olmaktadır. Ayrıca, çok nesneli ortamlarda, ortamlardaki nesnelerin bireysel davranışları normal olsa bile, bu nesnelerin birbirleri ile olan etkileşimleri olağandışılığa yol açabilir. Örneğin imgenin yatay ve dikey düzleminde trafiğin birarada gözlenmediği bir ortamda, trafik senaryosunda yatay trafik gözlenirken, aynı anda dikey yönden de trafik akışı olması olağandışı bir olay olacaktır. Kalabalık ortam sözkonusu olduğunda ise, hem kalabalık içi davranış hem de kalabalığın bir bütün olarak davranışı olağandışı olabilir. Örneğin, kalabalık içerisindeki nesneler arasındaki normalden farklı bir etkileşim olması veya kalabalığın hızının normalden fazla olması anomali olarak nitelendirilebilir.

Kalabalık için anomali tespitinde en sık kullanılan yöntemlerden biri istatistiksel analizdir. Ali ve Shah (2007) önce Lagranj Uyumlu Yapılar (Lagrangian Coherent Structures(LCS)) yöntemini kullanarak sahnedeki gezingeleri çıkarmış ve bu gezingelerden bazı bilgiler elde etmeye çalışmıştır. Uyumlu yapılar kalabalık tarafından yaratılan akış alanları olarak tanımlanmaktadır ve bir sahnedeki farklı kalabalıkların sınırlarıyla eşleşmektedir. Sonra kalabalığı farklı akış bölütlerine (segment) ayırmak için, normalleştirilmiş kesikler (normalized cuts) algoritmasını kullanmışlardır. Yöntemlerinde, anomalileri bulmak için iki ardışık video karesindeki akış bölüt sayısını karşılaştırmışlardır. Yeni bulunan bir akış anomali olarak nitelendirilmektedir. Test kümesi olarak ilk olarak Getty-Images ve Video Google'dan elde edilen gerçek videolar kullanılmıştır. İkinci kullandıkları veri kümeleri National Geographic belgeselinden alınan görüntülerdir. Fakat başarılı tespitler gerçekleştirdiklerini belirtmelerine rağmen yöntemlerinde bazı problemler bulunmaktadır. Sadece farklı akışlara bakarak yapılan bir anomali tespiti yeterli olmayabilir. Kalabalığın hızı, yoğunluğu gibi bilgiler de daha doğru bir davranış analizi için çıkarılması gereken bilgilerdendir. Başka bir istatistiksel tabanlı yöntemi Dee ve Caplier (2010) gerçekleştirmiştir. Bu çalışmada, hareket yönünün histogramı (histogram of motion direction (HMD)) yöntemini baz alarak bir davranış model algoritması uygulamışlardır. Kanade-Lucas-Tomasi (KLT) özellik izleyicisini kullanarak sahnedeki özellikleri izlemişlerdir. Daha sonra her gezinge parçacığını (tracklet), HMD'yi oluşturmak için 8 yönden birine (yukarı, sağ, sol, ...) nicelendirmişlerdir. Bu HMD aracılığı ile zamansal anomaliyi tespit etmişlerdir. Testlerde PETS2009 veri kümesini kullanmışlardır. Genel olarak olağandışı olayları tespitte tatminkar sonuçlar elde etmişlerdir. Kendilerinin ifade ettiğine göre yöntemlerinin kısıtlayıcı yönü hareketin bir sahnede sürekli olduğunu farzetmektir. Bu da normalde anomali sayılmayacak bazı olayları normal dışı olaylar sayarak yanlış alarmlara sebebiyet vermektedir. Histogram tabanlı başka bir çalışmayı Adam vd. (2008) gerçekleştirmiştir. Bu çalışmada da yine zamansal anomali tespiti yapılmıştır. Yazarlar, görüntüdeki izlenimleri modellemek için çoklu yerel monitörler kullanmışlardır. Monitörler hız gibi yerel düşük düzeyli ölçümlerin elde edildiği nesnelere olarak tanımlanmıştır ve her monitörün gözlemlerini sakladığı bir olaylar tampon belleği (buffer) vardır. Bu bellekte bir olaylar histogramı yaratılmaktadır. Eğer yeni gelen izlenimin olasılığı düşük ise sistem alarm vermektedir. Test sonuçlarına göre normal olmayan olayların tespit oranı yüksek iken yanlış alarmların tespit oranı düşüktür. Yöntemin dezavantajı olarak çoklu monitör kullanımı sayılabilir. Çoklu monitör kullanımı hem saklanacak bilgi için gereken yer açısından hem de o monitörlerden gelen bilgileri işlemenin hızı etkilemesi açısından dezavantaja dönüşebilir. Veri kümeleri Dee ve Hogg (2004)'un kullandığı kümedir. Garate ve



diğerleri (2009) de olayları histogram tabanlı bir yöntem kullanarak modellemeyi ve zamansal anomalileri tespit etmeyi hedeflemişlerdir. Bu makalede, PETS veri kümesini üzerinden olayları tespit etmek için özellik noktalarını takip eden gradyanın histogramı (histogram of gradient (HOG)) tanımlayıcısını kullanmışlardır. Özellik noktalarını tespit etmek için FAST yöntemini kullanmışlardır. HOG yöntemi obje takibi için değil, video kareleri arasında özellik noktalarını takip ederek kalabalığın hızı ve yönü gibi bilgileri elde etmek için tercih edilmiştir. Belirli bazı olayları tespit etmek için hız ya da yön üzerinde bazı eşik değerleri belirlemişlerdir. Belirli bir eşik değeri belirlemek, yöntemleri için önemli bir noktadır. Bu nedenle, eşik değerinden dolayı test sırasında bazı yanlış sınıflandırmalar elde etmişlerdir

Literatürde diğer çok kullanılan anomali tespit yöntemi de sınıflandırmaya yönelik metotlardır. Kratz ve Nishino (2009) Saklı Markov Modeli (Hidden Markov Model (HMM)) yöntemini kullanarak zamansal ve uzaysal anomalileri tespit etmişlerdir. Bu çalışmada, yerel uzay-zaman birimlerinde hareket varyasyonları ve uzaysal-zamansal istatistiksel davranışları modellenerek bu sayede bir görüntüdeki tüm davranışlar nitelendirilmiştir. Her küboid 3 boyutlu Gaus dağılım olarak modellenmiştir. Yerel uzaysal-zamansal hareket örüntülerini birbirlerinden ayırmak için Kullback-Leibler (KL) kullanılmıştır. KL sayesinde hareketler arasında kurulan ilişki HMM'e girdi olarak verilmektedir. Veri kümesi olarak Adam vd. (2008)'in kullandığı metro istasyonu görüntülerinden yararlanılmıştır. Eğitim veri kümesinde bulunmayan hafifçe düzensiz hareket örüntüleri nedeniyle testlerinde bazı yanlış pozitif sonuçlar elde etmişlerdir. Eğitim için kullandıkları veri kümesi sınırlı olduğundan anomali tespitinde başarısız olmuşlardır. Kim ve Grauman (2009) ise başka bir sınıflandırma yöntemi olan Markov Rastlantısal Alan (Markov Random Field(MRF)) yöntemi ile zamansal anomalileri tespit etmiştir. Bu çalışmada da yine Adam vd. (2008) veri kümesi kullanılmıştır. Görüntü özelliklerini, MPPCA aracılığı ile optik akışı hesaplayarak elde etmişlerdir. Her yeni optik akış için, normallik derecesininin Maksimum Aposteriori (Maximum A Posteriori (MAP))'sini hesaplamak için öğrenilen modeli ve MRF'yi kullanmışlardır. Yöntemleri kalabalık videosunda atomik olayların yerini tespit etmekle kalmamaktadır, aynı zamanda yerel aktiviteler arasındaki düzensiz etkileşimler sonucu oluşan global düzeydeki anomalileri de yakalamaktadır. Fakat yine bu çalışmada da modelin denendiği veri kümesi sınırlıdır. Mehran vd. (2009) de sınıflandırma yöntemini de kullanmışlardır. Kelime torbası ("Bag of words") modelinden girdilerini alan Gizli Dirichlet Tahsisi (Latent Dirichlet Allocation (LDA)) kullanılarak zamansal anomaliler tespit edilmeye çalışılmıştır. Bu çalışmada bir görüntüdeki aktiviteleri anlamak için Sosyal Kuvvet Modeli (Social Force Model (SF)) kullanılmıştır. SF bir kalabalıktaki yan yana yayaların birbirlerine etkilerini ve bireylerin hareket çevresini yakalamak için kullanılmaktadır. Kalabalıktaki etkileşim kuvvetlerini anlamak için hareket eden parçacıklar arasındaki sosyal kuvvet hesaplanmaktadır. Elde edilen kuvvet modelleri normal olayları kelime torbası yöntemi ile modellemek için kullanılmaktadır. LDA, oluşturulan kelime torbası modellerini eğitmede kullanılmaktadır. LDA aracılığı ile bir akışın olasılığı hesaplanır. Olasılığı düşük çıkan akışlar anomali olarak sınıflandırılır. Yöntemleri etkili olmasına rağmen, gerçek zamanlı olarak uygulanabilirliği konusunda bir görüş belirtilmemiştir. Veri kümesi olarak Minnesota Üniversitesinin veri kümesi kullanılmıştır (UMN). Sınıflandırma yöntemi ile zamansal anomalileri tespit etmeye çalışan bir başka yöntem ise Wang vd. (2007)'de görülmektedir. Bu

çalışmada, yazarlar düşük seviyeli görsel özellikler, basit “atomik” hareketler ve çok etmenli etkileşimler olmak üzere üç elementi birleştiren hiyerarşik bir model tasarlamışlardır. “Atomik” olayları modellerken düşük düzeyli görsel özellikler kullanılmıştır. Etkileşimler ise “atomik” olaylar üzerindeki dağılım olarak modellenmiştir. Denetlenen(supervised) metotları kullanmaksızın cisim etkileşimlerini modelleyerek bazı iyileştirmeler yapılmıştır. Sistemin dezavantajı olarak, önce düşük seviyeli özellikleri çıkarıp bunlardan daha yüksek seviyeli atomik ve çok etkileşimli olaylar yaratma sürecinin sistemin gerçek zamanlı çalışmasını engelleyebilir olması sayılabilir. Ryan vd. (2011) Gaus Karışım Modelleri (Gaussian Mixture Model(GMM) tabanlı bir zamansal anomali analizi yöntemi uygulamışlardır. Bu çalışmada veri kümesi olarak California Üniversitesi, San Diego (UCSD) veri kümesini kullanmışlardır. Homojenlik, kontrast gibi uzaysal-zamansal özellikleri çıkarmak için 3 boyutlu Gri Seviyesi Birlikteliği Matrisi (Grey Level Co-Occurrence Matrix(GLCM)) hesaplamışlardır. Bu GLCM yapıları kullanılarak, normal davranışların GMMleri oluşturulmuştur. Bu modele aykırı değerleri anomali olarak sınıflandırmışlardır. Yöntemlerini Dinamik Desen Karışımı (Mixture of Dynamic Textures(MDT)), Olasılık Asıl Parça Çözümleyici Karışımı (Mixture of Probabilistic Principal Component Analyzer(MPPCA)), SF-MPPCA (Adam vd., 2008) ile karşılaştırmışlardır. Kendi metotları ile karşılaştırdıkları metotlardan daha düşük yanlış olay tespit oranı elde etmişlerdir. Fakat, kullandıkları veri kümesi çok sınırlıdır. Literatürde, bahsettiğimiz sadece zamansal anomalileri tespit eden yöntemler dışında hem zamansal hem uzaysal anomalileri tespit eden yöntemler de bulunmaktadır. Mahadevan vd. (2010) zamansal normalliği MDT kullanarak modellemiştir. Görüntüdeki her bölge için bir MDT öğrenilmiştir. Daha sonra test aşamasında, MDT kullanılarak ölçülen log-olabilirliğinden (log-likelihoodlar) düşük olasılığı olan olaylar anomali olarak nitelenmiştir. Uzaysal normallik MDT tabanlı ayırıcı çıkıntı (saliency) kullanılarak tespit edilmiştir. Yöntemleri en gelişmiş yöntemlerle karşılaştırılmıştır. Olay tespit oranları ve anomali olayların yerini doğru tespit oranı diğer yöntemlerden daha yüksektir. Sistemin kısıtlayıcı yönü zamansal ve uzamsal olayları tespit eden iki farklı yöntem kullanarak sistemin gerçek zamanlı çalışmasını engelleme sayılabilir.

Başka bir anomali tespit yöntemi de kümeleme yöntemi tabanlı yöntemlerdir. Sharif vd. (2010) yöntemlerinde zamansal anomalileri bulmayı hedeflemişlerdir. Hareket Sıcaklık Haritası (Motion Heat Map) kullanarak ilk önce ilgi bölgesini (region of interest) tespit etmişlerdir. Sonra GMM kullanılarak ön plan çıkarımı yapmışlardır. İlgi alanının tahmini için Harris köşe tespit edicisini kullanmışlardır. Piramidal KLT izleyici uygulamasını kullanarak özellik noktalarını takip etmişlerdir. İlgi alanları üzerine K-ortalama (K-means) kümelemesi uygulamışlardır. Video kareleri arasındaki kümeler arasında Bhattacharyya uzaklığını hesaplamışlardır. Anomali olaylar bu uzaklığa konulan eşik değeri ile tespit edilmiştir. Her iki veri kümesinde de anomali olayları başarılı bir şekilde tespit etmişlerdir. Bu yöntemdeki temel problem önerilen metodun eşik değerine bağlı olması bundan dolayı eşik değerinin hatalı belirtilmesinde yanlış alarm oranını artırma olasılığıdır. Diğer bir kümeleme yöntemini kullanan ve zamansal anomalileri tespit eden çalışma Chiu ve Tsai (2010)'nin çalışmasıdır. Aynı zamanda düzensizlik (entropy) çıkarımı gibi bilgi teorisine dahil yöntemler de kullanıldığı için, kullandıkları yöntem bilgi teorisi anomali tespit yöntemlerine de dahil edilebilir. Bu çalışmada kendi laboratuvarlarında çekilen görüntüleri ve BEHAVE benchmark veri kümesinden alınan videoları kullanmışlardır. Kullandıkları Makro-gözlem (Macro-observation) yöntemi bir görüntü sırasının zamansal-uzaysal temsili olarak tanımlanabilir. Yöntemlerinde ilk önce enerji haritası kullanarak ön plan objelerini çıkarmışlardır. Enerji haritasının şekli ve haritadaki her pikselin hareket gücü tek bir kişinin ya da birden çok kişinin çevre ile zamansal-uzaysal etkileşimi hakkında bilgi vermektedir. Her yeni görüntü için bu enerji haritalarından ayırıcı değişmez moment ve düzensizlik gibi özellikler çıkarılır. Eğitim sırasında, benzer enerji haritalarını aynı gruplara kümelemek için hiyerarşik kümeleme kullanmışlardır. Daha sonra her hiyerarşi seviyesi için bulanık C-ortalama (fuzzy C-means) kümeleme yöntemini kullanmışlardır. Anomalileri tespit etmek için, elde edilen her küme için merkeze uzaklık eşik değeri hesaplamışlardır. Böylece, yeni gelen görüntünün özellik vektörünün küme merkezine uzaklığı eşik değerinden yüksekse, bu görüntüdeki olaylar anomali olarak nitelendirilir. Testler sırasında özellik vektörü veri kümesine Asıl Parça Analizi (Principal Component Analysis (PCA)) de uygulamışlardır. Fakat tüm özellik vektörlerini kullanmak PCA'dan daha iyi sonuç vermiştir. Eşik değerinin elle belirlenmesi gerektiğinden her farklı bölge için metodun doğru bir şekilde uygulanmasını güçleştirmektedir. Yanlış belirlenmesi hatalı tespit oranını artırabilir.



En yakın komşuluk temelli yaklaşımları benimseyerek anomali tespiti için kullanan bir çalışma Seidenari vd. (2010)'nin çalışmasıdır. Bu çalışmada video sekanslarını zamansal-uzaysal birimlere bölmüşlerdir. Her birim üç boyutlu imgeciklerin luminans değerlerini kullanarak hesaplanmış gradyana bağlı tanımlayıcılar kullanılarak temsil edilmiştir. Her birim 18 hücreye bölünmektedir. Anomali olay tespiti için en yakın komşu (nearest-neighbor) algoritması kullanılmıştır. Bu yaklaşımda eğitim veri kümesinde komşusu olmayan olay örüntüsü anomali olay olarak kabul edilmektedir. Testler sırasında yöntemi en gelişmiş yöntemlerle karşılaştırmışlardır ve kendi yöntemleri Mahadevan vd. (2010)'nin sunduğu yöntemden sonra ikinci en iyi sonucu veren yöntem olduğunu belirtmişlerdir. Fakat Mahadevan vd. (2010)'nin yöntemi gerçek zamanlı çalışabilecek bir yöntem değilken kendi yöntemleri gerçek zamanlı çalışabilen bir yöntemdir. Yöntemlerinin bir kısıtlayıcı yönü, metotları bir kalabalığın içindeki anomali davranışları bulmaktan çok, yayaların içinden araba, bisiklet geçmesi gibi anomalileri tespit üzerine kurulmuş bir sistemdir. Bu yüzden, bina içinde oluşabilecek anomalileri (sadece insanların birbirleriyle etkileşimde bulunduğu ortamlarda) tespit için uygun bir yöntem değildir.

Literatüre genel olarak bakıldığında nesne takibine dayalı yöntemlerin uzun süreli gözlemlerde ve kalabalık içeren ortamlarda yetersiz olduğu görülmektedir (Adam vd., 2008). Literatürde, kalabalık davranış analizi alanında kullanılan yöntemler bütüncül ve obje tabanlı olmak üzere ikiye ayrılmaktadır (Cezar vd., 2010). Objeye tabanlı yaklaşımlar, sahnedeki her bir kişinin gezingesini çıkarır ve bu gezingelerden kalabalığın davranışını anlamaya çalışır. Bütüncül yaklaşımlarda ise kalabalık tek bir eleman olarak düşünülür ve bu tek varlık (entity) takip edilip analiz edilir. Bu projede bütüncül yaklaşım kullanılmıştır. Objeye tabanlı yaklaşımlarla aşırı yoğunluktaki kalabalıklarda kişilerin gezingesini çıkarmak örtüşmelerden (occlusion) dolayı zor olduğu için, kalabalık içeren görüntülerde yeterli performans elde edilemediği literatürde belirtilmesinin yanısıra daha önceki çalışmalarımızda da gözlemlenmiştir. Ayrıca kalabalık analizinde her objenin gezingesinden çok, genel kalabalığın akışı bizim için yeterli bir bilgidir.

#### Kaynaklar

Adam, A., Rivlin, E., Shimshoni, I., Reinitz D. 2008. "Robust Real-Time Unusual Event Detection Using Multiple Fixed-Location Monitors", Pattern Analysis and Machine Intelligence, 30, 3, 555-60.

Ali, S., Shah, M. 2007. "A Lagrangian Particle Dynamics Approach for Crowd Flow Segmentation and Stability Analysis", Computer Vision and Pattern Recognition, Minneapolis, 1-6.





Cezar, J., Jacques, S., Musse, S.R.2010. "Crowd Analysis Using Computer Vision Techniques", IEEE Signal Processing Magazine, 27, 66-77.

Chandola, V., Banerjee, A., Kumar, V. 2009. "Anomaly detection : a survey, ACM Computing Surveys", 41, 3, 1-72.

Chiu, W., Tsai, D. 2010. "A Macro-Observation Scheme for Abnormal Event Detection in Daily-Life Video Sequences", EURASIP J. Adv. Signal Process, 1-19.

Dee, H. M., Caplier, A. 2010. "Crowd Behaviour Analysis Using Histograms Of Motion Direction", 17th International Conference on Image Processing, 1545-1548.

Dee, H. M., Hogg, D. 2004. "Detecting Inexplicable Behaviour", Proceedings of British Machine Vision Conference.

Garate, C., Bilinsky, P, Bremond, F. 2009. "Crowd Event Recognition Using HOG Tracker", Performance Evaluation of Tracking and Surveillance (PETS-Winter), 2009 Twelfth IEEE International Workshop on, Snowbird - ABD, 1-6.

Kim, J., Grauman, K. 2009. "Observe locally, Infer Globally: A Space-Time MRF For Detecting Abnormal Activities With Incremental Updates", Computer Vision and Pattern Recognition, IEEE Conference on, Miami, 1063-6919.

Kratz, L., Nishino, K. 2009. "Anomaly Detection in Extremely Crowded Scenes Using Spatio-Temporal Motion Pattern Models", Computer Vision and Pattern recognition, Miami-ABD, 1446-1453.

Loy, C.C., Xiang, T., Gong, S. 2011. "Detecting and discriminating behavioural anomalies", Pattern Recognition, 44, 1, 117-132,.

Mahadevan, V., Weixin, L., Bhalodia, V., Vasconcelos, N. 2010. "Anomaly detection in crowded scenes", Computer Vision and Pattern Recognition (CVPR), IEEE Conference on, San Francisco, 1063-6919.

Mehran, R., Oyama, A., Shah, M. 2009. "Abnormal Crowd Behavior Detection Using Social Force Model", Computer Vision and Pattern recognition, 935-942.

Ryan, D., Denman, S., Fookes, C., Sridharan, S. 2011. "Texture of Optical Flow for Real-time Anomaly Detection in Crowds", Advanced Video and Signal-Based Surveillance (AVSS), 8th IEEE International Conference on, Klagenfurt, 230-235.

Seidenari, L., Bertini, M., Del Bimbo, A. 2010. "Dense Spatio-Temporal Features For Non-Parametric Anomaly Detection and Localization", Proceedings of The First ACM International Workshop on Analysis and Retrieval of Tracked Events and Motion in Imagery Streams (ARTEMIS '10), New York, 27-32.

Sharif, H., Sahin U, Chabane, D. 2010. "Crowd Behavior Surveillance Using Bhattacharyya Distance Metric", Lecture Notes in Computer Science, 6026, 311-323.

Wang, X., Ma X., Grimson, W.E.L. 2007. "Unsupervised Activity Perception in Crowded And Complicated Scenes Using Hierarchical Bayesian Models", Pattern Analysis and Machine Intelligence, 31, 3, 539-55.

### 3. GEREÇ VE YÖNTEM

Projede faaliyetleri temel olarak ihtiyaç duyulan gereçlerin hazırlanması ve yöntemlerin geliştirilmesi olarak ikiye ayrılabilir.

Projede öncelikle gereç olarak ihtiyaç duyulan veri kümelerinin oluşturulması için çalışılmıştır. Bu faaliyetler aşağıdaki gibidir:

- Uygun senaryoların belirlenerek kalabalık simülasyonlarının hazırlanması.
- Farklı ortam koşullarında amaca yönelik kalabalık videolarının kaydedilmesi.

Veri kümesinin oluşturulmasının ardından araştırma ve yöntemlerin geliştirilmesi aşamalarına geçilmiştir. Projede yapılan araştırma çalışmaları ve geliştirilen yöntemler aşağıda özetlenmiştir:

- Kalabalık yoğunluğunun tespiti ve yoğunluğa uygun model seçilmesi.
- Kalabalık videolarında bölgesel davranışların kümelenebilmesi.
- Davranışların zaman-uzamsal modellenmesi ve aykırılık tespiti.

Yukarıda bahsedilen faaliyetler ve yöntemler aşağıda detaylandırılmıştır.

#### 3.1. Kalabalık Simülasyonlarının Hazırlanması



Simülasyonların hazırlanması için Unity 3D kullanılmıştır. Unity 3D, içinde gerekli grafik ve gerçekçi fizik araçlarını bulunduran bir oyun ve simülasyon yapma programıdır. Bu sayede grafiksel kısmın ve gerekli fizik kurallarının tekrar tanımlanmasına ve programlanmasına gerek kalmamıştır. Bu projede Unity 3D'nin Pro sürümü kullanılmıştır. Sebebi; Pro sürümünün simülasyon yapımı için gerekli olan yapay zeka kısmını içermesi ve simülasyonlar için teknik desteği vermesidir.

Temelde Unity 3D, objeler ve script'ler üzerine dayanmaktadır. Objeler simülasyondaki gözle görülen veya görülmeyen grafiksel birimlerdir, script'ler ise, bu objelerin hareket,davranış, komut alma, verme vb. İşlemlerini tanımlayan kod kısımlarıdır. Unity standart olarak C# script, JavaScript ve Boo script ile kodlanabilmektedir. Bu projedeki simülasyonlar için C# script kullanılmıştır. C# script, syntax olarak C# ile aynı olup, gerekli fonksiyonların ve değerlerin Unity tarafından sağlanmış olduğu script dilidir. Kullanımı daha kolay ve anlaşılır olması, internette yeterince kaynak döküman bulunabilmesi sebebi ile C# script seçilmiştir.

Simülasyonlar için gerekli figürlerin ve animasyonların hazırlanması, hem çok uzun süreceği hem de gerçekçi olması açısından profesyonel bir çalışma gerektireceği için bu figürler ve animasyonlar gerekli piyasa araştırması yapıldıktan sonra hazır paket halinde satın alınmıştır. Satın alınan paket "3DRT Realpeople males + females collection" dir. Erkek ve kadın paketlerinin her birinde, 3 grafiksel model ve 20 adet texture (doku) bulunmaktadır. Toplamda 120 değişik insan figürü elde edilebilmektedir. Bu da simülasyonlardaki, insan çeşitliliği bakımından yeterlidir.

Simülasyonlarda gerekli olan diğer elemanlar, sahne ve ortamlar, insanların taşıdığı diğer eşyalar (şemsiye, çanta, balon vb.) ya proje çalışanları tarafından Unity ile uyumlu değişik modelleme programlarında modellenmiş ya da internetten ücretsiz modeller bulunmuştur. Bu eşyaların ve texture'ların (doku) kullanımı ve taşınması tamamen rastgele olacak şekilde programlanmıştır. Bu rastgelelik oranı, simülasyonun geçtiği ortama göre gerçekçi olacak şekilde ayarlanmıştır. Örneğin; yağmurlu bir ortam için yapılan simülasyonda, insanların şemsiye taşıma oranı diğerlerine göre yüksektir.

Unity 3D Pro yapay zeka ve yön bulma algoritmaları için "Navigation Mesh" tekniği kullanılmaktadır. "Navigation Mesh", sanal karakterlerin üzerinde yürüyebileceği yüzeyleri belirlemektedir. Karakterlerin yürüme hızları, diğer



karakterlerle arasındaki mesafe farkı, yürüyüş sırasında çarpışmaya yönelik davranışları vb. yapay zeka değerleri değiştirilerek istenilen şekilde ayarlanabilir. Ayrıca yapay zeka ve "Navigation Mesh" üzerinde de kod ile oynama yapılabilmektedir.

Simülasyonlar, ortam/sahne modelinde yürünebilecek yüzeyler "Navigation Mesh" ile belirlendikten sonra, karakterlere gerekli yapay zeka kodlaması yapılarak oluşturulmaktadır. Kodlama "1" karakter için yapılmakta, daha sonra istenilen sayıda karakter kadar bu karakterden kopyalama yapılmaktadır. Unity'nin kendi sağladığı görüntü alma fonksiyonu ile saniyede 25 ekran görüntüsü alınmakta, daha sonra bunlar birleştirilerek 25FPS frekansında istenilen formatta videolar oluşturulmaktadır. Videolar belirli hareket ve davranışları tanımlayacak şekilde kısa süreli klipler halinde, değişik açılarda ve yoğunluklarda çekilmektedir.

Video etiketleri "isim\_açı\_yoğunluk" formülüne göre verilmiştir. Açı için a:angle önekli olmak üzere f:far ve c:close harfleri kullanılmıştır. Yoğunluk için d:density önekli olmak üzere h:high, m:medium ve l:low harfleri kullanılmıştır. Bu durumda örnek olarak "Concert\_af\_dh" etiketi "Concert" isminde uzak açıdan çekilmiş yüksek yoğunlukta kalabalık içeren video anlamına gelmektedir.

Konser ortamı için tanımlanan normal kalabalık davranış biçimi "canlı ve eğlenen kalabalık"tır ("an expressive or revellous crowd"; Neary vd., (2011) sf. 23). Kişilerin birlikte veya bağımsız olarak eğlendiği, dansettiği, şarkı söylediği canlı ve hareketli kalabalık tipi olarak tanımlanmıştır.

Konser ortamında tanımlanan klipler: konser öncesi toplanma, konser sırasında, konser sonrası dağılma ve konser alanının boş hali olacak şekilde belirlenmiştir. Bu videoların çekiminde uzak ve yakın olmak üzere 2 ayrı açı kullanılmıştır. Kalabalık yoğunluğu ise düşük, orta ve yüksek olmak üzere 3 ayrı yoğunlukta çekilmiştir. Kişiler ve animasyonlar tamamen rastgeledir.

Sonuç olarak 20 adet 854x480 çözünürlükte 25 kare/saniye olarak her biri 2 dakikalık simülasyon videoları hazırlanmıştır. Bu videoların daha yüksek çözünürlükteki imge'leri de yine elde edilmiştir; böylelikle istenilen çözünürlükte ve FPS'de videolar hazırlanabilmektedir.

### 3.2. Kalabalık Videolarının Kaydedilmesi

Uygun nitelikte kalabalık davranışlarını ve yoğunluğunu içeren videoların elde



edilmesi için ODTÜ kampüsündeki etkinlikler göz önüne alınarak üniversitenin bahar şenlikleri sırasında videoların çekilmesine karar verilmiştir. Alınan bütün görüntüler ODTÜ içinde gerekli izinler alınarak çekilmiştir. Videolarda isimlendirme yapılırken yine simülasyon videolarında yapılan isimlendirme tekniği kullanılmıştır.

Görüntü alınan mekanlar, zamanlar, olaylar ve alınan görüntü süreleri şu şekildedir:

- Bahar şenliği sırasında çarşının ön tarafında kurulan sahneden izleyiciler, 2 video, toplam 5 dakika 20 saniye
- Bahar şenliği sırasında festival alanı ve dans edenler, 3 video, toplam 4 dakika
- Bahar şenliği sırasında alışveriş alanının (otopark), 4 video, toplam 3 dakika 50 saniye
- Bahar şenliği sırasında çarşı ve alışveriş alanını (otopark) bağlayan yol, 2 video, toplam 2 dakika
- Öğle arası zamanı yemekhane önü, 2 video, toplam 4 dakika
- Öğle arası zamanı kütüphane önü, 2 video, toplam 3 dakika
- Öğle arası zamanı yağmurlu havada kütüphane önü, 1 video, 1 dakika 30 saniye
- Öğle arası zamanı çarşı önü, 3 video, toplam 30 saniye
- Öğle arası zamanı rektörlük yanı merdivenler, 1 video, 1 dakika
- Etkinlik(konser) öncesi stadyum, 6 video, toplam 10 dakika
- Protesto öncesi hazırlık binasında toplanma, 1 video, 3 dakika
- Protesto öncesi rektörlük önünde toplanma ve bekleme, 6 video, toplam 6 dakika 30 saniye
- Protesto sırasında yürüme, 6 video, toplam 9 dakika 20 saniye
- Protesto sırasında yağmurlu havada yürüme, 4 video, toplamda 5 dakika 10 saniye
- Protesto sırasında Fizik binası önünde bekleme, 4 video, toplam 5 dakika
- Protesto sonrası Fizik binası önünde dağılma, 2 video, toplam 5 dakika

Sonuç olarak toplamda 1280x720 çözünürlükte toplamda yaklaşık 68 dakikalık 43 video çekilmiştir. Çekimler sırasında daha fazla kayıt alınmıştır fakat inceleme sırasında bazılarının kullanılmayacağına karar verilmesinden sonra sadece bu videolar dikkate alınmıştır.

Kaydedilmiş ve simülasyonla üretilmiş olan veri kümesine aşağıdaki linkten açık olarak erişmek mümkündür.

<ftp://ftp.vrcv.ii.metu.edu.tr/Datasets/Crowd/>

İlgili yayınlarımızda veri kümesinin tanıtımı ve linkin verilmesi ile veriler diğer araştırmacıların da kullanımına sunulmuştur.

### 3.3. Kalabalık Yoğunluğunun Tespiti ve Yoğunluğa Uygun Model Seçilmesi

Kalabalık görüntülerini analiz ederken, analiz edilen videoya uygun modelin kullanılması yöntemin doğru çalışması açısından önemlidir. Bu sebeple kullanılan modelin öğrenileceği eğitim videolarının daha sonra analiz edilecek videolara benzer nitelikte olması beklenmektedir. Kalabalık videolarında niteliği belirleyen en önemli parametre kalabalığın yoğunluğudur, bu nedenle projede öncelikle kalabalık yoğunluğunun tespiti ve eğitim için benzer yoğunluktaki videoların seçilmesi için bir yöntem önerilmektedir.

Önerilen yöntem test video ilgili karesinin ve eğitim video karelerinin tamamını göz önünde bulundurarak bir ceza ( $C$ ) fonksiyonu kullanır:

$$C = O_f + O_{\bar{o}} + S_{\bar{o}} + \ddot{O}S_f + \zeta_f C = O_f + O_{\bar{o}} + S_{\bar{o}} + \ddot{O}S_f + \zeta_f \quad (1)$$

Test edilecek videoda normal ve aykırılık içeren kareler bir arada bulunmaktadır. Öğrenim videolarında ise sadece normal kareler bulunmaktadır. Bu yüzden, kalabalığın hareketinin yoğunluğa göre değiştiği varsayımı altında, öğrenme ve test videolarındaki değerlendirilen öznitelik sayılarının birbirine yakın olmasını beklenmektedir. Bu varsayım altında, ilgili test videosu karesiyle öğrenme videolarının tüm karelerindeki öznitelik sayısı farkının ortalamasını alarak  $\ddot{O}S_f$

(2) değişkeninde tuttuk.

$$\begin{aligned} \ddot{O}S_f &= \text{Ortalama}(\ddot{O}S_{\text{öğrenme}}(\text{tüm kareler}) - \ddot{O}S_{\text{ilgili test karesi}}) \\ \ddot{O}S_f &= \text{Ortalama}(\ddot{O}S_{\text{öğrenme}}(\text{tüm kareler}) - \ddot{O}S_{\text{ilgili test karesi}}) \end{aligned} \quad (2)$$

Bunun yanında test videosunda hem normal hem de aykırı, öğrenme videosunda da sadece normal kareler olduğu için, bu iki videonun hız değerlerinin bir noktaya kadar benzeşmesi beklenir. Her bir karede elde ettiğimiz çok sayıda öznitelik hız değerlerini temsil edebilmek adına bu hız değerlerinin ortalamasını karşılaştırıyoruz. Test videosundan gelen her yeni karenin ortalama hızını, bütün öğrenme videolarının tüm kareleriyle farkına bakıyoruz. Daha sonra bu farkın ortalamasını  $O_f$  değişkeninde tutuyoruz. Bu hesaplama Denklem 3'te ifade edilmiştir. Bu denklemde  $O$  ortalama hızı,  $O_f$  ise ortalama hız farkını ifade etmektedir.

$$\begin{aligned} O_f &= \text{Ortalama}(O_{\text{öğrenme}}(\text{tüm kareler}) - O_{\text{ilgili test karesi}}) \\ O_f &= \text{Ortalama}(O_{\text{öğrenme}}(\text{tüm kareler}) - O_{\text{ilgili test karesi}}) \end{aligned} \quad (3)$$

Ancak bazı test videolarında neredeyse tüm karelerin aykırı değere sahip olması nedeniyle yalnızca öğrenme ve test videolarının hız değerlerinin birbirine yakınlığı doğru sonuç vermeyecektir. Bu tip videolar söz konusu olduğunda, kendisine en benzer karakterdeki öğrenme videosu da çoğunlukla test videosundaki aykırı değerlere yakın hıza sahip olacak ve yanlış bir model kullanılacaktır. Bu yüzden de öğrenme videolarının tüm karelerinin hız ortalamasını da fonksiyonumuza  $O_o$  (4) değişkeniyle dahil edilir:

$$O_o = Ortalama(O_{\text{öğrenme}}(\text{tüm kareler})) \quad (4)$$

$$O_o = Ortalama(O_{\text{öğrenme}}(\text{tüm kareler}))$$

Aynı şekilde, öğrenme videolarında sadece normal kareler (insanların yürüdüğü kareler) olduğu için, bu videolardaki hız değerlerinin düşük değerler etrafında toplanmış olduğunu varsayılmakla birlikte videolarda gürültü mevcut olabileceği ve filtreleme sonucu halen bazı gürültü değerleri kalabileceği için yüksek hız değerleri de elde edilebilmektedir. Ancak test videolarında, aykırı değerlerden kaynaklı daha fazla sayıda yüksek hızlı öznelik olduğu için, test videolarının çarpıklık değerinin öğrenme videolarına göre daha düşük olduğu varsayılabilir. Bu sebeple bu iki değer farkını da göz önünde bulundurulmaktadır. Bu farkı  $\zeta_f \zeta_f$  olarak (5)'te ifade edilmiştir.

$$\zeta_f = Ortalama(\zeta_{\text{ilgili test karesi}} - \zeta_{\text{öğrenme}}(\text{tüm kareler})) \quad (5)$$

$$\zeta_f = Ortalama(\zeta_{\text{ilgili test karesi}} - \zeta_{\text{öğrenme}}(\text{tüm kareler}))$$

Son olarak, öğrenme videolarında değişkenlik gürültü veya düzensizlik anlamına geleceğinden, düzensiz videoları da eleme yönüne eğildik. Bu düzensizliği en basit şekilde ifade eden standart sapmayı da fonksiyonumuzda  $S_o S_o$  olarak (6)'da ifade ettik.

$$S_o = Ortalama(Std_{\text{öğrenme}}(\text{tüm kareler})) \quad (6)$$

$$S_o = Ortalama(Std_{\text{öğrenme}}(\text{tüm kareler}))$$

Bütün öğrenme videoları için ceza değeri C hesaplandıktan sonra, minimum C değerine sahip videoya sahip modeli, ilgili test videosunu analiz etmek için kullanılır. Bu işlem her bir test video karesi için ayrı ayrı yapılır.

### 3.4. Kalabalık Videolarında Bölgesel Davranışların Kümelmesi

Önerilen yöntemde kalabalık davranışının incelenmesi için öncelikle video görüntülerinden optik akış metodu ile hız ve yön bilgisi alınmaktadır. Alınan bilgiler Sonlu zamanlı Lyapunov üsleri -Finite Time Lyapunov Exponents- (FTLE) kullanılarak hız ve yöne bağlı olarak değerler tablosuna dönüştürülmektedir. Sonuç olarak elimizde her piksel için videodaki kare başına bir değer

bulunmaktadır. Her piksel için bu değerler hiyerarşik kümeleme kullanılarak kümelenmekte ve piksel kümeleri elde edilmektedir. Bu sayede videoda istenilen periyotlarda davranış kümeleri elde edilmektedir

Yöntemin akış şeması Şekil 1'de verilmiştir. Yöntem 4 ana aşamadan oluşmaktadır:

1. Optik akış kullanarak videodan hız ve yön bilgilerinin çıkartılması,
2. Hız ve yön bilgilerinden Finite-Time Lyapunov Exponents (FTLE) kullanılarak ısı haritalarının elde edilmesi,
3. Bu yoğunluk haritasının hiyerarşik kümeleme ile kümelere ayrılması ve davranış kümelerinin belirlenmesi,
4. Aykırılık içeren kümeler mevcutsa bunların gözetimsiz eşikleme ile tespiti.



Şekil 1. Bölgesel davranışların kümelenmesi yöntemi için akış şeması.

#### *Optik Akış Hesaplanması*

Optik akış; 2 video karesi arasındaki bağıntılı hareketi hesaplayarak, hız ve yön bilgisi veren bir yöntemdir (Farneback, 2003). Optik akış, her iki yönde de 4'e 1 oranında örnek seyreltme yapılarak 4x4'lük bir alan için bir optik akış değeri elde edilecek şekilde yapılmıştır. Bu şekilde 640x480 çözünürlükteki bir video için 160x120 çözünürlükte optik akışı verisi elde edilir. Bunun sebebi hareketin daha genel bir görünümünü elde etmek ve gürültüye karşı duyarlılık sağlamaktır.

#### *Sonlu Zamanlı Lyapunov Üsleri ile Yoğunluk Haritası Oluşturulması*

Lyapunov üsleri (Lyapunov exponent) sonsuz yakınlıktaki noktaların sonsuz zamanda uzaklaşma-yakınlaşma değerlerini gösteren asimptot değerleridir. Akışkanlar dinamiğinde parçacıkların karışma ve ayrılma durumlarını hesaplamak için sıkça kullanılır. Sonlu zamanlı Lyapunov üsleri (FTLE) ise bu noktaların başlangıç pozisyonlarından itibaren  $T$  süresi boyunca izledikleri yola göre bulunur ve bu değerler  $T$  süresi boyunca devam eden akış hakkında bilgi verirler. Bütün noktaların değerleri birleştirildiğinde bir FTLE haritası çıkartılır.

Bir  $x$  noktasının  $T$  süresi boyunca akışını (7) şeklinde gösterirsek ve  $y$  noktası  $x$ 'e sonsuz yakınlıkta bir nokta (8) ise;

$$x \rightarrow \varphi_{t_0}^{t_0+T} x \rightarrow \varphi_{t_0}^{t_0+T}(x) \quad (7)$$

$$y = x + \delta x(t_0) \quad y = x + \delta x(t_0) \quad (8)$$



bu 2 noktanın  $T$  süresince uzaklaşma-yakınlaşma durumları Taylor serisi açılımı kullanılarak (9)'daki gibi ifade edilebilir.

$$\delta x(T) = \varphi_T^{t_0+T}(y) - \varphi_T^{t_0+T}(x) = \frac{d\varphi_T^{t_0+T}(x)}{dx} \delta x(t_0) + o(|\delta x(t_0)|^2) \quad (9)$$

$$\delta x(T) = \varphi_T^{t_0+T}(y) - \varphi_T^{t_0+T}(x) = \frac{d\varphi_T^{t_0+T}(x)}{dx} \delta x(t_0) + o(|\delta x(t_0)|^2)$$

terimi sonsuz küçüklükte olduğundan  $o(|\delta x(t_0)|^2)$  terimi göz

ardı edilebilir. Bu durumda noktanın izlediği yol boyunca hareketinin değişimi (10) denkleminde hesaplanabilir (Shadden vd., 2005) (\* sembolü transpoz işlemi için kullanılmıştır).

$$\Delta = \frac{d\varphi_T^{t_0+T}(x) * d\varphi_T^{t_0+T}(x)}{dx} \quad (10)$$

Birbirine sonsuz yakınlıkta 2 noktanın  $T$  süresince birbirine en uzak olduğu zaman  $\Delta$  değerinin özdeğerinin (eigenvalue -  $\lambda$ ) en büyük olduğu zamandır.

Sonuç olarak  $x$  noktasının  $t_0$  anından itibaren  $T$  süresi boyunca en büyük sonlu zamanlı Lyapunov üs değeri (11) şeklinde ifade edilebilir.


$$\sigma_{t_0}^T(x) = \frac{1}{|T|} \ln \sqrt{\lambda_{\max}(\Delta)} \quad (11)$$

Bu çalışmada hesaplamalar için LCS Matlab Kit (The Biological Propulsion Laboratory, 2013) kullanılmıştır. LCS Matlab Kit optik akış verilerini alıp, gerekli



Şekil 2. Test videosundan örnek kareler.

hesaplamaları yaparak her kare için bir FTLE yoğunluk haritası vermektedir. Yoğunluk haritası her piksel için bir FTLE değeri içermektedir. Sonuç olarak elde edilen yoğunluk haritası yine optik akış sonucu ile eşit çözünürlüktedir.  $T$  değeri yazılımda "integration length" (tümleştirme süresi) ismiyle belirtilmiş olup, video için hesaplamaların yapılacağı kare sayısını ifade etmektedir Şekil 2'de test videosundan örnek kareler verilmiştir, koşan grubun bulunduğu bölge sarı ile, frizbi fırlatılan bölge ise kırmızı ile işaretlenmiştir. Bu veriden alınan örnek yoğunluk haritası Şekil 3'te görülmektedir. Soldaki yoğunluk haritası videonun başından alınmıştır ve frizbiye denk gelen bölge sarı ile işaretlenmiştir, sağdaki ise videonun ortasından alınmıştır; frizbiye denk gelen bölge sarı ile, koşan gruba denk gelen bölge ise siyah ile işaretlenmiştir.



Şekil 3. Test videosunun FTLE çıktıları.

### *Hiyerarşik kümeleme*

FTLE çıktısını kümelere ayırmak için hiyerarşik kümeleme (hierarchical clustering) (Hastie vd., 2009) kullanılmıştır. Hiyerarşik kümeleme istatistikte ve veri işleme uygulamalarında kullanılan, verileri belli bir hiyerarşiye göre düzenleyerek kümeleme yapan bir yöntemdir. Bu çalışmada aşağıdan yukarıya hiyerarşik (agglomerative) kümeleme kullanılmıştır. Aşağıdan yukarıya kümelemede ilk başta her bir veri ayrı bir küme olarak kabul edilir ve her yinelemede birbirine en yakın olan veriler birleştirilerek tek bir küme haline getirilir. İstenilen küme sayısına ulaşıldığında yinelemeler durdurulur.


Bu kümeleme yönteminde önemli olan 3 parametre vardır. 1. parametre; verilerin birleştirilmesi için gereken mesafeyi hesaplamada kullanılacak olan yöntemdir. Değişik denemeler (en yakın mesafe, en uzak mesafe, merkezi mesafe ve ağırlıklı ortalama mesafe) sonunda en iyi sonucu verdiği için Ward yönteminde (Ward, 1963) karar kılınmıştır. Ward yönteminde her yinelemede, birleştirildiği takdirde kümeler arasında en az varyansa yol açacak olan kümeler birleştirilmektedir. Böylelikle her yinelemede birbirine istatistiksel olarak en yakın olan kümeler birleştirilmektedir. 2. parametre; kümeler arası mesafeyi hesaplamak için kullanılan yöntemlerdeki mesafe tipidir. Ward metodu sadece Öklid uzaklığı ile çalıştığından Öklid seçilmiştir. 3. parametre küme sayısıdır. Kümeleme işlemi bittiğinde bütün verinin kaç kümeye ayrılacağı belirtilmelidir. Bunun için deneyler yapılarak değişik küme sayılarında sonuçlar gözlemlenmiştir.

### *Anomali tespiti*

Bu aşamada elde edilen kümelerin analizi ve anomali tespiti yapılması amaçlanmaktadır. Yöntem şeması Şekil 4'te görülmektedir.

İlk olarak her kümedeki her imgecik için en yüksek FTLE değerleri bulunmaktadır. Sonrasında her küme için bu değerlerin ortalaması alınıp bir ortalama azami (OA) değer elde edilmektedir. Bu değer her kümedeki hareket

hızının karakteristiğini belirten bir değer olma özelliği taşımaktadır. İşlem sonucunda her küme için bir değer elde edilmektedir. En düşük değere sahip olan küme hareketsiz arka plan kümesi kabul edilip bundan sonraki hesaplamalarda göz ardı edilecektir.



Şekil 4. Anomali içeren kümelerin tespiti.

Videoda anomali olup olmadığını bulmak için hesaplanan OA değerlerine çarpıklık testi uygulanmaktadır. Negatif çarpıklık değeri küme değerlerinin normal dağılım gösterdiğini ve bir anomali içermediğini belirtmektedir. Pozitif çarpıklık değeri ise bazı kümelerin yüksek OA değerine sahip olduğunu ve anomali içermeye ihtimali bulunduğunu belirtmektedir. Bu durumda anormal kümeleri belirlemek için gözetimsiz bir yöntem olan Eşit Ağırlıklı Eşik Değeri (Equal Width Thresholding; Dougherty vd., 1995) kullanılmıştır. Bu yöntem genelde veriyi eşit ağırlıklı örneklere bölmek için kullanılmaktadır. Yüksek çarpıklık içeren verilerde anormal değerler verinin genişliğini artırır ve verinin geri kalanından uzak noktalarda bulunurlar. Bu durumda eşit ağırlıklı bir eşik değeri veriyi ikiye bölecek, uzakta kalan anormal değerler bölümün ikinci kısmında kalacaktır. Bu yöntemde kullanılan eşik değeri (12) denkleminde hesaplanmaktadır.

$$Th = \frac{max - min}{2} + min \quad (12)$$

“max” ve “min” hesaplanan OA değerlerinin, en yüksek ve en düşük değerlerini belirtmektedir. Bu eşik değerinden yüksek OA değerine sahip olan kümeler anomali içeren kümeler olarak belirlenmiştir. Eşik değerinin otomatik olarak hesaplanması, önceden bir eşik değeri belirleme ihtiyacını ortadan kaldırmıştır ve bu sayede hesaplanan eşik değeri her video için farklı ve videoya uyumlu hale gelmiştir.

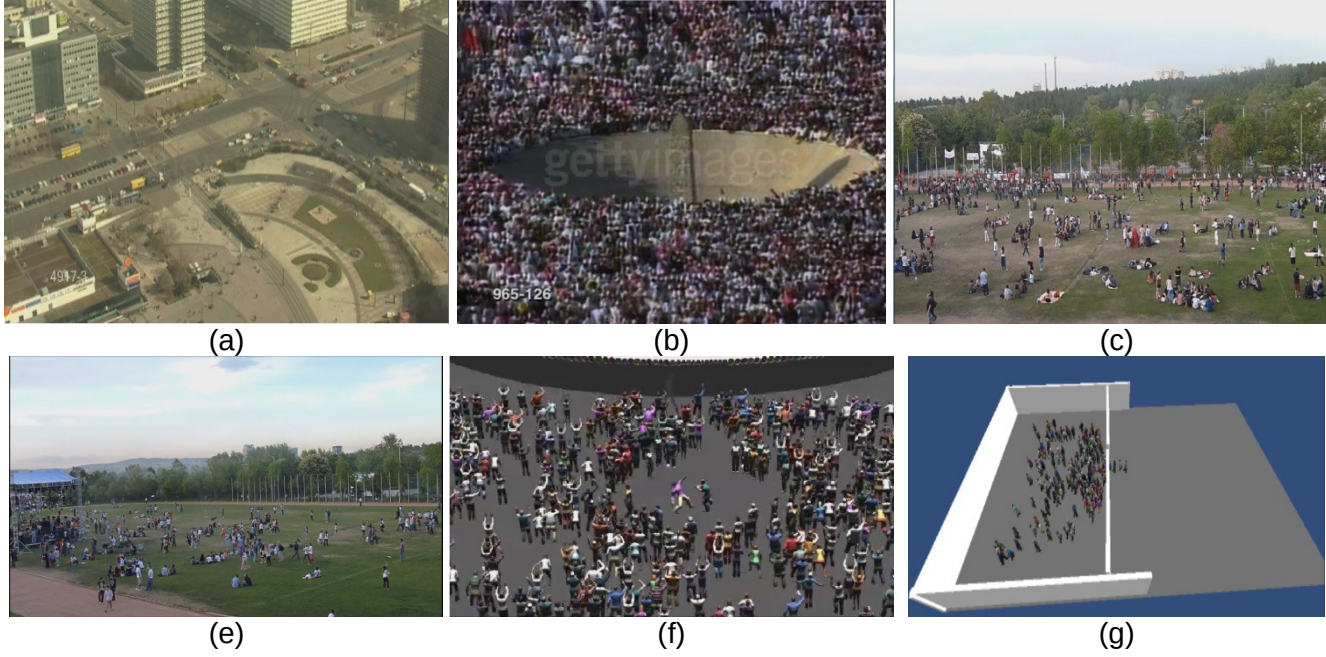
#### Deneyler

Yöntemi denemek için kullanılan test videoları 3 farklı kaynaktan alınmıştır:

- ODTÜ içerisinde bahar şenliği etkinlikleri boyunca farklı senaryoları içerecek şekilde çektiğimiz videolar.
- Bilgisayar ortamında Unity 3D kullanarak (Unity Technologies, 2012) oluşturduğumuz kalabalık benzetimi videoları. Bu videolar gerçek hayatta elde edilmesi güç durumlar için oluşturulmuştur.

- İnternet üzerinde açık olarak sunulmuş olan kalabalık videolarıdır (Ali ve Shah, 2007).

Deneşlerde kullanılmış olan veri kümelerinden örnekler Şekil 5'te verilmiştir.



Şekil 5. Test videolarından örnek kareler.

Tablo 1. Test videoları sonuçları.

ID#	Video Adı	Aykırılık	Çarpıklık	
			$i=1$	$i=10$
1	City Traffic	Yok	-0.6265	-1.0938
2	Door (S)	Yok	-0.6365	-0.3864
3	Marathon	Yok	-1.0310	-0.7314
4	Bazaar	Yok	-0.0121	-0.4151
5	Stadium 3	Yok	-0.4189	-0.0682
6	Station	Yok	-1.4031	-0.8049
7	Stadium	Var	<b>0.3605</b>	<b>0.5391</b>
8	Fight (S)	Var	<b>0.1427</b>	<b>1.6535</b>
9	Stadium 2	Var	<b>1.2625</b>	-0.4148
10	Stoning	Var	<b>1.7487</b>	<b>0.4046</b>
11	Hall	Var	<b>0.5791</b>	<b>0.2223</b>
12	Crossroad	Var	<b>0.7595</b>	<b>0.0882</b>

Test için 6 tanesi anomali içeren toplam 12 video kullanılmıştır. Kalan diğer 6 video ise sıradan kalabalık hareketleri içermektedir. Hesaplanan çarpıklık değerleri Tablo 1'de video ID numaraları ile birlikte gösterilmektedir. Bu değerler hesaplanırken küme sayısı 20, tümleştirme sayısı ise 1 ve 10 (tabloda "i=1" ve "i=10" olarak gösterilmiştir) alınmıştır. Simülasyon videoları ismin yanında "(S)" işareti ile belirtilmiştir, "Stadium" ismindeki videolar ise (ID#5,7 ve 9) kendi




çektığımız videolardır. Diğer videolar ise internet üzerinden bulunmuştur (Ali ve Shah, 2007).


Anomali içermeyen videolar için (ID#1-6), tümleştirme süresi 1 ve 10 için çarpıklık değeri negatif bulunmuştur. Yöntem bu videolarda anomali tespit etmemiştir ve bu videolar doğru bir şekilde normal olarak etiketlenmiştir. ID numarası 1 olan, UCF veri setinden alınan 720x404 çözünürlüklü 1750 kareden oluşan videodan alınan bir örnek kare Şekil 5(a)'da görülmektedir.

Anomali tespiti kendi çekimimiz olan Stadium (ID#7) videosunda gösterilmektedir. Video 700 kareden oluşmakta ve çözünürlüğü 854x480'dir. Videoda normal davranışların yanında (piknik yapma, konuşma, yürüme vb.) iki farklı anomali gözlenmektedir: Protesto eden kalabalık ve frizbi oynayan bir grup. Frizbi oynayan grup anomali olarak nitelendirilmiştir çünkü bu bir yabancı cisim fırlatma davranışıdır. Videodan örnek bir kare Şekil 6'da görülmektedir; frizbi oynayan grup beyaz daire, protesto eden grup kırmızı daire içine alınmıştır.

Optik akış, FTLE ve hiyerarşik kümeleme aşamalarında sonra elde edilen 20 küme sayısı için küme sonuçları Şekil 7(a)'da, her küme farklı bir renk olarak gösterilmektedir. Tümleştirme değeri 10 alınarak her küme için OA değerleri Tablo 2'de yükselen sıralamayla gösterilmektedir.



Şekil 6. 2 farklı anomali bölgesini gösteren test videosundan alınan örnek kare.



Şekil 7. Stadium (ID#7) videosunda 10 tümleştirme sayısı için (a) kümeleme sonuçları, (b) anomali içeren kümeler.

Tabloda da görüldüğü üzere en düşük OA değeri 20 numaralı kümededir. Bu sebepten dolayı bu küme hareketsiz arka plan olarak nitelenip bundan sonraki hesaplamalarda göz ardı edilecektir. Aynı zamanda bu küme imgecik sayısı bakımından en büyük kümedir ve Şekil 7(a)'da koyu kırmızı renk ile gösterilmektedir.

Geri kalan 19 küme için hesaplanan çarpıklık değeri 0.5391'dir. Video anomali içerdiğinden bu değer beklenildiği üzere pozitiftir. Anomali içeren kümeleri belirlemek için ilk aşamada eşik değeri (ED) denklem (12) kullanılarak hesaplanmıştır. Bu video için ED 0.1066 bulunmuştur. Bu ED'den yüksek OA değerine sahip olan kümeler anomali içeren kümeler olarak belirlenmiştir. Bu video için 5 küme (12, 19, 11, 10, 15) 0.1066 değerinden yüksek OA değerine sahip olduğu için anomali içeren küme olarak belirlenmiştir.

Şekil 7(b)'de sadece anomali içeren kümeler farklı renklerle gösterilmiştir. Şekilde sağ alt tarafta kalan kümeler frizbi oynayan gruba ait davranış kümesidir, orta kısımda kalan kümeler protesto eden gruba ait kümelerdir, sol alt kısımdaki küçük küme ise video boyunca sadece bir kere frizbi atma davranışı gösteren gruba ait kümedir.

Tümleştirme süresi 1 ( $i=1$ ) alındığı taktirde aynı yöntemle çarpıklık değeri 0.3605 olarak hesaplanmıştır. Kümeleme sonuçları Şekil 8(a)'da , anomali içeren kümeler Şekil 8(b)'de gösterilmiştir. Tümleştirme süresi 1 alındığından dolayı hareketin akışı sadece 1 kare için hesaplanmıştır ve bundan dolayı koşarak protesto eden grup gibi uzun süren hareketler hesaplanamamış ve sadece frizbi oynayan grup anomali olarak belirlenmiştir. Uzun süren anomalileri tespit etmek için daha uzun bir tümleştirme süresi seçilmelidir, düşük tümleştirme süresi genelde kısa süren yüksek hızlı anomalileri (kavga, bayılma vb.) tespit etmek için tercih edilebilir. Tümleştirme süresinin belirlenmesi duruma özgü olsa da yöntem


farklı tümleştirme süreleriyle aynı anda çalıştırılarak hem kısa hem uzun anomalileri tespit etmek için kullanılabilir.

Tablo 2. Küme sayısı, Küme Boyutu ve Ortalama Azami değerler.

20	16382	0.0029	16	146	0.0946
4	2974	0.0328	17	507	0.0965
9	1058	0.0485	6	131	0.0975
3	1548	0.0520	13	263	0.0978
7	507	0.0597	5	146	0.1037
1	276	0.0636	15	46	0.1188
8	492	0.0637	10	20	0.1275
2	66	0.0840	11	36	0.1323
18	184	0.0862	19	126	0.1358
14	317	0.0918	12	23	0.1805




(a)




(b)

Şekil 8. Stadium (ID#7) videosunda 1 tümleştirme sayısı için (a) kümeleme sonuçları, (b) anomali içeren kümeler.



(a)



(b)

Şekil 9. Fight videosu için anomali içeren kümeler (a) tümleştirme sayısı 1 için, (b) tümleştirme sayısı 10 için.

Küme sayısı 10 olarak ayarlandığında çarpıklık değeri negatif bulunmuştur. Bunun sebebi, küme sayısı 10 alındığında bütün davranışları farklı kümeler haline getirmek mümkün olmamış ve anomali içeren ve içermeyen kümeler birleşmiştir. Küme sayısı 30 alındığında tümleştirme süresi 1 ve 10 için çarpıklık değeri pozitif çıkmış ve görsel sonuçlar 20 küme sayısı ile aynı bulunmuştur. Küme sayısı videodaki davranış sayısından fazla olduğunda anomali içeren kümeler alt kümelere bölünmüştür. Eşik değeri de bu sonuçlara göre otomatik olarak hesaplandığından sonuçlar yine aynı çıkmıştır. Sonuç olarak 20 küme sayısı bu yöntem için yeterlidir.

Kavga davranışını test etmek için, iki kişinin kavga ettiği, diğerlerinin müzikle dans ettiği yüksek yoğunluklu kalabalık içeren Fight (ID#8) isimli simülasyon videosu kullanılmıştır. Kavga videonun orta kısmında olmaktadır ve kavga başladığında yakındaki insanlar çember haline gelip kavgayı izlemektedir. Video 450 kareden oluşmakta ve çözünürlüğü 854x480'dir. Videodan örnek bir kare Şekil 5(f)'te görülmektedir. 20 küme sayısı ve tümleştirme süresi 1 ve 10 alındığında çarpıklık değeri pozitif ve anomali tespit edilmiştir. Her iki tümleştirme süresi için de anomali içeren kümelerin görsel sonuçları Şekil 9(a) ve (b)'de mevcuttur.

Şekil 9(a)'da görüldüğü gibi, tümleştirme süresi 1 alındığında orta kısımdaki kavga davranışı içeren küme doğru biçimde, sol altta yer alan diğer 2 küme ise yanlış biçimde anomali olarak tespit edilmiştir. Tümleştirme süresinin 1 olması sadece çok kısa süreli hareketleri dikkate aldığından gürültüye karşı çok duyarlıdır. Tümleştirme süresi 10 alındığında kavganın olduğu orta bölge doğru biçimde anomali olarak tespit edilmiştir. Bu durumda uzun süren davranışlar dikkate alındığından, uzun süre boyunca kavga olan daha küçük bölge anomali olarak tespit edilmiştir.

Stadium 2 (ID#9) videosu Stadium (ID#7) ile aynı yerden farklı açıdan çekilmiştir ve benzer özellikler taşımaktadır. Farklı olarak frizbi oynayan grup çok kısa sürede görülmektedir ve protesto eden grup görülmemektedir. Bu videoda tümleştirme süresi 1 alındığında çarpıklık değeri pozitifdir. Tümleştirme süresi 10 alındığında kısa süreli hareketler dikkate alınmadığından çarpıklık değeri negatif bulunmuştur.

*Stoning* videosu (ID#10) Mekke'deki şeytan taşlama görüntüsüdür. İnsanlar uzun süre boyunca yabancı cisim atıklarından her iki tümleştirme süresi için çarpıklık değeri pozitif çıkmış ve anomali tespit edilmiştir.


*Hall* videosu (ID#11) Mekke'deki hacıların bir binanın içinde yürümesini göstermektedir. Genel yürüme hareketi haricinde videonun orta bölgesinde bazı hacılar koştuğu için bu bölge anomali olarak belirlenmiştir.

*Crossroad* videosu (ID#12) insanlar karşıdan karşıya geçerken çekilmiştir. Videoda genel olarak insanlar yürüyerek karşıdan karşıya geçerken bazı kişilerin koştukları gözlenmiştir. Çarpıklık değeri pozitif bulunmuş ve anomali tespit edilmiştir. Anomali içeren kümeler incelendiğinde koşan insanların bulunduğu



kümelerin anomali olarak belirlendiği ortaya çıkmıştır. Bu bir gözlemci için anomali sayılmayacak davranış olsa da videodaki genel harekete ters düşen bir durum olduğu için yöntem tarafından anomali olarak belirlenmiştir.

### 3.5. Davranışların Zaman-Uzamsal Modellenmesi ve Aykırılık Tespiti



Şekil 10. Yöntem akış şeması.

Kalabalık dinamiklerinin çıkarılması için, öznitelik tespit ve takip tekniklerini analiz eden çalışmayı (Gündüz vd., 2013) temel alarak, bu amaçla ORB öznitelik tespit edicisi ve tanımlayıcısı kullanmayı seçtik. Bu amaç için ORB'un, SIFT ve SURF gibi oturmuş yöntemlerle benzer performans gösterirken, hesaba dayalı karmaşıklığının çok daha düşük olduğu gösterilmiştir.

Vektörel hız hesabı görüş açısına (perspektif) bağlı olduğu için, bu problemi aşmak adına öncelikle sahne çakışan daha küçük alanlara ayrılır. Sonrasında, bu bölgelerde ORB öznitelik noktaları tespit edilerek, iki ardışık kare arasında öznitelik eşlemesi yapılır.

Eşlenmiş özniteliklerinin lokasyon bilgileri alındıktan sonra, bu öznitelikler arasında Öklid uzaklığı kullanılarak imgecik bazında hız hesabı yapılır. Bütün sahnenin karakteristik özelliğini temsil edebilmek adına, hesaplanan hızları, iki ardışık kare arasında eşlenmiş özniteliklerin açısına bağlı olarak 8 seleye ayırıyoruz. Bu yön binleri şu şekilde etiketlenmiştir:  $\{[0^\circ-45^\circ):D1, [45^\circ-90^\circ):D2, [90^\circ-135^\circ):D3, [135^\circ-180^\circ):D4, [180^\circ-225^\circ):D5, [225^\circ-270^\circ):D6, [275^\circ-315^\circ):D7, [315^\circ-360^\circ):D8\}$ . Bu aşama, her bir bölgeye uygulanarak, her bir video için  $M \times (N-1) \times 8$  hız vektörü elde edilmiştir. Burada  $M$  bölge sayısı,  $N$  ise videodaki toplam kare sayısıdır. Hız hesabı ardışık iki karenin eşlenmesiyle yapıldığı için, son karenin verisi mevcut değildir, bu da  $N-1$  karenin verisinin varlığı anlamına gelmektedir. Her vektörün boyutu, eşlenmiş öznitelik sayısına eşittir.

Daha sonra, hız vektörünün boyutunu küçültmek adına, çeyrek kütle (quartile) temelli bir yaklaşım kullandık. Yayaların hızı, diğer ulaşım araçlarıyla karşılaştırıldığında nispeten düşük değerlere sahiptir. Bir yaya bölgesinde, varlıkların hepsi olmasa bile büyük çoğunluğunun yaya olduğu varsayılmaktadır. Bu sebeple veri düşük değerlere sahip olma eğilimindedir. Bu problemi aşmak için, verinin çeyrek kütle değerlerini incelemeyi uygun gördük. Verinin

karakteristiğini temel alarak, yayaların hızı düşük olduğu için, var olan aykırılıkların dördüncü çeyreklige düşeceğini varsaydık. Aykırı değerlerin varlığı durumunda, bu değerlerin hız vektörünün yüksek değerli ucunda bulunması gerekmektedir. Biz yaya alanlarındaki aykırılık tespitine odaklanmış olsak da, bu yöntem farklı karakteristikli uygulamalara da uyarlanabilir. Örneğin, eğer trafikteki beklenmeyen sıkışmalar tespit edilmek isteniyorsa, hız vektörünün düşük değerli ucu kullanılabilir.

Öğrenme kümesinde, öncelikle, video karesini daha küçük uzamsal bölgelere ayırmak için ikili maske uyguluyoruz. İmgecik (i,j), maskenin (i,j) noktasındaki değeri bire eşit olduğunda görünür durumdadır. Daha sonra bütün maskeler için video başına, her  $D_i$  yönüne giden ortalama öznitelik sayısını,  $\mu_{FC(i)}$ , hesaplıyoruz.  $C_{D_i}$ , verinin analiz edilebilmesi için gerekli maksimum veri nokta sayısı olsun. Öyleyse Denk. (13)  $Q_4$  ile gösterilen dördüncü çeyreklikteki veri sayısını tanımlar.


$$C_{D_i} = \frac{\mu_{FC(i)}}{4} \quad (13)$$

Bu adımı takiben,  $i$ 'nin yönü ( $D1$ 'den  $D8$ 'e kadar) gösterdiği durumda her maske  $m$  için, her karenin ( $f$  ile gösterilir) son  $C_{D_i}$  hızlarının ortalaması hesaplanarak  $\mu_{V(f,m,i)}$  ile Denk. (14)'de gösterilir.

$$\mu_{V(f,m,i)} = \frac{\sum_{j \in Q_4} V_j(f, m, i)}{C_{D_i}} \quad (14)$$

Boyut küçültmeden önce elimizde  $M \times (N-1) \times 8$  hız vektörü varken, bu aşamadan sonra elimizde her video için  $M \times (N-1) \times 8$  skaler (hız ortalamaları) vardır. Daha sonra gürültüyü azaltmak için, bütün öğrenme veri kümesinin ortalama hız matrisi hesaplanarak, tek bir öğrenme matrisi elde edildi. Denk. (15), son veri setinin elde ( $TrD$ ) edilmesini açıklamaktadır. Ortalamasını aldığımız veri seti sadece normal hız değerlerini içermektedir.

$$TrD = \frac{\sum_{v \in V} \mu_{v(f,m,i)}}{V} \quad (15)$$



Şekil 11. 3 zaman dilimi için açılmış, 5 zincirli CHMM.

Elde edilen veri, olasılıksal modellerin gürültülü veriyi modellemede iyi sonuç verdiği gösterildiği için, Eşlenmiş Gizli Markov Modeli (Coupled Hidden Markov Model (CHMM)) ile modellenmiştir. CHMMlerin, bitişik düğümler arasındaki ilişkileri modelleme yeteneği vardır. Bitişik ve çakışan perspektif maskelerini CHMM düğümleri olarak kullanarak, maskeler arasındaki ilişkileri çıkarmayı amaçladık. Kullandığımız modelin 5 gizli kesikli düğümü, her bir kesikli düğümün ise gözlenen bir sürekli normal dağılıma sahip çocuğu vardır. Zaman dilimi  $t$ 'deki gizli düğümler sadece  $t-1$  anındaki komşu düğümlerden etkilenirler ve  $t+1$  anındaki komşu düğümleri etkilerler. Kullandığımız CHMM Şekil 11'de gösterilmiştir. Bu model gösterim amaçları için sadece 3 zaman diliminde açılmış olsa da, bizim modelimiz  $N-1$  zaman dilimi için açılmıştır. Dikdörtgen şekilli düğümler kesikli düğümlerdir. Bu düğümler sınıf değişkenleridir. Dairesel düğümler, normal dağılımlı gözlemlerimizi göstermektedir. Bu gözlemler hesaplanmış hız vektörleridir.

Modelimizdeki kesikli gizli düğümler, karenin normal veya aykırı olduğunu ifade eden iki değere sahiptir. Normal verinin parameterlerini, öğrenme setinden elde ettiğimiz asil matrisi kullanarak öğreniyoruz. Aykırı verinin parameterlerini ise asil veriyi kullanmak yerine, bu veriye yapay gürültü ekleyerek öğreniyoruz. Gürültü ekleme işlemi, yayaların çoğunlukla yürüdüğü yönlere eklenmiş normal ak gürültüden çekilen rastgele verileri oluşturarak yapılır. Geri kalan yönler içinse, asil veriyle aynı normal dağılıma sahip rastgele değerler oluşturulur. Kullanılan rastgele yürüyüş denklemi Denk. (16)'da verilmiştir.

$$N_i = \alpha * \mu_{tr} + Z \quad (16)$$



Burada Z standart normal dağılıma sahiptir ve  $\alpha$  değeri de Denk (5)'teki gibi hesaplanmaktadır. Bu denklemde  $\mu_{tr}$  ve  $\sigma_{tr}$  öğrenme verisinin (TrD) (15) ortalama ve standart sapmasıdır, s ise aşağıda açıklanan kaydırma faktörüdür.

$$\alpha = \frac{\mu_{tr} + s * \sigma_{tr}}{\mu_{tr}} \quad (17)$$

Alfa değerinin seçim motivasyonu alan bilgisi üzerine kuruludur. Hızsal aykırılıkların, hız değerlerinin yüksek ucunda olması gerektiğini biliyoruz. Bu yüzden, bu yüksek değerli hızsal aykırılıkları temsil eden yapay gürültü eklemek adına, gürültüye sahip hız değerlerinin ortalamasını yukarı doğru kaydırmamız gerekmektedir. Kaydırma faktörü s, normal dağılımda genellikle aykırı değer sınırı kabul edilen 3 olarak seçilmiştir.

Diğer yönlerden seçilen rastgele örneklemeler, asil veriyle aynı dağılıma sahiptir. Asil veriyle aynı dağılımın kullanılmasının sebebi, bu yönlerde çok az anomalinin olmasıdır ve daha yüksek ortalamaya sahip bir dağılımdan örneklem çekmek hatalı bir modelle sonuçlanacaktır. Etkinliğin düşük olduğu bu yönleri de yüksek aykırı değerlere sahip verilerle modellemek bu yönlerde sıklıkla aykırılık meydana geldiği anlamına gelirdi ancak durum böyle olmadığı için örnekleme aynı dağılımdan çekmeye karar verdik.

Her zaman kesitindeki normal dağılıma sahip çocuk düğümler ve ilgili kare ve maskeden elde edilmiş asil veriyle modellenmiştir. Parametreler beklenti en-yükseklenmesi (Expectation Maximization (EM)) algoritmasıyla, en fazla 10 iterasyona ulaşana kadar veya çok küçük bir epsilon hata değerine erişilene kadar öğrenilmiştir. Bu durumda epsilon değeri  $\epsilon = 10^{-3}$ 'tür.

Model öğreniminden sonra, test setindeki her kare, sonracıl (posterior) olasılığına göre sınıflandırılmıştır.


Deneyisel değerlendirme için, sadece normal karelere sahip 34 tane öğrenme videosuna ve hem normal hem de aykırı karelere sahip 36 tane test videosuna sahip olan UCSD Peds 1 veri kümesi kullanılmıştır. Algoritma, sadece öğrenme videoları kullanılarak öğrenilmiş ve test videolarında test edilmiştir. Her video 200 tane  $238 \times 158$  çözünürlüklü kareye sahiptir. Sahneyi çakışan 5 tane bölgeye ayırıyoruz. Deneyimlerimiz daha fazla bölge kullanmanın sahneyi fazla küçük parçalara bölerek öznelik tespitinin doğru çalışmasını engellediğini göstermiştir.



Öğrenme kümesini incelediğimizde, birkaç öğrenme videosunda aykırılık tespit ettik. İkinci ve yedinci videoda, yaya yolundan bisiklet geçtiği ve on altıncı videoda yaya yolu yerine çim alanda yürüyen bir adam olduğu gözlemlenmiştir. Ayrıca, otuzaltıncı test videosunda, verilen etiketlerde belirtilmemiş bir aykırı durum bulunmaktadır. Bu videoda sadece yaya yolundan geçen araba aykırı olarak işaretlenmiştir. Biz, öğrenme verisinin ortalamasını kullandığımız için bu aykırılıkların etkisi giderilmiştir ve bu videoları öğrenme setinden çıkarmamız gerekmemiştir.

Öğrenme kümesini kullanarak elde ettiğimiz hız değerlerinin normal dağılımı takip ettiği 0.0324 büyüklüğündeki en küçük p değeriyle gösterilmiştir. Bu testte p için güven değeri 0.01 olup, bu test yaptığımız normal dağılım varsayımını doğrulamıştır. Öğrenme kümesi kullanılarak elde edilen  $\alpha$  değeri 1.20 olarak hesaplanmıştır.

Önerilen yöntemin literatürdeki benzerleri ile karşılaştırmalı sonuçları Şekil 12'de verilmiştir. Bu yöntemlerden yalnızca Seidenar vd. (2010)'de önerilen metod gerçek zamanlı çalışacak şekilde tasarlanmıştır. Bu yöntemin saniyede işleyebileceği kare sayısı belirtilmemiş olmakla birlikte gerçek zamanlı olarak çalıştığı rapor edilmiştir. Mahadevan vd. (2010)'de önerilen yöntem en iyi sonuçları veriyor olmasına rağmen bu yöntemin saniyede ancak 0.04 kare işleyebildiği rapor edilmiştir. Yoğun işlem ihtiyacı nedeniyle bu yöntemin gerçek zamanlı uygulanması mümkün görünmemektedir.



Şekil 12. Literatürdeki Yöntemlerin ve Önerilen Yöntemin ROC Eğrisi Grafiği.

### 3.6. Kaynaklar

Adam, A., Rivlin, E., Shimshoni, I., Reinitz, D. 2008. "Robust Real-Time Unusual Event Detection using Multiple Fixed-Location Monitors," IEEE Transactions on Pattern Analysis and Machine Intelligence, 30, 3, 555-560.

Ali, S., Shah, M. 2007. "A Lagrangian Particle Dynamics Approach for Crowd Flow Segmentation and Stability Analysis", IEEE Conference on Computer Vision and Pattern Recognition (CVPR).

Dougherty, J., Kohavi, R., Sahami, M. 1995. "Supervised and Unsupervised Discretization of Continuous Features", Machine Learning: Proceedings of the Twelfth International Conference.

Farneback, G. 2003. "Two-Frame Motion Estimation Based on Polynomial Expansion", 13th Scandinavian Conference on Image Analysis.



Gunduz, A.E., Temizel A., Taskaya Temizel T. 2013. "Kalabalık Dinamiklerinin Çıkartılması İçin Özniteliklerin Tespit ve Takibi ", IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.

Hastie, T., Tibshirani, R., Friedman, J. 2009. "14.3.12 Hierarchical clustering", The Elements of Statistical Learning (2nd ed.). New York: Springer.

Mahadevan, V., Li, W., Bhalodia V., Vasconcelos, N. 2010. "Anomaly detection in crowded scenes", IEEE Conference on Computer Vision and Pattern Recognition (CVPR).

Neary, C., Hogervorst, M., Simeonov, A., Olsen, S. N., Gavrilla, D. M. 2011. "Abnormal Behaviour Definition", ADABTS D3.1

Seidenar, L., Bertini, M., Bimbo, A.D. 2010. "Dense spatio-temporal features for non-parametric anomaly detection and localization", Proceedings of The First ACM International Workshop on Analysis and Retrieval of Tracked Events and Motion in Imagery Streams.

Shadden, S. C., Lekien, F., Marsden, J. E. 2005. "Definition and Properties of Lagrangian Coherent Structures from Finite Time Lyapunov Exponents in Two Dimensional Aperiodic Flows", Physica D 212.

Tipping M., Bishop, C.M. 1999. "Mixtures of probabilistic principal component analyzers", Neural Computation, 11, 2, 443-482.

The Biological Propulsion Laboratory. "LCS Matlab Kit v2.3".

<http://dabiri.caltech.edu/software.html>

Son Erişim Tarihi : Ekim 2013.

Unity Technologies. "Unity 3D v4.0.0".

<http://unity3d.com/>

Son Erişim Tarihi: Kasım 2012

Ward, J. H. Jr. 1963. "Hierarchical Grouping to Optimize an Objective Function", Journal of the American Statistical Association v. 58.



#### 4. BULGULAR VE TARTIŞMA/SONUÇ

Projenin çıktısı olarak aşağıdaki 3 uluslararası, 4 ulusal bildiri konferanslarda kabul almış ve sunulmuştur. Ayrıca bir adet dergi makalesinin hazırlanarak gönderilmiştir.

Dergi makalesi:

- Gunduz, A.E., Ongun, C., Taskaya Temizel, T., Temizel, A., “Density Aware Anomaly Detection in Crowded Scenes”, Machine Vision and Applications (7 Kasım 2014 tarihinde yollandı, değerlendirme sürecinde).

Uluslararası konferans bildirisi:

- Gunduz, A.E., Taskaya Temizel, T., Temizel, A. Ağustos 2014. “Pedestrian Zone Anomaly Detection by Non-Parametric Temporal Modeling”, accepted to IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS).
- Ongun, C., Temizel, A., Taskaya Temizel, T. Ağustos 2014. “Local Anomaly Detection in Crowded Scenes Using Finite-Time Lyapunov Exponent Based Clustering”, accepted to IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS).
- Guler P., Temizel, A., Taskaya Temizel, T. Aralık 2013. “Real-Time Global Anomaly Detection for Crowd Video Surveillance Using SIFT”, 5th International Conference on Imaging for Crime Detection and Prevention (ICDP-2013).

Ulusal konferans bildirisi:

- Öngün, C., Temizel, A., Taşkaya Temizel, T. Nisan 2014. “Kalabalık Videolarında Bölgesel Davranışların Kümelenmesi”, IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.
- Gündüz, A. E., Taşkaya Temizel, A., Temizel, A. Nisan 2014. “Kalabalık Videolarında Yoğunluk Kestirimi”, IEEE 22. IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.
- Güler, P., Temizel, A., Taşkaya Temizel, T. Nisan 2013. “Kalabalık Videolarında Aykırılık Tespiti İçin Öğreticisiz Bir Yöntem”, IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.





- Gündüz, A. E., Temizel, A., Taşkaya Temizel, T. Nisan 2013. “Kalabalık Dinamiklerinin Çıkartılması İçin Özniteliklerin Tespit ve Takibi”, IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.

Projenin başarı ölçütleri proje önerisinde aşağıdaki şekilde belirtilmiştir:

- “Kalabalık anomali tespitinde literatürdeki temel yayınlardan daha iyi sonuç almak (true positive, false positive değerleri açısından). Bunun için hedeflenen literatürdeki yeni bir çalışmayı baz alarak doğru pozitif oranının (TP) 0.73 ve yanlış pozitif oranının (FP) ise 0.3'den daha iyi olmasını hedeflemekteyiz.”  
Projenin ilk evrelerinde yaptığımız çalışmalarda literatürde temel alınan yayınlarda en çok kullanılan veri kümelerinde recall değeri [0.93-1] arası, precision değeri ise [0.86-0.93] arası elde ettik (projenin başında hedeflediğimiz recall değerinin –  $(TP/(TP+FP))$  ) 0.70'in oldukça üzerinde). Bunun üzerinde daha ileriki çalışmalarımızda literatürde geçen daha zorlu bir veri kümesi kullanılarak karşılaştırmalar yapılmıştır. Bu veri kümesi kullanılarak elde edilen proje başarımları Şekil 12'de verilmiştir ve literatürde gerçek zamanlı çalışan diğer yöntemlere göre başarımları daha yüksektir.
- “Anomali tespitinin gerçek zamanlı olarak yapılabilmesi.”  
Intel Core i7-3630 QM, 2.40 GHz merkezi işlemcili ve 8 GB RAM belleğe sahip bir PC'de öznitelik tespiti, betimlemesi ve eşleştirilmesi için OpenCV ve Visual Studio 2010, ön işleme ve veri analizi için de Matlab üzerinde BNT toolbox kullanıldığında saniyede 34 kare işlenebildiği görüşmüştür. Bu gerçek zamanlı çalışma için koymuş olduğumuz 25 kare/saniye hedefinin üzerindedir.
- Algoritmanın iç mekandaki kalabalık görüntüleriyle çalışabilir olması.  
Projedeki deneyler iç mekan simülasyon görüntülerinin yanı sıra dış ortamın değişken koşulları nedeniyle daha zorlayıcı olan dış mekan görüntüleri üzerinde de yapılmış ve çalışır olduğu gösterilmiştir.
- Zamana ve mekana göre değişen anomalilerin kabul edilir ölçüde saptanması.  
Yukarıda bahsedildiği üzere yöntemler zaman ve mekana göre değişiklik gösteren anomalilerin tespit edilebilmesi için tasarlanmış ve test edilen veri kümelerinde hedeflenen performansı göstermiştir.



## **Ekler**

Unity3D kullanarak oluşturmuş olduğumuz sentetik verilerden örnek videolar sisteme yüklenmiştir.

**TÜBİTAK**  
**PROJE ÖZET BİLGİ FORMU**

Proje Yürütücüsü:	Doç. Dr. ALPTEKİN TEMİZEL
Proje No:	112E141
Proje Başlığı:	Kalabalık Ortam Video Gözetleme Uygulamalarında Anomali Tespiti
Proje Türü:	Araştırma
Proje Süresi:	20
Araştırmacılar:	TUĞBA TAŞKAYA TEMİZEL
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	ORTA DOĞU TEKNİK Ü. ENFORMATİK ENSTİTÜSÜ
Projenin Başlangıç ve Bitiş Tarihleri:	01/10/2012 - 01/06/2014
Onaylanan Bütçe:	129637.0
Harcanan Bütçe:	103968.75
Öz:	<p>Video görüntüsünde belirgin nesnelere olduğunda, nesne-bazında izleme ve gösterim ile normal davranışlardan sapmalar hesaplanarak aykırılıklar tespit edilebilir. İzdiham durumlarında oluşan düzensiz hareketler, kavgalar, ani hareketlilikler ya da insanlar tarafından fırlatılan nesnelere aykırılıklara örnektir. Nesne sayısı az olduğunda nesnelere takip edilerek yörüngeleri ve hızları gibi özelliklerin değerlendirilmesi ile bu tip aykırılıkların tespitlerinin yapılması mümkündür. Fakat nesne sayısı arttığında olağandışı olayların tespiti oluşan kapatmalar ve yörünge kesikliklerinden dolayı nesne-bazında izleme ve gösterim ile güçtür. Ayrıca birden fazla nesnenin olduğu senaryolarda, nesne tabanlı gösterim öğrenmeyi ve çıkarım yapmayı güçleştiren karmaşık bir model yapısına yol açar.</p> <p>Kalabalık görüntülerindeki aykırılık tespiti için yakın zamanda piksel tabanlı gösterim teknikleri kullanılmaya başlanmıştır. Bu tekniğe dayalı çözümler birçok nesnenin bulunduğu görüntülerde kabul edilebilir bir başarı vermektedir. Fakat hesaplama yükleri nedeniyle gerçek zamanlı sistemler için kullanılması güçtür. Ayrıca literatürdeki yöntemler zamana bağlı değişkenlik gösteren ortama bağlı aykırılıkları ele almamaktadırlar.</p> <p>Bu projede uzam ve zamana göre değişkenlik gösteren aykırılık örüntülerini herhangi bir öncü kural kümesi kullanmadan öğrenip tespit edebilen piksel tabanlı analiz ve gösterim tekniklerine dayalı bir yöntem geliştirilmiştir. Önerilen yöntem kalabalık yoğunluğunun tespiti ve yoğunluğa uygun model seçilmesi, kalabalık videolarında bölgesel davranışların kümelenmesi, davranışların zaman-uzamsal modellenmesi ve aykırılık tespiti aşamalarından oluşur.</p> <p>Bu çalışmada piksel tabanlı analiz ORB öznelikleri kullanılarak yapılmıştır. Bu öznelikler yardımı ile kalabalık yoğunluğuna göre sınıflandırma sağlanır ve uygun model seçilir. Bölgesel davranışların kümelenmesi için optik akış metodu ile hız ve yön bilgisi alınmasının ardından bu bilgiler Finite Time Lyapunov Exponents (FTLE) kullanılarak hız ve yöne bağlı olarak değerler tablosuna dönüştürülür ve bu tablo yardımıyla aykırılık gösteren bölgeler tespit edilebilir. Ayrıca farklı karakteristiğe sahip davranış bölgeleri Coupled Hidden Markov Model (CHMM) kullanılarak zaman-uzamsal olarak modellenir ve aykırılıkların tespiti sağlanır. Önerilen yöntemler halihazırda mevcut açık veri kümelerinin yanı sıra proje kapsamında kayıtlı edilen gerçek video görüntülerinde ve oluşturulan simülasyon verileri üzerinde ve deneyerek sonuçlar referans bilgileri ile karşılaştırılmıştır.</p>
Anahtar Kelimeler:	Akıllı Video Analizi, Model Füzyonu, Bilgisayarla Öğrenme, Kalabalık Analizi, Anomali Tespiti
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır

Proje Yapılan Yayınlar:	<p>1- Kalabalık Videolarında Bölgesel Davranışların Kümelenmesi (Bildiri - Ulusal Bildiri - Sözlü Sunum),</p> <p>2- Local Anomaly Detection in Crowded Scenes Using Finite-Time Lyapunov Exponent Based Clustering (Bildiri - Uluslararası Bildiri - Sözlü Sunum),</p> <p>3- Kalabalık Videolarında Aykırılık Tespiti İçin Öğreticisiz Bir Yöntem (Bildiri - Ulusal Bildiri - Sözlü Sunum),</p> <p>4- Kalabalık Dinamiklerinin Çıkarılması İçin Özniteliklerin Tespit ve Takibi (Bildiri - Ulusal Bildiri - Sözlü Sunum),</p> <p>5- Kalabalık Videolarında Yoğunluk Kestirimi (Bildiri - Ulusal Bildiri - Sözlü Sunum),</p> <p>6- Real-Time Global Anomaly Detection for Crowd Video Surveillance Using SIFT (Bildiri - Uluslararası Bildiri - Sözlü Sunum),</p> <p>7- Pedestrian Zone Anomaly Detection by Non-Parametric Temporal Modeling (Bildiri - Uluslararası Bildiri - Poster Sunum),</p>
-------------------------	---

TÜBİTAK