



استفاده از نمایش پراکنده و همکاری دوربین‌ها برای کاربردهای نظارت بینایی

اصغر فیضی

دانشگاه دامغان، دامغان، سمنان، ایران

چکیده

مسئله آشکارسازی رفتارهای غیرمعمول براساس ویدئو، درحقیقت شناسایی الگوها در داده‌هایی است که با رفتارهای مورد انتظار مطابقت ندارند. درهمین‌اواخر برای خوشه‌بندی رفتارها و آشکارسازی رفتارهای غیرمعمول، از روش‌های بازسازی پراکنده استفاده می‌شود. در این مقاله از نمایش پراکنده ویژگی‌ها و همکاری دوربین‌ها، برای شناسایی رفتارها و آشکارسازی رفتارهای غیرمعمول استفاده می‌شود. ابتدا برای هر محل در فریم تصویر، یک ویژگی که دارای استقلال هندسی است، استخراج می‌شود؛ سپس برای یک دوربین، ماتریس دیکشنری A محاسبه و به‌عنوان یک مجموعه از مدل رفتاری در نظر گرفته می‌شود. حال، تحت عنوان مسئله همکاری دوربین‌ها، ماتریس دیکشنری یادگرفته‌شده به دوربین دیگر منتقل می‌شود و در دوربین جدید برای آشکارسازی غیرمعمول‌ها مورد استفاده قرار می‌گیرد. برای یادگیری ماتریس دیکشنری، یک روش سلسله‌مراتبی با استفاده از خوشه‌بندی طیفی پیشنهاد و یک معیار اندازه‌گیری با استفاده از نمایش پراکنده برای آشکارسازی رفتارهای غیرمعمول ارائه می‌شود. نتایج آزمایشی، مؤثر بودن ره‌یافت پیشنهادی در استفاده از همکاری دوربین‌ها برای آشکارسازی رفتارهای غیرمعمول را نشان می‌دهد.

واژگان کلیدی: نظارت بینایی، نمایش پراکنده، شناسایی رفتارها، رفتارهای غیرمعمول، اشتراک اطلاعات چند دوربین

Application of Sparse Representation and Camera Collaboration in Visual Surveillance Systems

Asghar Feizi

The Electrical Engineering Department, Damghan University, Damghan, Semnan, Iran

Abstract

With the growth of demand for security and safety, video-based surveillance systems have been employed in a large number of rural and urban areas. The problem of such systems lies in the detection of patterns of behaviors in a dataset that do not conform to normal behaviors. Recently, for behavior classification and abnormal behavior detection, the sparse representation approach is used. In this paper, feature sparse representation in a multi-view network is used for the purpose of behavior classification and abnormal behavior detection. To serve this purpose, a geometrically independent feature is first extracted for each location in the image. Then, for each camera view, the matrix for the dictionary A is calculated, which is considered as a set of behavior models. In order to share information and make use of the trained models, the learned dictionary matrix from the experienced camera is transferred to inexperienced cameras. The transferred matrix in the new camera is subsequently used to detect abnormal behaviors. A hierarchical method on the basis of spectral clustering is proposed for learning the dictionary matrix. After sparse feature representation, a measurement criterion, which makes use of the representation, is presented for abnormal behavior detection. The merit of the method proposed in this paper is that the method does not require correspondence across cameras. The direct use of the dictionary matrix and transfer of the learned dictionary matrix from the experienced camera to inexperienced ones, are tested on several real-world video datasets. In both cases, desirable improvements in abnormal behavior detection are obtained. The experimental results point to the efficacy of the proposed method for camera cooperation in order to detect abnormal behaviors.

Keywords: Visual Surveillance, Sparse Representation, Behavior Recognition, Abnormal Behavior, Camera Collaboration

*Corresponding author

* نویسنده عهده‌دار مکاتبات

فصلنامه



پراکندگی مورد استفاده و رخدادها مورد آزمایش قرار می‌گیرند تا مشخص شود این رخدادها برحسب ترکیب خطی پراکنده کدام یک از نمونه‌های آموزش معمول یا غیرمعمول می‌توانند بیان شوند.

۱-۱- مرور کارهای پیشین

روش‌های موجود برای آشکارسازی رفتارهای غیرمعمول به‌طورعمومی در دو خوشهٔ رهیافته‌های با نظارت و رهیافته‌های بدون نظارت قرار می‌گیرند. در مسألهٔ آشکارسازی رفتارهای غیرمعمول با نظارت، فرض بر این است که در مرحلهٔ آموزش تمام رفتارهای غیرمعمول، مشخص هستند؛ لذا می‌توان یک مدل از رفتارهای غیرمعمول را در مرحلهٔ آموزش تهیه و سپس در مرحلهٔ آزمایش با مقایسهٔ رفتار آزمایشی با مدل رفتارهای غیرمعمول، در مورد معمول یا غیرمعمول بودن آن رفتار تصمیم‌گیری کرد. از دیدگاه آماری این مسأله درحقیقت یک روش خوشه‌بندی مرسوم در حوزهٔ یادگیری ماشین است. بعد از انتخاب تعدادی ویژگی، تابع چگالی احتمال رفتارهای غیرمعمول تخمین زده می‌شود و درنهایت با اعمال یک آزمایش نرخ احتمال، رفتارهای غیرمعمول آشکارسازی می‌شوند. مرجع [1] یک رهیافت نسبت هیستوگرام برای نمایش ویژگی‌های هدف ارائه داده‌اند. در این مرجع، رفتارهای غیرمعمول مانند رهاکردن چمدان، آشکارسازی می‌شوند. مرجع [2] یک پروفایل رفتاری بر اساس رخداد گسسته، برای آشکارسازی رفتارهای غیرمعمول ارائه داده‌اند. یک مدل مارکوف مخفی بر اساس محل، اندازه و سرعت و بر اساس خوشه‌های داده، آموزش داده می‌شود؛ سپس یک مدل ترکیبی استخراج می‌شود. وقتی یک ویدئوی آزمایشی به‌دست‌آمد، ویژگی‌ها استخراج و تحت مدل آموزشی آزمایش می‌شوند. اگر مقدار احتمال کم‌تر از یک آستانه باشد، ویدئوی آزمایشی به‌عنوان غیرمعمول در نظر گرفته می‌شوند. مشکل اصلی رهیافته‌های با نظارت این است که در داده‌های آموزش، نمونه‌های غیرمعمول در مقایسه با نمونه‌های معمول، بسیار اندک و به‌دست‌آوردن نمونه‌های غیرمعمول نیز مشکل است. همچنین این روش‌ها قادر به شناسایی رفتارهای غیرمعمول جدید نخواهند بود. در دهه گذشته، پژوهش‌گران بر رهیافته‌های بدون نظارت تمرکز کرده‌اند. رهیافته‌های بدون نظارت به‌طورعمومی به‌معنای معلوم‌نبودن برچسب‌ها است. در این رهیافته‌ها یک فرض ساده وجود دارد و آن این است که در داده آموزش نمونه‌های معمول خیلی بیش‌تر از نمونه‌های غیرمعمول است. مرجع [3] بر اساس ساختار کشف

امروزه با افزایش تقاضا برای ایمنی و امنیت، در بسیاری از محیط‌های شهری و روستایی، سامانه‌های نظارتی^۱ براساس ویدئو به‌کار گرفته شده‌اند؛ لذا تعداد زیادی از ویدئوها که در برگیرندهٔ رفتارهای غیرمعمولی^۲ هم‌چون: تجاوز، جرم، تصادف، تروریسم، خرابکاری و دیگر رفتارهای مشکوک هستند، می‌توانند جمع‌آوری و تحلیل شوند. از آنجایی که تحلیل دستی این حجم گسترده از داده‌ها پرهزینه است، لذا یک نیاز مبرم برای توسعه ابزارهای نرم‌افزاری موثر که بتوانند در تفسیر و تحلیل خودکار یا نیمه‌خودکار داده‌های ویدئویی مورد استفاده قرار گیرند، وجود دارد. تفسیر و تحلیل خودکار یا نیمه‌خودکار داده‌های ویدئویی در زمینه‌های متعددی از جمله نظارت، اجرای قانون، مدیریت و کنترل ترافیک می‌توانند استفاده شوند. مسأله آشکارسازی رفتارهای غیرمعمول بر اساس ویدئو، درحقیقت شناسایی الگوها در داده‌هایی است که با رفتارهای مورد انتظار مطابقت ندارند و لذا نیازمند اقدام و توجه ویژه‌ای هستند. مسأله آشکارسازی رفتارهای غیرمعمول براساس ویدئو درهمین‌اواخر به‌عنوان یک مسأله آزمایش نرخ احتمال^۳ (LRT) با این فرض که اطلاعات در مورد توزیع رخدادهای معمول و غیرمعمول در دسترس می‌باشد، مطرح شده است. در بیش‌تر موارد فرض بر این است که در داده‌های آموزش، رخدادهای غیرمعمول به اندازه کافی موجود هستند (یادگیری با نظارت^۴)؛ اما در بسیاری از مسائل جهان واقعی، توزیع رخدادهای معمول و غیرمعمول مشخص نیست و لذا فرض یادگیری با نظارت درعمل صادق نیست. چالش‌های موجود در سامانه‌های آشکارسازی رفتارهای غیرمعمول بر اساس ویدئو شامل موارد زیر است:

- ۱- وجود نوفه در داده‌های نظارتی و انسداد هدف‌ها؛
- ۲- آشکارسازی رفتارهای غیرمعمول شامل چند هدف؛
- ۳- کمبود رخدادهای غیرمعمول در داده‌های آموزش؛
- ۴- نمایش رخدادها با استفاده از چند ویژگی و چند دوربین. به‌تازگی روش‌های بازسازی پراکنده^۵ برای خوشه‌بندی تصاویر مورد استفاده قرار گرفته‌اند و نتایج به‌دست‌آمده نشان‌دهندهٔ کارآمد بودن روش پراکنده نسبت به مسأله خوشه‌بندی و آشکارسازی رفتارهای غیرمعمول است. این روش امروزه در آشکارسازی رفتارهای غیرمعمول بر اساس

¹ Surveillance systems

² Abnormal behavior

³ Likelihood Ratio Test (LRT)

⁴ Supervised learning

⁵ Sparse reconstruction

فریم‌های آزمایشی با احتمال پایین تحت مدل ترکیبی گوسی تخمین زده شده، به عنوان فریم غیرمعمول شناسایی می‌شوند. در رهیافت ارائه شده در [7] برای آشکارسازی رفتارهای غیرمعمول بر اساس ظاهر، گرادیان‌های مکان-زمان به عنوان توصیف کننده ظاهر استخراج و سپس یک روش جدید بر اساس بردار پشتیبان توصیف داده (SVDD)³ برای متمایز ساختن رفتارهای معمول و غیرمعمول استفاده می‌شود. مرجع [8] از روش تجزیه ویدئو برای آشکارسازی رفتارهای غیرمعمول استفاده می‌کند. رهیافت تجزیه ویدئو در این مرجع از دو قسمت تشکیل شده است. ابتدا در هر فریم ویدئویی، تعداد زیادی از نامزدهای هدف را آشکار و سپس آن‌ها را به فرض‌های هدف مکان-زمان گروه بندی می‌کند.⁴ این مسأله به عنوان یک مسأله استنباطی در قالب یک مدل گرافیکی مطرح می‌شود. غیرمعمول‌ها در این مرجع، فرض‌های هدف غیرمعمولی هستند که پیکسل‌های پیش‌زمینه را پوشش می‌دهند؛ اما مطابقتی با نمونه‌های هدف معمول به دست آمده در مرحله آموزش ندارند. ایده اصلی رهیافت پیشنهاد شده در [9] برای آشکارسازی رفتارهای غیرمعمول دو مرحله دارد. ابتدا یک آرایه ویدئویی به تکه‌های مکان-زمان تقسیم بندی و یک مدل آماری بر اساس مدل نیمه پارامتری برای تعیین این که آیا یک تکه ویدئویی از لحاظ ظاهری مشکوک به غیرمعمول است یا نه، استفاده می‌شود؛ سپس برای اطمینان از این که آیا تکه‌های ویدئویی مشکوک به غیرمعمول به طور قطعی دارای رفتار غیرمعمول هستند یا نه، توصیف کننده‌های نزدیک ترین محل و بیشینه انرژی شار نوری استفاده می‌شوند. رهیافت ارائه شده [10] یک رهیافت در اصطلاح پایه⁵ است که در بیش تر کارها برای مقایسه مورد استفاده قرار می‌گیرد. این رهیافت به روش MPPCA⁶ معروف است. در این رهیافت از ویژگی شار نوری برای ساخت مدل‌های رفتاری نرمال و آشکارسازی رفتارهای غیر معمول و روش ارائه شده در [11] از ویژگی‌های خط سیر و شار نوری محلی، برای آشکارسازی رفتارهای غیرمعمول استفاده می‌کند. در بسیاری از پژوهش‌های انجام شده سعی بر این بوده که از خط سیرها به عنوان ویژگی استفاده کنند. رهیافت‌های موجود برای به دست آوردن خط سیرها از روش‌های تعقیب هدف استفاده می‌کنند. این رهیافت‌ها برای آشکارسازی غیرمعمول‌ها در صحنه‌های ترافیک جذاب هستند؛ زیرا در این حوزه روش‌های

سلسله مراتبی الگوهای رفتاری و با در نظر گرفتن محتوای مکان-زمان رفتارهای غیر معمول را در هر دو سطح سراسری و محلی، شناسایی می‌کند. در مرحله آموزش برای یادگیری الگوهای رفتاری معمول در سطح سراسری، هیستوگرام بردارهای شار نوری برای هر سلول محاسبه می‌شود. الگوریتم خوشه بندی k-means برای خوشه بندی سلول‌ها با استفاده از هیستوگرام شار نوری به کار می‌رود و خوشه‌های سلول‌ها با ویژگی‌های مشابه استخراج می‌شوند. تابع توزیع هر خوشه بر اساس تابع کرنل گوسین به دست می‌آید و به این ترتیب الگوهای رفتاری معمول اتمی در سطح سراسری محاسبه و در نهایت یک تابع انرژی تعریف می‌شود که با اندازه گیری عدم تشابه الگوهای رفتاری به دست آمده در مرحله آزمایش در مقایسه با الگوهای رفتاری معمول محلی و سراسری به دست آمده در مرحله آموزش، در مورد معمول یا غیرمعمول بودن آن رفتار تصمیم گیری می‌کند. مرجع [4] با استفاده از شبکه‌های عصبی کانولوشنی کامل (FCN)¹ و داده‌های موقتی، FCN با نظارت از پیش آموزش دیده را به یک FCN بدون نظارت انتقال می‌دهد. این رهیافت یک FCN با معماری جدید با بازدهی بالا از نظر زمانی برای آشکارسازی رفتارهای غیر معمول ارائه می‌دهد. روش ارائه شده در [5] یک روش کدگذاری پراکنده محدود شده برای آشکارسازی رهیافت‌های غیرمعمول در صحنه‌های ترافیک پیشنهاد می‌دهد. در این روش ابتدا غیر معمول بودن رفتارها از نظر اندازه و زاویه حرکت به طور مجزا مورد بررسی قرار می‌گیرند و سپس این دو بعد با هم ترکیب می‌شوند تا یک نتیجه آشکارسازی رفتار غیر معمول قوی تر به دست آید. مرجع [6] از رهیافت انتقال ذرات برای آشکارسازی رفتارهای غیرمعمول استفاده می‌کند. این روش ابتدا تصویر را به ناحیه‌هایی تقسیم بندی می‌کند (پیکسل‌های 10×10). برای هر ناحیه یک ذره در نظر می‌گیرد. هیستوگرام ذرات متحرک را در جهت x و y محاسبه کرده و سپس توزیع احتمال ذرات متحرک در جهت x و y را به دست می‌آورد. بر اساس این توزیع احتمال، آنتروپی ذرات متحرک در جهت x و y محاسبه شده و حاصل ضرب این دو آنتروپی به عنوان آنتروپی نهایی در نظر گرفته می‌شود. در مرحله آموزش برای هر فریم، آنتروپی هر ناحیه محاسبه و سپس بر اساس این آنتروپی، ویژگی توزیع ازدحام محاسبه می‌شود. بر اساس این ویژگی پارامترهای مدل ترکیبی نرمال (GMM)² تخمین زده و به عنوان مدل رفتاری معمول در نظر گرفته می‌شوند. حال در مرحله آزمایش،

³ Support Vector Data Description

⁴ Spatio-temporal object hypotheses

⁵ Baseline

⁶ Mixture of Probabilistic Principal Component Analyzers

¹ fully Convolutional Neural Networks

² Gaussian Mixture Model

بسیاری برای تعقیب هدف وجود دارد. مرجع‌های [12], [13] یک نمایش بردار حرکتی برای نمایش رخدادها با استفاده از مدل مارکوف دو حالتی پیشنهاد می‌دهد. مرجع [14] ابتدا ناحیه‌های نامزد را برای حذف اطلاعات اضافی و کاهش بار محاسباتی، استخراج می‌کنند؛ سپس ویژگی‌های هیستوگرام شار نوری (HOF)^۱ و الگوری دودویی محلی (LBP)^۲ برای نمایش ظاهر و حرکت نواحی نامزد، استخراج می‌شوند. در نهایت دو مدل مجزای ماشین بردار پشتیبان یک طبقه (one-class SVM)^۳ برای آشکارسازی رفتارهای غیر معمول استفاده می‌شوند. مرجع [15] استفاده از یک مدل بیزین سلسله‌مراتبی را پیشنهاد می‌کند. در این مدل داده‌های ویدئویی به تکه‌هایی تحت عنوان "فایل‌ها" تقسیم‌بندی و رخدادها به عنوان ویژگی‌های کوانتیزه شده یا به اصطلاح "واژه‌ها" در داخل این فایل‌ها در نظر گرفته می‌شوند. مرجع [16] بر اساس بیشینه احتمال بعدی (MAP)^۴ یک ره‌یافت جدید برای آشکارسازی رفتارهای غیر معمول ارائه می‌دهند. در این ره‌یافت ابتدا با استفاده از الگوریتم آشکارسازی اختلاف از پس زمینه، ناحیه‌های متحرک آشکار می‌شوند. همچنین این ره‌یافت از یک تابع احتمال برای مقایسه تشابه بین نمونه‌های آزمون و نمونه طراحی شده استفاده می‌کند. مرجع [17] رخدادها را به صورت حجم‌های مکان زمان نمایش می‌دهد و از درخت تصمیم‌گیری برای شناسایی رخدادها استفاده می‌کند. در ره‌یافت پیشنهاد شده در [18] ابتدا یک مرحله پیش پردازش برای کاهش حجم داده‌های آموزشی در مرحله آموزشی ارائه می‌شود؛ سپس ویژگی‌های HOF و مدل نرمال چندمتغیره برای آشکارسازی رفتارهای غیر معمول بر اساس ظاهر مورد استفاده قرار می‌گیرد. علاوه بر آن رفتارهای غیر معمول بر اساس حرکت نیز با استفاده از متوسط شار نوری آشکارسازی می‌شوند. در تمام این ره‌یافت‌ها یک انگیزه حرکت از روش‌های سنتی تعقیب بر اساس هدف، به سمت ره‌یافت‌های جدیدی که به مدل‌های آماری بر اساس محل استناد می‌کنند، مشاهده می‌شود. با توجه به کارهای انجام شده در زمینه آشکارسازی رفتارهای غیر معمول، چالش‌های اساسی که در این زمینه احساس می‌شود، به شرح زیر است:

۱- هر چند روش‌های بر اساس خط سیر، مزایای زیادی دارند، اما مشکلاتی نیز دارند. تعقیب هدف یک کار سخت است؛

به ویژه در حالت بلادرنگ و در صحنه‌های شهری که اغلب تعداد زیادی از هدف‌ها وجود دارند. چون آشکارسازی غیر معمول‌ها به کیفیت تعقیب هدف وابسته است، لذا خطای تعقیب به شدت روی نتیجه آشکارسازی رفتارهای غیر معمول تأثیر می‌گذارد. مسأله مهم بعدی نیز مسأله انسداد هدف‌ها است که یکی از موضوعات چالش بر انگیز در حوزه تعقیب هدف است.

۲- آشکارسازی رفتارهای غیر معمول با نظارت: بیشتر کارهای انجام شده در این زمینه به صورت نظارت شده است که فرض می‌کنند در داده‌های موجود در مرحله آموزش، نمونه‌های غیر معمول نیز به حد کافی وجود دارد؛ اما در جهان واقعی، جمع‌آوری نمونه‌های غیر معمولی که بیان‌گر تمام رفتارهای غیر معمول باشند، امکان پذیر نیست.

۳- بیشتر ره‌یافت‌های غیر معمول تنها از یک ویژگی و از یک نما (دوربین) برای نمایش و آشکارسازی رفتارهای غیر معمول استفاده می‌کنند. این مسأله موجب می‌شود که رفتار یک هدف فقط از یک بعد بررسی شود و ممکن است آن هدف از منظر آن ویژگی دارای رفتار معمول، اما از منظر دیگر به صورت غیر معمول رفتار کرده باشد.

۲-۱- روش پیشنهادی این مقاله

نوآوری ارائه شده در این مقاله در سه حوزه به شرح زیر است:

۱- برای رفع مشکل موجود در روش‌های براساس هدف (که در این روش‌ها ویژگی‌های استخراج شده به هدف وابسته است و به طور معمول از فرایند پرهزینه و دارای خطای بالای تعقیب هدف استفاده می‌شود)، در این مقاله یک روش بر اساس محل پیشنهاد و برای هر محل (بلوکی از پیکسل‌ها) یک ویژگی استخراج که این ویژگی به هدف بستگی ندارد و مرحله تعقیب هدف حذف می‌شود.

۲- روش پیشنهادی در این مقاله یک ره‌یافت بدون نظارت است. در مرحله آموزش فقط رفتارهای معمول وجود دارد. از مدل‌های رفتاری معمول به دست آمده در مرحله آموزش برای آشکارسازی رفتارهای غیر معمول استفاده می‌شود؛ لذا در این مقاله مشکلات ره‌یافت‌های بانظارت که باید نمونه‌های غیر معمول نیز در مرحله آموزش باشند، وجود ندارد.

۳- مرحله آموزش در هر ره‌یافت شناسایی رفتار، یک مرحله پرهزینه، زمان‌بر و دارای بار محاسباتی بالایی است. در این مقاله از همکاری بین دوربین‌ها برای آشکارسازی

¹ Histogram of Optical Flow

² Local Binary Pattern

³ One- class Support Vector Machine

⁴ Maximum a Posteriori

می‌شود و در نهایت بخش پایانی به نتیجه‌گیری از این مقاله اختصاص داده می‌شود.

۲- استخراج ویژگی

در روش‌های نمایش بر اساس محل، ویژگی‌های استخراج‌شده، مربوط به محل خاص و در سطح پیکسل هستند. در این ویژگی‌ها بر خلاف روش‌های نمایش بر اساس هدف، ویژگی‌های استخراج‌شده به هدف‌های خاص نسبت داده نمی‌شوند. مهم‌ترین روش نمایش بر اساس محل، تخمین پیکسل‌های پیش‌زمینه با استفاده از روش اختلاف پس‌زمینه است. یک روش ساده برای استخراج پیکسل‌های پیش‌زمینه، اختلاف فریم فعلی از تصویر پس‌زمینه است [20]؛ اما این روش به تغییرات شدت روشنایی در دوربین‌های نظارتی، حساس است و باعث ایجاد نوفه و اثرات نامطلوب در روند مدل کردن رفتارها می‌شود. برای حذف این مشکل یک روش مدل کردن پس‌زمینه قوی‌تر ارائه می‌شود. هدف این مدل این است که اطلاعات اخیر را در مورد آرایه‌ای از تصاویر داشته باشد و این اطلاعات را با تغییرات سریع در صحنه پس‌زمینه، به‌روز کند. فرض کنید X_1, X_2, \dots, X_N نمونه اخیر از مقادیر روشنایی یک پیکسل باشند؛ با استفاده از این نمونه‌ها، تابع چگالی احتمالی که این پیکسل دارای مقدار روشنایی x در زمان t باشد، به‌صورت غیر پارامتری با استفاده از تخمین‌زن کرنل k ، از رابطه (۱) تخمین زده می‌شود:

$$pr(x_t) = \frac{1}{n} \sum_{i=1}^N k(x_t - x_i) \quad (1)$$

اگر تابع تخمین‌زن کرنل k ، به‌صورت تابع نرمال (σ, Σ) که Σ پهنای باند (کواریانس) تابع کرنل را نمایش می‌دهد، انتخاب شود، در این صورت چگالی احتمال از رابطه (۲) به‌دست می‌آید:

$$pr(x_t) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma|^{\frac{1}{2}}} e^{-\frac{1}{2}(x_t - x_i)^T \Sigma^{-1} (x_t - x_i)} \quad (2)$$


با استفاده از این تخمین احتمالاتی، اگر رابطه $pr(x_t) \leq th$ ، برقرار باشد که th یک آستانه است، پیکسل x به‌عنوان پیکسل پیش‌زمینه در نظر گرفته می‌شود. بعد از به‌دست آوردن پیکسل‌های پیش‌زمینه، مرحله بعدی تعریف ویژگی رفتاری برای هر محل (بلوک از پیکسل‌ها) است. در این مقاله از ایده استفاده‌شده در [19] برای تعریف ویژگی استفاده و برای هر بلوک از پیکسل‌ها، مدت زمان اشغال بلوک

رفتارهای غیر معمول استفاده می‌شود. به این ترتیب که برای یک نمای دوربین در مرحله آموزش، ماتریس پراکنده دیکشنری استخراج و به‌عنوان مدل رفتاری در آن نمای دوربین در نظر گرفته می‌شود؛ سپس این مدل رفتاری می‌تواند در نمای دوربین دیگر که تازه وارد سامانه شده است، برای آشکارسازی رفتارهای غیر معمول استفاده شود و به این ترتیب مرحله آموزش برای دوربین جدید حذف می‌شود.

برای انجام روش پیشنهادی، در مرحله نخست با استفاده از روش اختلاف از پس‌زمینه، پیکسل‌های پیش‌زمینه آشکارسازی و برای کاهش بار محاسباتی، ویژگی‌های رفتاری برای نواحی متحرک استخراج می‌شود. در این مقاله ویژگی رفتاری بر اساس محل ارائه‌شده در [19] به‌عنوان ویژگی رفتاری مورد استفاده قرار می‌گیرد. این ویژگی دارای استقلال هندسی است؛ لذا از دید نماهای متفاوت دوربین‌ها یکسان است. مرحله بعدی از روش پیشنهادی، ارائه نمایش پراکنده، برای بیان رفتار هر محل است. در این روش، هر رفتار می‌تواند به‌صورت ترکیب خطی رفتارهای موجود در ماتریس دیکشنری، بیان شود؛ لذا ابتدا باید یک ماتریس دیکشنری پراکنده طراحی شود. برای هر نمای دوربین و طی فرایند یادگیری پیشنهادی در این مقاله، یک ماتریس دیکشنری پراکنده یاد گرفته می‌شود. حال پیشنهاد بعدی این مقاله استفاده از تجربیات یک دوربین و اشتراک اطلاعات برای شناسایی رفتارها در دوربین دیگر است. در این مقاله ویژگی رفتاری استفاده‌شده برای نمایش هر محل دارای استقلال هندسی است؛ لذا ماتریس دیکشنری پراکنده نیز استقلال هندسی خواهد داشت. این ماتریس به‌دلیل استقلال هندسی از دید نماهای متفاوت دوربین‌ها یکسان است؛ در نتیجه ماتریس دیکشنری پراکنده یادگرفته‌شده در یک دوربین می‌تواند به‌عنوان مدل رفتاری در دوربین دیگری که تازه وارد سامانه شده است، مورد استفاده قرار گیرد. در نهایت در این مقاله یک معیار تصمیم‌گیری آماری نیز برای تشخیص رفتارهای غیرمعمول ارائه می‌شود.

ساختار مقاله بدین شکل است که در بخش دوم به مسأله استخراج ویژگی پرداخته و در بخش سوم نمایش پراکنده معرفی می‌شود. در بخش چهارم رهیافت یادگیری دیکشنری ارائه و روش جدید همکاری دوربین‌ها و اشتراک اطلاعات در بخش پنجم توضیح داده می‌شود. بخش ششم به معرفی رهیافت معیار ارزیابی برای آشکارسازی رفتارهای غیرمعمول می‌پردازد. نتایج آزمایشی در بخش هفتم ارائه

از پیکسل‌ها توسط هدف‌های پیش‌زمینه، به‌عنوان ویژگی تعریف می‌شود. در هر فریم از آرایه آموزش، اگر بلوک پیکسل‌ها به‌عنوان بلوک پیش‌زمینه شناخته شود، مقدار یک و اگر آن بلوک به‌عنوان پس‌زمینه شناخته شود، مقدار صفر به آن نسبت داده می‌شود. این روند در یک آرایه ویدئویی آموزشی انجام می‌شود و در نهایت برای هر بلوک از پیکسل‌ها یک آرایه دودویی $V(-, \bullet)$ وجود خواهد داشت که $V(i, r)$ مقدار دودویی بلوک i را در فریم r مشخص می‌کند. اگر بیش از نیمی از پیکسل‌های بلوک i در فریم r دارای حرکت باشند و به‌عنوان پیش‌زمینه شناخته شده باشند، آن‌گاه $V(i, r) = 1$ و در غیر این صورت $V(i, r) = 0$ خواهد بود. برای بلوک پیکسل‌های i در یک ویدئوی دودویی با طول T ، آرایه $V^i = (V(i, 1), V(i, 2), \dots, V(i, T))$ استخراج می‌شود. حال اگر نرخ اشغال B_n^i ، طول n آمین مجموعه از یک‌های پشت‌سرهم در بلوک پیکسل n ام و نرخ ساکن I_n^i ، طول n آمین مجموعه از صفرهای پشت‌سرهم در بلوک پیکسل n ام در ویژگی V^i باشند، آن‌گاه برای هر بلوکی از پیکسل‌های i ، دوتایی‌های (B_n^i, I_n^i) ، به‌عنوان ویژگی رفتار بلوک پیکسل‌های i ، در نظر گرفته می‌شود. دوتایی‌های اشغال-ساکن برای بلوک i در شکل (۱) نشان داده شده است. در این شکل محور افقی، سری زمانی مشاهده بلوک i است. در محور عمودی، عدد یک بیان‌گر این است که در این لحظه زمانی در بلوک i توسط یک جسم متحرک حرکت اتفاق افتاده و عدد صفر بیان‌گر این است که هیچ حرکتی در این لحظه در بلوک i اتفاق نیفتاده است.



(شکل-۱): ویژگی رفتار به‌دست آمده برای بلوک i .
(Figure-1): the Behavior Feature for i th Block

۳ - نمایش پراکنده^۱

یک روش رایج برای بیان دسته وسیعی از سیگنال‌ها شامل سیگنال‌های تصویر و صدا در شکل فشرده، استفاده از نمایش

^۱ Sparse representation

با بردارهای اساسی^۲ است. ازجمله کاربردهای گسترده نمایش با بردارهای اساسی، نمایش در حوزه موجک و فوریه است [21]. این روش‌ها امروزه الهام‌بخش کاربردهای گسترده‌تری شده‌اند که نمایش پراکنده، یکی از این کاربردها است. از نمایش پراکنده برای اکتساب، فشرده‌سازی و مدل کردن استفاده می‌شود. مسأله اساسی در حس‌گری فشرده^۳ (CS) بازیابی سیگنال $x \in R^n$ به‌شرط برداری از اندازه‌گیری‌های خطی $y \in R^m$ ، $m \ll n$ ، در شکل $y = Ax$ است. با توجه به نتایج پژوهش [22] در نمایش پراکنده به شرط نمونه‌های آموزشی کافی از خوشه y می‌تواند به‌صورت ماتریس $A_i = [v_{i,1}, v_{i,2}, \dots, v_{i,n}] \in R^{m \times n}$ هر نمونه جدید (آزمایشی) $y \in R^m$ از خوشه y نام می‌تواند به‌صورت ترکیب خطی از نمونه‌های آموزشی موجود در خوشه y نام با رابطه (۳) بیان شود.

$$y = \alpha_{i,1}v_{i,1} + \alpha_{i,2}v_{i,2} + \dots + \alpha_{i,n}v_{i,n} \quad (۳)$$

در این رابطه $j=1, \dots, n$ ، $\alpha_{i,j} \in R$ ضرایب اسکالر هستند. از آنجایی که در ابتدا مشخص نیست که نمونه آزمایشی جدید در کدام خوشه قرار می‌گیرد، لذا یک ماتریس جدید A برای تمام نمونه‌های آموزشی به‌صورت پیوست n نمونه آموزشی از تمام خوشه‌ها با رابطه (۴) تعریف و ماتریس A ، ماتریس دیکشنری پراکنده نامیده می‌شود.

$$A = [A_1, \dots, A_n] \quad (۴)$$

حال نمایش ترکیب خطی نمونه جدید آزمایشی y می‌تواند بر حسب تمام نمونه‌های آموزشی از تمام طبقه‌ها به‌صورت رابطه (۵) نوشته شود:

$$y = Ax \in R^m \quad (۵)$$

در این رابطه $x = [0, \dots, 0, \alpha_{i,1}, \alpha_{i,2}, \dots, \alpha_{i,n}, 0, \dots, 0]^T \in R^n$ یک بردار ضرایب است که تمام ضرایب آن به استثنای ضرایبی که مرتبط با خوشه i هستند، برابر صفر است. درحقیقت بردار x هویت نمونه آموزشی جدید y را مشخص می‌کند؛ لذا سعی بر این است که با حل رابطه $y = Ax$ بردار ضرایب x به‌دست آید. فرض کنید بردار x قابل فشرده‌سازی باشد، آن‌گاه این بردار می‌تواند از یک دستگاه معادلات با حل رابطه (۶) بازیابی شود:

$$\min_x \|x\|_0 \text{ subject } y = Ax \quad (۶)$$

^۲ Basis representation

^۳ Compressing sensing

یک روش خوشه‌بندی با بار محاسباتی پایین است و تعداد خوشه‌ها به‌طور خودکار محاسبه می‌شود [26], [25]. در روش خوشه‌بندی طیفی، به شرط مجموعه $BI = \{BI^1, BI^2, \dots, BI^N\}$ که BI^i ها، دوتایی‌های اشغال-ساکن برای بلوک i هستند، ماتریس تشابه S به‌صورت رابطه (۹) تشکیل می‌شود. در این ماتریس * نشان‌دهنده مقادیر متقارن است.

$$S = \begin{bmatrix} S(1,1) & S(1,2) & \dots & S(1,N) \\ * & S(2,2) & \dots & S(2,N) \\ \vdots & \vdots & \ddots & \vdots \\ * & * & \dots & S(N,N) \end{bmatrix} \quad (9)$$

این ماتریس یک $N \times N$ است که هر درایه از آن بیان‌گر تشابه بین دو بلوک بر اساس معیار فاصله است. مراحل روش خوشه‌بندی طیفی به شکل زیر است:

- ۱- محاسبه ماتریس تشابه S
- ۲- تعریف ماتریس قطری D که عناصر (i,i) آن به‌صورت جمع سطرها از ماتریس A است $d_{ii} = \sum_j S(i,j)$
- ۳- تشکیل ماتریس $L = D^{-\frac{1}{2}} S D^{-\frac{1}{2}}$
- ۴- پیدا کردن K تا از بزرگترین بردارهای ویژه L و تشکیل ماتریس $X = \{x_1, x_2, \dots, x_k\}$
- ۵- تشکیل ماتریس Y از X با هنجارسازی کردن هرکدام از سطرهای X برای داشتن طول واحد

$$Y_{ij} = \frac{X_{ij}}{(\sum_j X_{ij}^2)^{1/2}}$$

- ۶- در نظر گرفتن هر سطر Y به‌عنوان یک نقطه و دسته‌بندی آن‌ها به K دسته با روش K -means
- ۷- نسبت دادن دوتایی‌های BI^i به خوشه z ، اگر و فقط اگر سطر i از ماتریس Y به خوشه z نسبت داده شده باشد.

بعد از تعیین خوشه‌ها و قرارگرفتن نمونه‌های آموزشی اولیه در خوشه‌های مربوطه، از نمونه‌های آموزشی جدید برای کامل کردن و بهینه‌کردن این ماتریس دیکشنری استفاده می‌شود. بر طبق نمایش پراکنده، هر نمونه آموزشی جدید باید بر حسب ترکیب خطی نمونه‌های آموزشی در خوشه‌ای که به آن متعلق است، بیان شود. به عبارت دیگر به شرط ماتریس دیکشنری موجود، برای نمونه آموزشی جدید باید تابع هزینه داده‌شده در (۱۰) کمینه شود؛

$$f(y, A) = \min_x \frac{1}{2} \|y - Ax\|_{\ell_2}^2 + \lambda \|x\|_{\ell_1} \quad (10)$$

در رابطه (۹)، شاخصه λ یک شاخصه تنظیم‌کننده است. در این روش، بردار ضرایب پراکنده که این تابع را کمینه

"اندازه" ℓ_p سیگنال x ، یک بردار N بعدی است و با رابطه (۷) تعریف می‌شود:

$$\|x\|_{\ell_p} = \left(\sum_{i=1}^N |x_i|^p \right)^{\frac{1}{p}} \quad (7)$$

با تعریف "اندازه" ℓ_p می‌توان به راحتی "اندازه" ℓ_0 ، "اندازه" ℓ_1 و "اندازه" ℓ_2 را تعریف کرد. مطابق با رابطه (۸)، "اندازه" ℓ_2 درحقیقت برابر ضرب داخلی در فضای R^N است.

$$\|x\|_{\ell_2} = \sqrt{\langle x, x \rangle} \quad (8)$$

$\|x\|_0$ درحقیقت "اندازه" ℓ_0 است که برابر با تعداد ورودی‌های غیرصفر بردار x است. تحت شرایط معین "اندازه" ℓ_0 می‌تواند با "اندازه" ℓ_1 تقریب زده شود که به یک مسأله بهینه‌سازی محدب منجر می‌شود. هرچند در ابتدا مفهوم پراکنده‌گی برای حل مسائل بازسازی معکوس پذیر ارائه شد، اما کارهایی که در همین اواخر انجام شده، بیان‌گر مؤثر بودن نمایش پراکنده‌گی در کاربردهای خوشه‌بندی است. فرض اساسی برای نمایش پراکنده در حوزه خوشه‌بندی این است که یک تصویر آزمایشی می‌تواند به‌طور قابل قبولی بر حسب ترکیب خطی تصاویر آموزشی متعلق به یک خوشه و بدون دخالت تصاویر موجود در خوشه‌های دیگر، تقریب زده شود [24], [23]؛ لذا با وجود $A = [A_1, \dots, A_k]$ که در آن A_i بیان‌گر تصاویر آموزشی برداری شده موجود در خوشه i ام است، بردار ضرایب متناظر $x = [x_1^T, \dots, x_k^T]^T$ یک بردار پراکنده و بیان‌گر اطلاعات متمایز کننده است. به عبارت دیگر، اطلاعات معنایی سیگنال مورد نظر در نمایش پراکنده گنجانده می‌شود.

۴- یادگیری دیکشنری^۱

در این مقاله یک روش جدید برای طراحی ماتریس دیکشنری پراکنده A پیشنهاد شده است. این ماتریس درحقیقت متشکل از تمام ویژگی‌های رفتاری اتفاق افتاده در یک نمای دوربین است. در این دیکشنری ویژگی‌هایی که بیان‌گر یک رفتار هستند، در یک خوشه قرار می‌گیرند. در مرحله آموزش به شرط نمونه‌های آموزشی اولیه $Y = [y_1, y_2, \dots, y_n]$ ، ابتدا روش خوشه‌بندی طیفی^۲ برای خوشه‌بندی این نمونه‌های آموزشی مورد استفاده قرار می‌گیرد. روش خوشه‌بندی طیفی

¹ Dictionary learning

² Spectral clustering

می‌کند، به‌دست می‌آید و با استفاده از این بردار پراکنده، خوشه‌ای که این نمونه آموزشی جدید به آن متعلق است، تعیین می‌شود. این نمونه آموزشی در ماتریس دیکشنری اولیه، به خوشه‌ای که به آن تعلق دارد اضافه می‌شود و این روند ادامه پیدا می‌کند تا تمام خوشه‌ها در ماتریس دیکشنری دارای تعداد مشخص T نمونه شوند. این ماتریس دیکشنری تکمیل‌شده در بخش‌های بعدی به‌عنوان مدل رفتاری برای شناسایی رفتارها و آشکارسازی رفتارهای غیرمعمول مورد استفاده قرار خواهد گرفت. الگوریتم یادگیری دیکشنری در شکل (۲) نمایش داده شده است.

ورودی: داده آموزشی Y
خروجی: ماتریس دیکشنری پراکنده A
راه‌اندازی: استفاده از خوشه‌بندی طیفی برای خوشه‌بندی داده‌های آموزشی اولیه Y و تولید ماتریس دیکشنری پراکنده اولیه A^0
حلقه For (تا زمانی که خوشه‌ها در ماتریس دیکشنری پراکنده دارای T نمونه آموزشی شوند)
 - ورود نمونه آموزشی جدید
 - حل مسأله بهینه‌سازی (۹) و پیدا کردن ضرایب پراکنده و قراردادن نمونه آموزشی در خوشه جدید.
 - به‌روزر کردن ماتریس دیکشنری پراکنده $A^1 \leftarrow A^0$
 End

(شکل-۲): الگوریتم یادگیری ماتریس دیکشنری پراکنده
 (Figure-2): Learning Algorithm for Sparse Dictionary Matrix

۵ - همکاری و اشتراک اطلاعات دوربین‌ها

مدل رفتاری یعنی همان ماتریس دیکشنری پراکنده A که از نمای یک دوربین به‌دست می‌آید، مجموعه‌ای از ویژگی‌ها است که این ویژگی‌ها دارای استقلال هندسی هستند؛ لذا این مدل نیز دارای استقلال هندسی خواهد بود. در این مقاله با استفاده از این خاصیت مدل رفتاری، رهیافتی برای اشتراک اطلاعات و همکاری دوربین‌ها پیشنهاد می‌شود. بر اساس رهیافت پیشنهادی، در پروفایل چند دوربین، مدل رفتاری استخراج‌شده می‌تواند به‌طور قابل معاوضه بین دوربین‌ها استفاده شود. در نتیجه لازم نیست در هر دوربین مدل رفتاری استخراج شود. برای مثال در وضعیتی که دوربین جدیدی به شبکه دوربین‌ها اضافه می‌شود و یک محیط معین را نظارت می‌کند، تنها کاری که باید انجام شود، این است که مدل رفتاری در دوربینی که این ناحیه را نظارت می‌کرد به دوربین جدید انتقال یابد. حال در دوربین جدید با استفاده از این مدل رفتاری می‌توان وظایفی هم‌چون آشکارسازی رفتارهای غیرمعمول را انجام داد. فرض کنید C_i در دوربین (۱) و L_j در دوربین (۲)، دو بلوک پیکسل متناظر باشند که یک محل را

نشان می‌دهند. تحت شرایط ایده‌آل رفتار f^{C_i} و f^{L_j} یکسان خواهد بود؛ لذا ماتریس دیکشنری A_i که تحت بلوک C_i به دست آمده است، می‌تواند برای بلوک پیکسل L_j مورد استفاده قرار گیرد. این کار باعث انعطاف‌پذیری در شبکه دوربین‌ها می‌شود؛ به‌طوری که دوربین‌ها می‌توانند نواحی قابل نظارت را به یک‌دیگر انتقال دهند و از تجربیات یک‌دیگر استفاده کنند. در بخش نتایج آزمایشی نشان داده خواهد شد که منحنی ROC^1 به‌دست‌آمده از طریق انتقال مدل رفتاری برای آشکارسازی رفتارهای غیرمعمول در حد منحنی ROC برای وقتی است که مدل رفتاری به‌طور مستقیم و بدون انتقال، برای آشکارسازی رفتارهای غیرمعمول استفاده می‌شود.

۶ - آشکارسازی رفتارهای غیرمعمول

در آشکارسازی رفتارهای غیرمعمول به این شکل عمل می‌شود که یک مدل رفتاری معمول در مرحله آموزش به‌دست می‌آید؛ سپس در مرحله آزمایش با مقایسه نمونه آزمایشی تحت مدل رفتاری معمول، در مورد معمول یا غیرمعمول بودن آن تصمیم‌گیری می‌شود. رهیافت ارائه‌شده در این مقاله یک رهیافت بدون نظارت است. یعنی در مرحله آموزش فرض بر این است که فقط رفتارهای معمول اتفاق می‌افتد. ماتریس دیکشنری پراکنده A یا همان مدل رفتاری که در بخش‌های قبلی و در مرحله آموزش به‌دست آمد، مجموعه‌ای از خوشه‌های رفتاری معمولی است که در یک صحنه اتفاق می‌افتند. حال در مرحله آزمایش، یک نمونه جدید آزمایشی اگر دارای رفتار معمول باشد، باید بتواند بر حسب ترکیب خطی نمونه‌های یکی از خوشه‌های دیکشنری A بیان شود. در غیر این‌صورت چون نمونه آزمایشی به هیچ‌کدام از رفتارهای معمول تعلق ندارد، یک رفتار غیرمعمول است. در این مقاله برای تعیین معمول یا غیرمعمول بودن نمونه آزمایشی با فرض نوفه با توزیع گوسین، از رابطه (۱۱) استفاده می‌شود.

$$p(y|A) = (2\pi\sigma^2)^{-K/2} \exp\left(-\frac{1}{2\sigma^2} \|y - Ax_i\|_{\ell_2}^2\right) \quad (11)$$

در این رابطه K تعداد خوشه‌های رفتاری معمول، σ^2 واریانس نوفه گوسین و x_i ضرایب غیرصفر مرتبط با خوشه i است. خوشه i ، خوشه‌ای است که باقی‌مانده $\|y - Ax_i\|_{\ell_2}^2$ تحت آن خوشه کمینه است. در این رابطه درحقیقت احتمال نمونه آزمایشی به شرط مدل رفتاری A به‌دست می‌آید. اگر

¹ Receiver Operating Characteristic

پایگاه داده UMN در شکل (۴) نشان داده شده است.



(شکل-۴): نمونه رفتارهای غیرمعمول آشکارشده با روش

پیشنهادی برای پایگاه داده UMN.

(Figure-4): Examples of Detecting Abnormal Behaviors through the Proposed Method Using the Samples in the UMN Datasets.

برای مقایسه ره یافت پیشنهادی با ره یافت‌های ارائه شده در این زمینه از منحنی ROC و معیار مساحت زیرمنحنی 'ROC (AUC) استفاده می‌شود. منحنی ROC یکی از پروتکل‌های استاندارد برای ارزیابی نتایج آشکارسازی غیرمعمول‌ها است. برای این منحنی ابتدا مؤلفه‌های نرخ مثبت صحیح^۲ (TPR) و نرخ مثبت کاذب^۳ (FPR) محاسبه می‌شوند. شاخص^۲ TPR برابر است با نسبت (تعداد فریم‌هایی که به درستی به عنوان غیرمعمول تشخیص داده شده‌اند) به (تعداد کل فریم‌ها).

شاخص^۳ FPR برابر است با نسبت (تعداد فریم‌هایی که به اشتباه به عنوان غیرمعمول تشخیص داده شده‌اند) به (تعداد کل فریم‌ها).

منحنی ROC برابر با منحنی پارامتری (FPR و TPR) است. برای آشکارسازی رفتارهای غیرمعمول، باید یک حد آستانه برای تشخیص رفتارهای معمول از غیرمعمول در نظر گرفته شود. حال برای آزمایش و ارزیابی دقیق، برای مقادیر متفاوت از سطح آستانه منحنی ROC تشکیل می‌شود و عملکرد ره یافت پیشنهادی را نمایش می‌دهد. همچنین از یک معیار اندازه‌گیری عملکرد تحت عنوان AUC نیز برای مقایسه استفاده می‌شود. معیار AUC به طور مستقیم از منحنی ROC محاسبه می‌شود و در حقیقت سطح زیر منحنی ROC است.

¹ The Area Under an ROC Curve

² True Positive Rate

³ False Positive Rate

این احتمال کمتر از یک حد آستانه باشد، یعنی این نمونه آزمایشی به هیچ کدام از خوشه‌های رفتاری دیکشنری A تعلق ندارد؛ لذا یک رفتار غیرمعمول است. الگوریتم ره یافت آشکارسازی رفتار غیرمعمول در شکل (۳) نمایش داده شده است.

ورودی: دیکشنری A، نمونه آزمایشی y، آستانه ζ و σ^2

خروجی: برچسب برای بلوک پیکسل p_i : معمول یا غیرمعمول

پیدا کردن خوشه‌ای که باقیمانده $\|y - Ax_i\|_{\ell_2}^2$ تحت آن خوشه کمینه گردد.

محاسبه احتمال

$$p(y|A) = (2\pi\sigma^2)^{-K/2} \exp\left(-\frac{1}{2\sigma^2} \|y - Ax_i\|_{\ell_2}^2\right)$$

IF (اگر)

$$p(y|A) < \zeta$$

Then (آن‌گاه)

برچسب زدن بلوک پیکسل p_i به عنوان غیرمعمول

Else (در غیر این صورت)

برچسب زدن بلوک پیکسل p_i به عنوان معمول

End IF (پایان)

(شکل-۳): الگوریتم آشکارسازی رفتار غیرمعمول.

(Figure-3): the Proposed Algorithm for Detection of Abnormal Behaviors

۷- نتایج آزمایشی

در این بخش نتایج آزمایشی برای پایگاه داده در دسترس برای شناسایی رفتارها و آشکارسازی رفتارهای غیرمعمول ارائه شده است. این نتایج نشان‌دهنده کارآمد بودن ره یافت پیشنهادی و همچنین اعتباربخشیدن به ادعاها در بخش‌های قبلی است.

۷-۱- ارزیابی ره یافت پیشنهادی با استفاده از

پایگاه داده UMN

ره یافت پیشنهادی این مقاله با استفاده از پایگاه داده UMN [27] که به عنوان یک پایگاه داده استاندارد معیار برای ارزیابی روش‌های آشکارسازی رفتارهای غیرمعمول استفاده می‌شود، مورد بررسی قرار می‌گیرد. پایگاه داده UMN شامل سه صحنه است که در هر صحنه یک تناوب از رفتارهای معمول و به دنبال آن یک تناوب از رفتارهای غیرمعمول وجود دارد. در مورد رفتارهای معمول، افراد به تنهایی یا به صورت گروهی حرکت می‌کنند؛ اما در مورد رفتارهای غیرمعمول افراد با وحشت شروع به دویدن می‌کنند. برای هر کدام از سه صحنه، رفتارهای معمول و غیرمعمول یکی بعد از دیگری اتفاق می‌افتد. در صحنه‌های یک، دو و سه، به ترتیب دو، شش و سه رفتار غیرمعمول وجود دارد. نتایج ره یافت پیشنهادی برای

(جدول-۱): مقایسه کمی AUC (Area Under ROC) برای آزمایش‌های آشکارسازی رفتارهای غیرمعمول

در پایگاه داده UMN

(Table-1): The Quantitative Comparison of the AUC (Area Under ROC) for Abnormal Detection Experiments in the UMN Datasets


صحنه سه	صحنه دو	صحنه یک	ره یافت
83	82	84	روش MPPCA (%)
96	96	98	سونگاو و همکاران [9] (%)
99	98	98	گو و همکاران [6] (%)
98	94	95	امرای و همکاران [14] (%)
99	95	96	ره یافت پیشنهادی (%)

۷-۲- ارزیابی ره یافت پیشنهادی با استفاده از پایگاه داده PETs 2006

پایگاه داده PETs 2006 [28] یکی از پایگاه داده معروف در زمینه سامانه‌های نظارتی و بینایی ماشین است. در این پایگاه داده یک محیط بیرونی (ایستگاه قطار و مسیری که در آن عابران تردد می‌کنند)، توسط چهار دوربین از نماهای مختلف نظارت می‌شود. در این پایگاه داده اندازه فریم‌های تصویر ۵۷۶×۷۲۰ پیکسل و دارای نرخ ۲۵ فریم در ثانیه است. نمایی از این پایگاه داده که در این مقاله استفاده می‌شود در شکل (۶) نمایش داده شده است. ره یافت پیشنهادی بر داده‌های موجود در پایگاه داده PETs 2006 آزمایش شده است. در این پایگاه داده یک محیط بیرونی توسط چند دوربین نظارت می‌شود. مسافرانی که می‌خواهند سوار قطار شوند یا مسافرانی که قطار را ترک کرده‌اند، تردد می‌کنند. رفت و آمدهای افراد در این محیط به عنوان رفتارهای معمول در نظر گرفته می‌شود؛ لذا در مرحله آموزش فریم‌هایی که استفاده می‌شوند، فقط عابران پیاده در آن تردد می‌کنند و لذا در این مرحله آموزش، رفتارهای معمول به دست می‌آیند. در مرحله آزمایش برای ارزیابی سامانه در شناسایی رفتارهای غیرمعمول، در بعضی فریم‌ها یک شخص وارد صحنه شده و با توقف طولانی در یک محل و سپس قراردادن کیف روی زمین، محل را ترک می‌کند. این توقف طولانی و قراردادن کیف روی زمین به عنوان یک رفتار غیرمعمول است؛ زیرا در این محیط افراد حرکت می‌کنند و توقف طولانی ندارند و هیچ شیئی را در محیط باقی نمی‌گذارند؛ لذا این توقف طولانی و قراردادن کیف، یک رفتار غیرمعمول است که توسط ره یافت پیشنهادی در این مقاله، آشکارسازی شده و به عنوان رفتار غیرمعمول در نظر گرفته می‌شود. نتایج به دست آمده در شکل (۶) نمایش داده شده است.

حال برای این پایگاه داده، روش پیشنهادی با روش‌های ارائه شده در [6]، [9]، [10]، مقایسه می‌شود.

منحنی ارزیابی ROC در سطح فریم برای این پایگاه داده‌ها در شکل (۵) نمایش داده شده است.




(شکل-۵): منحنی ROC در سطح فریم برای پایگاه داده UMN (Figure-5): The Comparison of the ROC Curves Based on the Frame Level in the UMN Datasets

در این پایگاه داده رفتار غیرمعمول در حقیقت حرکت نامنظم و سرعت بالای افراد است. از آنجایی که در این پایگاه داده، حرکت‌ها شکل مشخصی ندارند و به صورت جمعی انجام می‌شوند، لذا در این پایگاه داده، روش‌های بر اساس هدف، کارآمد نخواهند بود؛ زیرا در این روش‌ها باید هدف‌ها دارای مسیرهای معین و به اصطلاح حرکت خط سیر هدف‌ها شکل بسته نداشته باشند. همچنین به دلیل وجود ازدحام در این پایگاه داده، آشکارسازی هدف و تعقیب تک تک هدف‌ها به آسانی قابل انجام نخواهد بود.

همان‌طور که از منحنی قابل مشاهده است، ره یافت پیشنهادی نتایج بهتری نسبت به روش‌های baseline [14]، [6]، [9] دارد. برای مقایسه کمی ره یافت پیشنهادی با روش‌های دیگر از معیار AUC که در حقیقت سطح زیر منحنی منحنی ROC است، استفاده می‌شود. جدول (۱) مقدار AUC را برای ره یافت پیشنهادی و روش‌های ارائه شده در [6]، [9]، [10] نمایش می‌دهد. AUC ره یافت پیشنهادی برای مجموعه صحنه یک، ۹۶ درصد است که ۱۲ درصد بیشتر از ره یافت baseline است. AUC ره یافت پیشنهادی برای مجموعه صحنه سه، ۹۹ درصد است که ۱۶ درصد بیشتر از ره یافت baseline، یک درصد بیشتر از [14] و ۳ درصد بیشتر از [9]، است.

داده شده است. برای این پایگاه داده، AUC رهیافت پیشنهادی، ۷۷ درصد است که ۱۸ درصد بیشتر از رهیافت baseline است. همچنین AUC برای رهیافت پیشنهادی یک درصد بالاتر از رهیافت [14]، و یک درصد پایین‌تر از رهیافت [6] است. دلیل برتری یک درصدی AUC روش [6]، نسبت به رهیافت پیشنهادی این است که روش [6]، از تعداد ویژگی‌های بیشتری استفاده کرده است که این ویژگی‌ها استقلال هندسی ندارند و لذا مدل رفتاری استخراج شده در یک دوربین، قابلیت انتقال به دوربین دیگر را ندارند؛ اما در رهیافت پیشنهادی این مقاله، به دلیل استفاده از ویژگی که دارای خاصیت استقلال هندسی است، مدل استخراج شده در یک دوربین می‌تواند برای دوربین‌هایی که تازه وارد محیط نظارت می‌شوند، مورد استفاده قرار گیرد.

حال برای ارزیابی رهیافت اشتراک اطلاعات بین دوربین‌ها و استفاده از تجربیات یکدیگر، در این مقاله ابتدا در یک نما از دوربین در پایگاه داده PETs 2006، مدل رفتاری (دیکشنری A) یاد گرفته می‌شود؛ سپس این مدل به دوربین دیگر منتقل و در این نما به طور مستقیم نمونه آزمایشی استخراج و تحت این مدل رفتاری در مورد معمول یا غیرمعمول بودن آن تصمیم‌گیری می‌شود. منحنی ROC برای این رهیافت پیشنهادی در شکل (۸) نشان داده شده است. این منحنی برای زمانی است که دیکشنری A به طور مستقیم برای دوربین محاسبه شده و دیکشنری که از دوربین دیگر منتقل شده است. همان‌طور که مشاهده می‌شود، نتایج در منحنی ROC بسیار نزدیک به هم هستند.



(شکل-۸): منحنی ROC در سطح فریم برای مقایسه آشکارسازی رفتار غیرمعمول با محاسبه مستقیم مدل رفتاری و استفاده از مدل رفتاری انتقال یافته.


(Figure-8): The Comparison of the ROC Curves between Direct Behavior Model and Transferred Behavior Model for Abnormal Behavior Detection



(شکل-۶): یک نمونه از پایگاه داده PETs 2006 و نتایج

به دست آمده در آشکارسازی رفتارهای غیرمعمول

(Figure-6): Examples of Detecting Abnormal Behaviors through the Proposed Method Using the Samples in the PETs 2006 Dataset.



(شکل-۷): منحنی ROC در سطح فریم برای

پایگاه داده PETs 2006

(Figure-7): The Comparison of the ROC Curves Based on the Frame Level in the PETs 2006 Dataset.

(جدول-۲): مقایسه کمی (Area Under ROC) AUC برای

آزمایش‌های آشکارسازی رفتارهای غیرمعمول در پایگاه داده PETs 2006

(Table-2): The Quantitative Comparison of the AUC (Area Under ROC) for Abnormal Detection Experiments in the PETs 2006 Dataset.

پایگاه داده PETs 2006	رهیافت
59	روش MPPCA (%)
67	سونگاو و همکاران [9] (%)
78	گو و همکاران [6] (%)
76	امرابی و همکاران [14] (%)
77	رهیافت پیشنهادی (%)

منحنی ارزیابی ROC در سطح فریم و همچنین AUC

برای این پایگاه داده به ترتیب در شکل (۷) و جدول (۲) نمایش

behavior detection by using the particle entropy,” *Optik (Stuttg.)*, vol. 125, no. 14, pp. 3428–3433, 2014.

- [7] Y. Zhang, H. Lu, L. Zhang, and X. Ruan, “Combining motion and appearance cues for anomaly detection,” *Pattern Recognit.*, vol. 51, pp. 443–452, 2016.
- [8] B. Antić and B. Ommer, “Video parsing for abnormality detection,” *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 2415–2422, 2011.
- [9] S. Zhu, J. Hu, and Z. Shi, “Local abnormal behavior detection based on optical flow and spatio-temporal gradient,” *Multimed. Tools Appl.*, vol. 75, no. 15, pp. 9445–9459, 2016.
- [10] J. Kim and K. Grauman, “Observe locally, infer globally: a space-time mrf for detecting abnormal activities with incremental updates,” in *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2009, no. June.
- [11] A. L. Hou, J. L. Guo, C. J. Wang, L. Wu, and F. Li, “Abnormal behavior recognition based on trajectory feature and regional optical flow,” in *Proceedings - 2013 7th International Conference on Image and Graphics, ICIG 2013*, 2013, pp. 643–649.
- [12] V. Saligrama, J. Konrad, and P. M. Jodoin, “Video anomaly identification,” *IEEE Signal Process. Mag.*, vol. 27, no. 5, pp. 18–33, 2010.
- [13] J. A. Rodríguez-Serrano and S. Singh, “Trajectory clustering in CCTV traffic videos using probability product kernels with hidden Markov models,” *Pattern Anal. Appl.*, vol. 15, no. 4, pp. 415–426, 2012.
- [14] S. Amraee, A. Vafaei, K. Jamshidi, and P. Adibi, “Anomaly detection and localization in crowded scenes using connected component analysis,” 2017.
- [15] X. Wang, X. Ma, and E. Grimson, “Unsupervised Activity Perception in Crowded and Complicated Scenes Using Hierarchical Bayesian Models.pdf,” vol. 31, no. 3, pp. 1–35, 2007.
- [16] S. Li, C. Liu, and Y. Yang, “Anomaly Detection Based on Maximum a Posteriori,” *Pattern Recognit. Lett.*, vol. 0, pp. 1–7, 2017.
- [17] C. Simon, J. Meessen, and C. De Vleeschouwer, “Visual event recognition using decision trees,” *Multimed. Tools Appl.*, vol. 50, no. 1, pp. 95–121, 2010.
- [18] S. Amraee, A. Vafaei, K. Jamshidi, and P. Adibi, “Abnormal event detection in crowded scenes using one-class SVM,” *Signal, Image Video Process.*, 2018.
- [19] B. D. Devarajan, Z. Cheng, and R. J. Radke, “Camera Networks,” vol. 96, no. 10, pp. 1625–1639, 2008.

۸ - نتیجه گیری

در این مقاله یک راه یافت جدید برای شناسایی رفتارها و آشکارسازی رفتارهای غیرمعمول بر اساس نمایش پراکنده ویژگی‌ها و با استفاده از همکاری بین دوربین‌ها ارائه شد. ابتدا برای هر محل در فریم تصویر، یک ویژگی که دارای استقلال هندسی است، استخراج شد؛ سپس برای یک دوربین، ماتریس دیکشنری پراکنده A محاسبه و به عنوان یک مجموعه از مدل رفتاری در نظر گرفته شد؛ سپس تحت عنوان مسأله اشتراک اطلاعات و استفاده از تجربه یادگیری یک دوربین برای دوربین دیگر، ماتریس دیکشنری یادگرفته شده در یک دوربین به دوربین دیگر منتقل شد و در دوربین جدید برای آشکارسازی غیرمعمول‌ها مورد استفاده قرار گرفت. برای یادگیری ماتریس دیکشنری، یک روش سلسله‌مراتبی با استفاده از خوشه‌بندی طیفی پیشنهاد شد. در نهایت، بعد از نمایش پراکنده ویژگی‌ها، یک معیار اندازه‌گیری با استفاده از نمایش پراکنده برای آشکارسازی رفتارهای غیرمعمول ارائه و نتایج آزمایشی برای پایگاه داده در دسترس برای شناسایی رفتارها و آشکارسازی رفتارهای غیرمعمول ارائه شد. این نتایج نشان‌دهنده کارایی راه یافت پیشنهادی و همچنین اعتباربخشیدن به ادعاها در بخش‌های قبلی است.

9- References

۹ - مراجع

- [1] C. Chi-Hung, H. Jun-Wei, T. Luo-Wei, C. Sin-Yu, and F. Kuo-Chin, “Carried object detection using ratio histogram and its application to suspicious event analysis,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 19, no. 6, pp. 911–916, 2009.
- [2] T. Xiang and S. Gong, “Video behaviour profiling for anomaly detection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 30, no. 5, pp. 893–908, 2008.
- [3] D. Xu, R. Song, X. Wu, N. Li, W. Feng, and H. Qian, “Video anomaly detection based on a hierarchical activity discovery within spatio-temporal contexts,” *Neurocomputing*, vol. 143, pp. 144–152, 2014.
- [4] M. Sabokrou, M. Fayyaz, M. Fathy, Z. Moayed, and R. Klette, “Deep-anomaly: Fully convolutional neural network for fast anomaly detection in crowded scenes,” *Computer Vision and Image Understanding*, no. February, Elsevier, pp. 0–1, 2018.
- [5] Y. Yuan, D. Wang, and Q. Wang, “Anomaly Detection in Traffic Scenes via Spatial-Aware Motion Reconstruction,” *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 5, pp. 1198–1209, 2017.
- [6] X. Gu, J. Cui, and Q. Zhu, “Abnormal crowd

- [20] M. Piccardi, "Background subtraction techniques: a review," *Vision Res.*, pp. 3099–3104, 2004.
- [21] H. Cheng, *Sparse Representation, Modeling and Learning in Visual Recognition*.
- [22] X. Mo, V. Monga, R. Bala, and Z. Fan, "A joint sparsity model for video anomaly detection," *Conf. Rec. - Asilomar Conf. Signals, Syst. Comput.*, pp. 1969–1973, 2012.
- [23] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma, "Robust face recognition via sparse representation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, no. 2, pp. 210–227, 2009.
- [24] A. Wagner, J. Wright, A. Ganesh, Z. Zhou, H. Mobahi, and Y. Ma, "Toward a practical face recognition system: Robust alignment and illumination by sparse representation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 2, pp. 372–386, 2012.
- [25] M. Planck and U. Von Luxburg, "A Tutorial on Spectral Clustering A Tutorial on Spectral Clustering," *Stat. Comput.*, vol. 17, no. March, pp. 395–416, 2006.
- [26] L. Zelnik and P. Perona, "Self-Yuning Spectral Clustering," vol. 17, no. 4.
- [27] R. Mehran, a. Oyama, and M. Shah, "Abnormal crowd behavior detection using social force model," *2009 IEEE Conf. Comput. Vis. Pattern Recognit.*, no. 2, pp. 935–942, 2009.
- [28] "PETS2006 dataset. Available: <http://www.cv-g.rdg.ac.uk/PETS2006/data.html>."



اصغر فیضی دارای مدرک دکترای

مهندسی برق گرایش مخابرات (سیستم) است. دوره کارشناسی را در سال ۱۳۸۷ در رشته مهندسی برق گرایش الکترونیک از دانشگاه گیلان به اتمام رسانیده و در سال ۱۳۸۹ و

۱۳۹۴ به ترتیب مدرک کارشناسی ارشد و دکترای خود را در رشته مهندسی برق گرایش مخابرات (سیستم) از دانشگاه تبریز اخذ کرده است. وی هم‌اکنون عضو هیئت علمی گروه مهندسی برق دانشگاه دامغان است. زمینه پژوهشی مورد علاقه ایشان، شامل پردازش سیگنال‌های دیجیتال و بینایی ماشین، سامانه‌های مخابرات دیجیتال، بازشناسی الگو و یادگیری ماشین است.

نشانی رایانامه ایشان عبارت است از:

a.feizi@du.ac.ir

