

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 veris etinde 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.

II. ANOMALİ TESPİTİ

Anomali tespitinde ilk adım video çerçevelerinden özellik çıkarımıdır. Özellik çıkarımı için çerçeveler hücrelere bölünür. Çerçeve boyutlarını ($W \times H$) olarak isimlendirirsek hücrelerin birbiri üstüne gelmeyen $K \times K$ boyutlarında olması gerekmektedir. Bu çalışmada 20×20 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 indeksi 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 önbilgisi 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 [1].

Her hücredeki tüm piksellerin hareket yönü ve büyüklüğü, Liu[2] 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 [3]. İki sinyal arasındaki yapısal benzerliğin bir ölçümü olan bu indis nesne algılama ölçümleri alanında geniş bir uygulama yelpazesinde popülerlik kazanmıştır [4]. Görüntü işleme problemlerinde algılanan görüntü / video kalitesini iyileştirmek için SSIM'in optimizasyon çerçevelerine dahil edildiği, örneğin görüntü gürültü ayırıştırma, görüntü restorasyonu, ekolayzır tasarımı, kontrast geliştirme, damgalama, görüntü yaklaştırma gibi çeşitli çalışmalar vardır [4]. Anomali tespiti çalışmalarında da yörüngelerin benzerliğinin hesaplanmasında [5] ve özellik çıkarımında [6], [7] 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 alır.

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 deyişle öğretmensiz, eğitimsiz bir yapay sinir ağı modeli olan Öz-Düzenleyici Haritalar (Self-Organizing Maps (SOM)) Kohonen tarafından 1981 yılında duyurulmuştur [8]. 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 yayınlanmıştır [9].

Yapılan çalışmada her bir hücre için ağ eğitimi yapılarak o alana özgü sınıflandırmalar elde edilmektedir. Bu çalışmada 4x4 boyutlu bir haritalandırma yapılmaktadır. Hücreye ait ağırlık vektörleri saklanarak test görüntülerinde hücrenin her sınıfa uzaklığı ölçülerek sınıflara dahilliği belirlenir. Herhangi bir sınıfa dahil olamayan hücre anomali olarak işaretlenmektedir.

III. DENEYSEL SONUÇLAR

Önerilen anomali tespit sistemi UCSD [10] Ped1 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 yayaları 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.

Eğitim videolarından elde edilen 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 anomalilerin kameraya yakınlığı-uzaklığı farketmeksizin tespit edildiği Şekil 2.'de görüldüğü üzere gözlenmiştir.



Şekil 3. Farklı anomalilerin tespiti

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

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] B. Horn and B. Schunck, "Determining optical flow: A retrospective," *Artif. Intell.*, vol. 59, no. 1-2, pp. 81-87, 1993.
- [2] C. Liu, "Beyond pixels: exploring new representations and applications for motion analysis," 2009.
- [3] 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.
- [4] 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.
- [5] X. Fan, B. Zheng, M. Li, W. Li, J. Zhang, and Z. Zhang, "Characterization for Complex Trajectory and Anomaly Detection," *IEEE*, 2014.
- [6] 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.
- [7] 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.
- [8] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biol. Cybern.*, vol. 43, no. 1, pp. 59-69, 1982.
- [9] T. Kohonen, *MATLAB Implementations and Applications of the Self-Organizing Map*. Unigrafia Oy, Helsinki, Finland, 2014.
- [10] "UCSD Anomaly Detection Dataset." [Online]. Available: <http://www.svcl.ucsd.edu/projects/anomaly/dataset.htm>.