

Yapısal Benzerlik ve Optik Akış Histogramı ile Anomali Tespiti

Anomaly Detection with Structural Similarity and Optical Flow Histogram

Kadriye Öz¹, İsmail Rakıp Karas²

¹Mekatronik Mühendisliği Bölümü, Karabük Üniversitesi, Karabük, Türkiye

²Bilgisayar Mühendisliği Bölümü, Karabük Üniversitesi, Karabük, Türkiye
{kadriyeoz, ismail.karas}@karabuk.edu.tr

Özetçe—Bu çalışmada, gözetim sistemleri için tasarlanmış bir anomali tespit ve lokalizasyon sistemi sunulmaktadır. Yeni bir özellik tanımlayıcı önerilmektedir. Normal durumları içeren videolardan optik akış histogramı ve yapısal benzerlik indeksi kullanılarak konum-zamansal tanımlayıcılar elde edilmektedir. Modellemede yapay sinir ağlarından öz düzenleyici haritalar kullanılmaktadır. Önerilen sistem UCSD verisetinde denenmiştir.

Anahtar Kelimeler—*anomali tespiti; optik akış histogramı; yapısal benzerlik indeksi; video gözetim.*

Abstract—In this paper, we present an anomaly detection and localization system for surveillance systems. A new feature descriptor is proposed. The spatio-temporal identifiers are obtained by using optical flow histogram and the structural similarity index from the videos that contain normal conditions. An artificial neural network, Self-organizing maps are used in modeling. The proposed system has been tested on the UCSD dataset.

Keywords—*anomaly detection; optical flow histogram; structural similarity index; video surveillance.*

I. GİRİŞ

Her geçen gün kameralar hayatımızda daha fazla yer kaplamaktadır. Bunun bir sonucu olarak video gözetim sistemleri yaygınlaşmıştır. Videolarda beklenen durum ve davranışların dışında kalan örüntülerin tespit edilmesi önemli bir ihtiyaç haline gelmiştir. Bu durum anomali tespiti olarak da ifade edilebilir.

Anomali olarak ifade edilen durumların gözetimin yapıldığı alana göre değişebileceği, anomalilerin her zaman şüpheli davranışlar olmayabileceği de göz önünde bulundurulmalıdır. Örneğin bir stadyumda koşan insanlar normal iken, yürüyüş yolunda anomali sayılabilir. Ayrıca anomali sayılabilecek davranışlar normal durumlara göre nadiren ortaya çıkmaktadır. Bütün bu bilgiler göz önüne

alındığında anomalilerin tespitinde normal davranışların kalıplarının çıkarılması ve bu kalıplara uymayanların anomali olarak sınıflandırılması tercih edilmiştir.

Anomali tespiti 2000 yılından bu yana gün geçtikçe ilgi çeken bir alan olmuştur [1]. Bu alanda yapılan çalışmalar farklı özellik çıkarım yöntemleri ya da modelleme yöntemleri ortaya koyarak tespitteki doğruluğu artırmaya çalışmaktadırlar. Hareketi temsil etme yeteneği ile optik akış hesaplamaları pek çok çalışmada kullanılmaya devam etmektedir [2]–[6]. Ancak yaptığımız çalışmada [7] optik akış yönteminin başarılı olsa da tek başına yeterli olmadığını gözlenmiştir. Bu nedenle hareket bilgisi yanında nesnelerin görünüş özelliklerinin de dikkate alınmasına karar verdik. Nesnelere ait yapısal karşılaştırma için nesne algılama çalışmalarında sıkça kullanılan yapısal benzerlik indisinden faydalanılmıştır.

II. ANOMALİ TESPİTİ

Anomali tespitinde ilk adım video çerçevelerinden özellik çıkarımıdır. Özellik çıkarımı için çerçeveler hücrelere bölünür. Hücreler, konumsal özellikleri itibarıyla anomalinin yerinin görüntülenmesinde önem arz etmektedir. Hücrelerin birbiri üstüne gelmeyen KxK boyutlarında seçilmesi işlem kolaylığı sağlamaktadır [8]. Bu çalışmada 20x20 boyutlarında hücreler kullanılmıştır.



Şekil 1. Çerçevelerin hücrelere bölünmesi

Şekil 1'de örnek bir çerçeve için hücrelerin gösterimi verilmiştir. Her hücre için bir adet özellik vektörü hesaplanmaktadır. 17 değerden oluşan özellik vektörünün ilk sekiz değerini optik akış histogramı, sonraki 9 değerini ise yapısal benzerlik indisi oluşturmaktadır.

Öz-Düzenleyici Haritalar (Self-Organizing Maps (SOM)) yardımı ile normal durumlar modellenir. Her hücre için ayrı modelleme yapıldığından hücrelere özgü olan hareket modelleri ortaya konmaktadır. Test aşamasında ise hareket modellerine uymayan durumlar anomali olarak işaretlenir.

A. Optik Akış Histogramı

Optik akış, video çerçevelerinde her resmin bir sonraki resimle ilintili, nesnelerin belirgin hareketlerinin gösterildiği bir vektör seti olarak tanımlanabilir. Parlaklığın birbirini takip eden çerçevelerde değişmeyeceği öngibisi ile vektörler oluşturulur. Resimdeki her piksel için yer değişimi parlaklığın değişmezliği ile,

$$I(x, y, t) = I(x + dx, y + dy, t + dt) \quad (1)$$

elde edilebilir. Burada I görüntü dizisi, $[dx, dy]$, $[x, y]$ piksel koordinatlarının t ve dt çerçeve aralığındaki değişimi olarak ifade edilebilir [9].

Her hücredeki tüm piksellerin hareket yönü ve büyüklüğü, Liu [10] tarafından geliştirilen optik akış algoritması kullanılarak hesaplanır. Histogramlar optik akışın yönleri göre büyüklüklerinin toplanması ile oluşturulur. 0-360 derece arasında 8 eşit parçaya bölündüğünde " $\leftarrow, \rightarrow, \uparrow, \downarrow, \nearrow, \nwarrow, \swarrow, \searrow$ " yönleri elde edilir. Örneğin -22,5 ile 22,5 derece arasındaki açılara ait büyüklükler toplanarak " \rightarrow " yönüne ait değer bulunur. 8 farklı yön için toplanan hareket büyüklükleri ile hücre optik akış histogramları elde edilir.

B. Yapısal Benzerlik

Yapısal Benzerlik İndisi (Structural Similarity (SSIM) Index) 2004 yılında Wang ve arkadaşları tarafından duyurulmuştur [11]. İki sinyal arasındaki yapısal benzerliğin bir ölçümü olan bu indis nesne algılama ölçümleri alanında geniş bir uygulama yelpazesinde popülerlik kazanmıştır [12]. Görüntü işleme problemlerinde algılanan görüntü / video kalitesini iyileştirmek için SSIM'in optimizasyon çerçevelerine dahil edildiği, örneğin görüntü gürültü ayrıştırma, görüntü restorasyonu, ekolayzır tasarımı, kontrast geliştirme, damgalama, görüntü yaklaştırma gibi çeşitli çalışmalar vardır [12]. Anomali tespiti çalışmalarında da yörüngelerin benzerliğinin hesaplanmasında [13] ve özellik çıkarımında [14], [15] kullanılmıştır.

SSIM, benzerlik ölçümü görevini üç karşılaştırmaya ayırır: parlaklık, kontrast ve yapı. x ve y yi birer görüntü kabul edersek, iki görüntü arasındaki karşılaştırma,

$$SSIM(x, y) = [I(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (2)$$

şeklinde ifade edilir. Parlaklık $I(x, y)$, kontrast $c(x, y)$ ve yapı $s(x, y)$ fonksiyonları ile karşılaştırılmaktadır. Fonksiyondaki α , β ve γ karşılaştırmaların etki oranlarını ifade etmektedir ve $\alpha = \beta = \gamma = 1$ seçilerek ifade basitleştirilebilir. $I(x, y)$ sinyal ortalamaları μ_x ve μ_y 'nin fonksiyonudur.

$$I(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (3)$$

$c(x, y)$ standart sapmalar σ_x ve σ_y 'nin fonksiyonudur.

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (4)$$

$s(x, y)$ için görüntüler kendi standart sapması ile normalize edilir, böylece fonksiyon $(x - \mu_x)/\sigma_x$ ve $(y - \mu_y)/\sigma_y$ üzerinden oluşturulur.

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (5)$$

Eşitliklerdeki C_1 , C_2 ve C_3 normalleştirme sabitleri olarak tanımlanmıştır. Kararsızlığın önlenmesinde etkilidir. Sıfıra yakın değerler alırlar.

Her hücre için 8 yan komşusu ve kendinden bir önceki çerçevedeki komşusu için yapısal benzerlik indisi hesaplanır. Böylece ilgili hücreyi tanımlayan 9 özellik değeri elde edilmiş olur. Optik akış histogramı ile elde edilen 8 özelliğe ilave edildiğinde bir hücre 17 değer ile tanımlanmaktadır.

C. Öz-Düzenleyici Haritalar ile Modelleme

Denetimsiz bir diğer değişle öğretmensiz, eğitmensiz bir yapay sinir ağı modeli olan Öz-Düzenleyici Haritalar (Self-Organizing Maps (SOM)) Kohonen tarafından 1981 yılında duyurulmuştur [16]. Burada ele alınan yöntem bir veri analiz yöntemidir. Veri öğeleri arasındaki benzerlik ilişkilerinin korunduğu, yüksek boyutlu veri dağılımlarının düşük boyutlu izdüşüm görüntüleri üretilir. Bir bakıma, karmaşık verilerin azaltılmış özetleri oluşturulur. Bu yöntem, 1982'den beri bilim, teknoloji, finans ve diğer birçok alanda kullanılmıştır. Üzerinde 10 000'den fazla bilimsel makale ve 20'den fazla kitap yayımlanmıştır [17].

Yapılan çalışmada her bir hücre için ağ eğitimi yapılarak o hücreye özgü sınıflandırmalar elde edilmektedir. Bu çalışmada 4x4 boyutlu bir haritalandırma yapılmaktadır. Hücreye ait ağırlık vektörleri saklanmaktadır. Test görüntülerindeki hücrelerin bu ağırlıklar kullanılarak sınıflara olan uzaklıkları ölçülmektedir. Uzaklık değerleri hücrenin sınıfa dahil olup olmadığını belirlemektedir. Herhangi bir sınıfa dahil olamayan hücre anomali olarak işaretlenmektedir.

III. DENEYSEL SONUÇLAR

Önerilen anomali tespit sistemi UCSD [18] Pedst veri setinde denenmiştir. UCSD veri seti yaya geçitlerine bakan, yüksek bir yere monte edilmiş sabit bir kamera tarafından çekilmiş görüntülerden elde edilmiştir. Yaya geçidinden elde edilen görüntüler 200'er çerçeveli görüntüler şeklinde sınıflandırılmıştır. Normal olarak kabul edilenler yalnızca yayaaları içerir ve eğitim sınıfını oluşturmaktadırlar. Yaya olmayan varlıkların (bisikletliler, patenciler, küçük arabalar) yürüyüş yollarında dolaşımı, anormal yaya hareket desenlerini kapsar. Bütün anormallikler doğal olarak ortaya çıkmaktadır; diğer bir deyişle, veri kümesinin toplanması amacıyla sahnelenmemiştir. Veriler, her biri farklı bir sahneye karşılık gelen 2 alt gruba ayrılmıştır. 34 eğitim video örneği ve 36 test video örneği içerir [18].

Eğitim videolarından elde edilen konum zamansal özellik tanımlayıcılar modellenerek her hücre için normal durumları modelleyen sınıflar oluşturulmuştur. Test videolarında yine her hücre için konum zamansal tanımlayıcılar hesaplanarak ilgili sınıflara dahil olup olmadığı kontrol edilir.



Şekil 2. Kameraya olan uzaklığın anomali tespiti üzerine etkisi

Yapılan deneyler sonucunda anomali tespit sisteminin kameraya yakınlığı-uzaklığı fark etmeksizin tespit edileceği Şekil 2.'de görüldüğü üzere gözlenmiştir.

Şekil 3.'de aynı anda iki farklı anomalinin tespiti, çim alanda yürüyenlerin tespiti ve yaya yolunda araba ve bisikletlilerin tespiti örnekleri görülmektedir.



Şekil 3. Farklı anomali türlerinin tespiti

IV. SONUÇLAR

Bu çalışmada anomali tespit sistemi gerçekleştirilmiştir. Video gözetim sistemlerinde anomali içeren çerçevelerde anomalinin yeri ilgili hücreler işaretlenerek kullanıcıya sunulmuştur. İleriki dönemlerde hücreler yerine ilgili pikseller işaretlenerek sunulmak istenmektedir.

KAYNAKÇA

- [1] K. Öz and S. Görgünöğlu, "Video Gözetim Sistemlerinde Anomali Tespiti Üzerine Bir Derleme," *El-Cezeri Fen ve Mühendislik Derg.*, vol. 2016, no. 3, pp. 506–512, 2016.
- [2] J. Kim and K. Grauman, "Observe locally, infer globally: A space-time MRF for detecting abnormal activities with incremental updates," *2009 IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. Work. CVPR Work. 2009*, no. June, pp. 2921–2928, 2009.
- [3] R. Parvathy, S. Thilakan, M. Joy, and K. M. Sameera, "Anomaly Detection Using Motion Patterns Computed From Optical Flow," 2013.
- [4] Y. Liu, "Abnormal Crowd Behavior Detection Based on Optical Flow and Dynamic Threshold *," no. 863, pp. 2902–2906, 2014.
- [5] K. P. Risha and A. C. Kumar, "Gradient operator in video after object detection by optical flow and morphological operation," in *2016 10th International Conference on Intelligent Systems and Control (ISCO)*, 2016, pp. 1–4.
- [6] R. V. H. M. Colque, C. Caetano, M. T. L. de Andrade, and W. R. Schwartz, "Histograms of Optical Flow Orientation and Magnitude and Entropy to Detect Anomalous Events in Videos," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 27, no. 3, pp. 673–682, Mar. 2017.
- [7] K. Öz and S. Görgünöğlu, "Anomaly Detection System With Optical Flow Method," in *2nd International Conference on Science, Ecology and Technology-2016 (ICONSET-2016)*, 2016, p. 490.
- [8] D. Xu, X. Wu, D. Song, N. Li, and Y.-L. Chen, "Hierarchical Activity Discovery within Spatio-Temporal Context for Video Anomaly Detection," pp. 3597–3601, 2013.
- [9] B. Horn and B. Schunck, "'Determining optical flow': A retrospective," *Artif. Intell.*, vol. 59, no. 1–2, pp. 81–87, 1993.
- [10] C. Liu, "Beyond pixels: exploring new representations and applications for motion analysis," 2009.
- [11] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: From error visibility to structural similarity," *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600–612, 2004.

- [12] D. Brunet, E. R. Vrscay, and Z. Wang, "On the mathematical properties of the structural similarity index," *IEEE Trans. Image Process.*, vol. 21, no. 4, pp. 1488–1495, 2012.
- [13] X. Fan, B. Zheng, M. Li, W. Li, J. Zhang, and Z. Zhang, "Characterization for Complex Trajectory and Anomaly Detection," *IEEE*, 2014.
- [14] M. Fathy, M. Sabokrou, and M. Hosseini, "Abnormal event detection and localization in crowded scenes based on Similarity Structure," *MODARES J. Electr. Eng.*, vol. 14, no. 3, pp. 1–12, Nov. 2016.
- [15] M. Sabokrou, M. Fathy, M. Hosseini, and R. Klette, "Real-Time Anomaly Detection and Localization in Crowded Scenes," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 1, pp. 18–32, Nov. 2015.
- [16] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biol. Cybern.*, vol. 43, no. 1, pp. 59–69, 1982.
- [17] T. Kohonen, *MATLAB Implementations and Applications of the Self-Organizing Map*. Unigrafia Oy, Helsinki, Finland, 2014.
- [18] "UCSD Anomaly Detection Dataset." [Online]. Available: <http://www.svcl.ucsd.edu/projects/anomaly/dataset.htm>.