

تفریق پس‌زمینه با استفاده از شبکه‌های عصبی حافظه کوتاه-مدت بلند عمیق و سازوکار توجه

مهشام کوشکی^۱، عصمت راشدی^۲، مریم آموزگار^۳

چکیده

جداسازی اشیاء متحرک از پس‌زمینه یکی از مسایل مهم و کاربردی در حوزه بینایی ماشین است. در این مقاله یک روش برخط و بدون نظارت مبتنی برای جداسازی پس‌زمینه از پیش‌زمینه در داده‌های ویدیویی ارائه شده است که در آن پس‌زمینه به صورت یک ماتریس کم‌رتبه L توسط یک شبکه عصبی عمیق استخراج می‌شود و پیش‌زمینه به صورت یک ماتریس تنک با تفریق L از تصویر اصلی به دست می‌آید. در طراحی شبکه عصبی فوق، از یک شبکه حافظه کوتاه-مدت بلند (LSTM) مبتنی بر سازوکار توجه استفاده شده است. یادگیری این روش به صورت بدون نظارت انجام می‌شود و می‌تواند آموزش ببیند به قسمت‌هایی از داده‌ها و تصویر که پیش‌زمینه در آن وجود دارد، وزن بیشتری اختصاص داده و توجه و تمرکز بیشتری داشته باشد. جهت ارزیابی مدل پیشنهادی، پایگاه داده LASIEST انتخاب شده است. کارایی راهکار پیشنهادی به طور کمی با استفاده از معیارهای استاندارد یادآوری، دقت و اندازه‌ی F-measures ارزیابی و با تعدادی از روش‌های معتبر و مطرح مقایسه شده که به ترتیب به میزان ۸٪، ۱۰٪ و ۵٪ بهبود داشته است. علاوه بر این از نظر کیفی و شهودی نیز با راهکارهای موجود مورد مقایسه قرار گرفته که موفق به اخذ نتایج مطلوب‌تر شده است.

کلید واژه‌ها: تفریق پس‌زمینه از پیش‌زمینه، یادگیری عمیق، شبکه عصبی LSTM، سازوکار توجه، یادگیری بدون نظارت، تفریق برخط پس‌زمینه

۱- مقدمه

جداسازی اشیاء متحرک یا پیش‌زمینه از پس‌زمینه در یک دنباله ویدیویی، یکی از مسائل پایه‌ای و مهم در مباحث بینایی ماشین است [۱]. این مسئله در کاربردهایی همچون خودروهای خودران [۲]، نظارت بر جریان ترافیک [۳]، تشخیص ناهنجاری [۴]،

این مقاله در آذرماه ۱۴۰۲ دریافت شد؛ در خردادماه ۱۴۰۳ بازنگری و سپس پذیرفته گردید.

^۱ کارشناس ارشد از دانشکده مهندسی برق و کامپیوتر، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران.

رایانامه: mahshamkushki6724@gmail.com

^۲ دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران.

رایانامه: e.rashedi@kgut.ac.ir

^۳ استادیار، گروه کامپیوتر و فناوری اطلاعات، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران.

رایانامه: amoozegar@kgut.ac.ir

نویسنده مسئول: عصمت راشدی

ردیابی اشیاء [۵] و نظارت ویدیویی [۶] مورد استفاده قرار می‌گیرد. مساله تفریق پس‌زمینه با چالش‌های زیادی در سناریوهای دنیای واقعی مانند: تغییرات روشنایی، سایه‌ها، تغییرات دائمی در صحنه‌ها، تغییرات آب و هوا، لرزش دوربین، انسداد جزئی و کلی، انسداد و پیش‌زمینه ثابت روبرو است [۷]. برای مقابله با این چالش‌ها، در چند دهه اخیر روش‌های کلاسیک بسیار زیادی مانند بهبود فرآیند نگهداشت مدل در مسئله تفریق پس‌زمینه [۱]، روش‌های مبتنی بر ردیابی اشیاء [۸] و روش‌های مبتنی بر دسته بندی مسیر [۹] برای تشخیص شیء متحرک معرفی شده است.

در کنار روش‌های کلاسیک، در سال‌های اخیر رویکردهای مبتنی بر شبکه عصبی عمیق به دلیل توانایی آن‌ها در تجزیه و تحلیل حجم زیاد داده و در نظر گرفتن روابط غیرخطی داده‌ها، محبوبیت بسیار زیادی کسب کرده‌اند [۱۰]. این راهکارها به سه دسته آموزش با نظارت، آموزش بدون نظارت و آموزش نیمه نظارتی تقسیم‌بندی می‌شوند. این نکته حائز اهمیت است که اکثر

ویدیویی ارائه شده است. شبکه های LSTM با موفقیت موقعیت های مکانی و زمانی را یاد می گیرند. در واقع این شبکه رابطه مکانی و زمانی را با پارامترهای کمتری یاد می گیرد. آمار و ارقام نشان می دهد که شبکه های عصبی LSTM عملکرد بهتری نسبت به شبکه های GRU دارند.

سازوکار توجه^۶ در حوزه یادگیری ماشین، اساسا مانند توجه و انتخاب بصری انسان است. این کار شبیه به آن چیزی است که افراد در محیط پیرامون خود انجام می دهند. این تکنیک می تواند در شناسایی افراد، ردیابی آن ها، تشخیص چهره و سایر موارد مفید باشد. در واقع، این تکنیک با توجه به ویژگی های مختلف، تشخیص مناطق دارای اهمیت را دقیق تر می کند، به این معنا که تمایل دارد به بخش های خاصی از اطلاعات که از اهمیت بیشتری برخوردار است (در این مساله بخش هایی از تصویر که پیش زمینه در آن وجود دارد) وزن بیشتری اختصاص دهد. با توجه به مزایای این تکنیک در تمایز و تمرکز بر ویژگی ها، به طور گسترده ای در حوزه یادگیری ماشین مورد استفاده قرار گرفته است. از تکنیک توجه می توان برای افزایش وزن پیش زمینه و بهبود توانایی یادگیری مدل استفاده کرد. این شبکه آموزش می بیند که به طور خودکار کدام قسمت از داده های آموزشی مرتبط تر است و محاسبات خود را روی آن قسمت متمرکز می کند [۲۳].

بر این اساس، این مقاله راهکاری برخط برای تفریق پس زمینه ارائه می کند که متکی بر شبکه های عصبی بازگشتی LSTM و مبتنی بر سازوکار توجه است. در واقع شبکه پیشنهادی هر ویدیو را قاب^۷ به قاب در لحظه پردازش می کند و لذا برای سناریوهای بلادرنگ مناسب است. نکته حائز اهمیت دیگر اینکه روش پیشنهادی بدون نظارت است و به هیچ برچسبی نیاز ندارد. همچنین سازوکار توجه باعث می شود شبکه توجه بیشتری به پیش زمینه داشته باشد و اثر پس زمینه نامرتبط را کاهش داده و توانایی یادگیری مدل را بهبود بخشد. این شبکه قابلیت رویارویی با چالش های ویدیویی مانند تغییرات روشنایی، سایه ها، تغییرات دائمی در صحنه ها، تغییرات آب و هوا، لرزش دوربین، خود راه اندازی^۸، انسداد، استتار، انسداد جزئی و کلی را دارد.

در ادامه، در بخش دوم به پیشینه تحقیق در دو قسمت یادگیری کلاسیک و یادگیری عمیق پرداخته شده است. در بخش سوم معماری شبکه پیشنهادی مورد بحث قرار می گیرد. در بخش چهارم پایگاه داده مورد استفاده و در بخش پنجم معیارهای ارزیابی، چگونگی ارزیابی و نتایج کمی و کیفی بروی پایگاه داده ارزیابی شده و مقایسه مدل پیشنهادی با روش های دیگر آورده شده است. نهایتا در بخش ششم به جمع بندی پرداخته شده است.

رویکردهای موجود بانظارت و با استفاده از داده های برچسب گذاری ارائه شده اند مانند [13D-CNN]، [۱۲T-CNN] و [۱۳SFC]. با توجه به اینکه روش های مطرح شده، متکی بر آموزش با نظارت هستند و فرآیند آموزش در این روش ها متکی بر داده های برچسب گذاری شده است، قدرت تعمیم پذیری آن ها کاهش پیدا می کند. در واقع شبکه به نمونه های آموزشی خود عادت کرده و دچار کاهش کارایی در شناسایی نمونه های جدید می شود. اکثر الگوریتم های تفریق پس زمینه در این دسته به صورت برون خط بوده و داده ها را چندین بار پردازش می کنند [۱۴]، بر خلاف الگوریتم های برخط که به صورت تدریجی-افزایشی عمل کرده و فقط یکبار داده ها را پردازش می کنند.

شبکه عصبی همگشتی^۱ (CNN) یک شبکه کارآمد خاص است که به دلیل توانایی یادگیری با استفاده از ویژگی های سطح بالا برای تشخیص شیء و تفریق پس زمینه استفاده می شود [۱۲]. این شبکه دارای دقت و سرعت خوبی در تشخیص اشیاء است و در زمینه ی طبقه بندی اشیاء و تقسیم بندی اشیاء به موفقیت زیادی دست پیدا کرده است. در واقع شبکه های همگشتی عمیق مشکل کوتاه بودن حافظه را دارند و اگر یک دنباله به اندازه کافی طولانی باشد، ارسال اطلاعات از مرحله قبلی به مرحله بعدی به مشکل برمی خورد و در طول انتشار شبکه دچار محوشدگی گرادیان می شوند [۱۵]. محققان مشکل محوشدگی گرادیان را با استفاده از شبکه های عصبی بازگشتی حل کردند [۱۶].

تشخیص ناهنجاری با استفاده از شبکه های عصبی بازگشتی در مساله تفریق پس زمینه و داده های دیگر به نتایج مطلوبی دست پیدا کرده است. به عنوان مثال می توان روش برخط^۲ ارائه شده در [۱۷] مبتنی بر واحدهای بازگشتی گیتی^۳ (GRU)، روش برخط استوار ارائه شده در مرجع [۱۸] و روش تشخیص ناهنجاری متکی بر سری های زمانی چندمتغیره در مرجع [۱۹] را ذکر کرد. در سال ۲۰۱۹، فرنوش و همکاران [۲۰] یک مدل پس زمینه احتمالی عمیق بدون نظارت به نام Deep PBM^۴ ارائه کردند که بر اساس چارچوب کد گذارهای خودکار متغیر [۲۱] برای تشخیص شیء متحرک کار می کند. در این شبکه یک مدل کم بعد از پس زمینه تخمین زده می شود. برای تفریق پس زمینه، با تکیه بر آستانه گذاری، تفاوت های بین خروجی مدل و قاب ورودی اصلی انجام می شود.

شبکه حافظه کوتاه-مدت بلند^۵ (LSTM)، یک نمونه شبکه عصبی بازگشتی بهبود یافته است. در [۲۲] یک شبکه رمزگذار و رمزگشا^۶ حافظه ی کوتاه مدت بلند برای پیش بینی پیکسل های

^۱Convolution Neural Networks^۲Online^۳Gated Recurrent Unit^۴Deep Probabilistic Background Model^۵Long Short-Term Memory^۶Encoder and decoder network^۷Attention Mechanism^۸frame^۹Boot Strap

۲- سابقه پژوهش

تفریق پس‌زمینه از پیش‌زمینه در پردازش تصویر، به معنای جداسازی شیء یا اجسام مورد نظر از پس‌زمینه تصویر است. این فرآیند در بسیاری از مسایل بینایی ماشین و پردازش تصویر استفاده می‌شود. در این بخش به انواع روش‌های جداسازی پس‌زمینه از پیش‌زمینه در دو دسته روش‌های کلاسیک آماری و شبکه‌های عصبی عمیق پرداخته شده است. توجه اصلی روی شبکه‌های عصبی عمیق می‌باشد که شامل شبکه‌های عمیق با نظارت^۱، بدون نظارت^۲ و نیمه‌نظارتی^۳ است.

۲-۱- روش‌های کلاسیک آماری

مطالعات جامعی از روش‌های مبتنی بر رویکرد^۴ PCA [۲۴] برای آزمایش و رتبه‌بندی الگوریتم‌های موجود برای تشخیص پیش‌زمینه انجام شده است. این رویکردها عموماً به صورت برون خط^۵ کار می‌کنند و با داده‌ها به صورت دسته‌ای^۶ سروکار دارند و برای برنامه‌های بلادرنگ، محدودیت در استفاده دارند. روش دیگری به نام روش مبتنی بر مدل مخلوط گاوسی^۷ (MOG) در [۲۵] ارائه شده است. مدل‌های مبتنی بر تحلیل مؤلفه‌های اصلی قوی (RPCA) برای تفکیک پس‌زمینه بازسازی شده به عنوان مؤلفه‌ای با رتبه پایین از پیش‌زمینه به عنوان یک ماتریس تنک ارائه شدند [۲۶]. در برخی موارد جداسازی پس‌زمینه از پیش‌زمینه، دقت پایین و عدم قطعیت وجود دارد که موجب شده برخی از نویسندگان به استفاده از مفاهیم فازی بپردازند [۲۷]. یک روش دیگر مبتنی بر استفاده از تخمین چگالی کرنل^۸ برای مدل کردن چگالی احتمال الگوهای محلی [۲۸] می‌باشد. از روش‌های مهم دیگر می‌توان به الگوریتم وایب^۹، به عنوان یک الگوریتم تفریق پس‌زمینه اشاره کرد [۲۹]. روش پیشنهادی برای هر پیکسل، مجموعه‌ای از مقادیر گذشته در همان مکان یا همسایگی آن را ذخیره می‌کند. سپس این مجموعه را با مقدار پیکسل فعلی مقایسه می‌کند تا تعیین کند آیا آن پیکسل متعلق به پس‌زمینه است یا خیر، و مدل را با انتخاب تصادفی مقادیری از مدل پس‌زمینه‌های جایگزینی، تطبیق می‌دهد. یک روش مدل‌سازی پس‌زمینه مبتنی بر کدگذاری تنک^{۱۰} توسط استالیانو و همکاران و معرفی شده است [۳۰]. این روش از تجزیه و تحلیل متغیر فضا استفاده می‌کند.

۲-۲- رویکردهای مبتنی بر شبکه عصبی عمیق

در سال‌های گذشته، روش‌های مبتنی بر یادگیری عمیق نشان داده‌اند که قادر به استخراج انتزاعات و داده‌های سطح بالا از مجموعه داده‌های بزرگ هستند.

ساختار شبکه عصبی عمیق شامل لایه‌هایی است که هر لایه به عنوان یک فیلتر برای استخراج ویژگی‌های مختلف از داده‌ها عمل می‌کند. هر لایه از خروجی لایه‌های قبلی خود به عنوان ورودی استفاده می‌کند و خروجی خود را به لایه‌ی بعدی ارسال می‌کند. این شبکه‌ها به کمک لایه‌های پنهان^{۱۱}، قابلیت این را دارند که بتوانند ویژگی‌های مختلفی را استخراج کنند. در نتیجه، شبکه عصبی عمیق با پردازش تدریجی و ترکیب ویژگی‌ها، به نتیجه نهایی در خروجی خود می‌رسد. شبکه‌های عصبی عمیق به روش‌های یادگیری با نظارت، یادگیری بدون نظارت و یادگیری نیمه‌نظارتی تقسیم می‌شوند. با استفاده از قابلیت این شبکه‌ها، روش‌های مختلفی مبتنی بر یادگیری عمیق جهت تفریق پس‌زمینه ارائه شده که در ادامه مرور شده‌اند.

لیو و همکاران [۳۱] اولین الگوریتم جهت تفریق پس‌زمینه را بر اساس شبکه‌های همگشتی (CNN) با الهام از قشر بینایی حیوانات ارائه کردند. شبکه‌های مولد متخاصم^{۱۲} (GAN) یکی از پیشرفت‌های چشم‌گیر در یادگیری عمیق بوده است. این شبکه اولین بار توسط گودفلو و همکاران ارائه شد. شبکه‌های GAN به عنوان یک چارچوب بسیار قدرتمند برای داده‌های بدون برچسب استفاده می‌شوند. این شبکه از دو شبکه متوالی تشکیل شده است: مولد و ممیز. بخش مولد نگاهی را از ورودی مشاهده و به خروجی می‌آموزد. برای بدست آوردن یک صحنه، از این شبکه برای استخراج پس‌زمینه استفاده شده است [۳۲] و [۳۳].

خودرمنزنگار^{۱۳} (AE) نوع دیگری از شبکه ANN^{۱۴} می‌باشد که یک شبکه یادگیری بدون نظارت است و برای کاهش داده و حجم داده استفاده می‌شود. این شبکه می‌تواند جهت استخراج پس‌زمینه مورد بهره برداری قرار بگیرد [۳۴].

یک روش دیگر برای تقسیم‌بندی و پیش‌بینی^{۱۵} (DCP) پس‌زمینه توسط سلطانا و همکاران ارائه شد [۳۵]. در یک معماری شبکه فشرده، رحمان و همکاران یک شبکه عصبی همگشتی Motion U-Net، را برای معماری عمیق رمزگذار چند نشانه‌ای توسعه دادند که نشانه‌های حرکت و تغییر را با نشانه‌های ظاهری برای تشخیص اشیاء متحرک، ادغام می‌کند [۳۶]. زنگ و همکاران یک معماری شبکه کاملاً پیچیده چند مقیاسی^{۱۶} را پیشنهاد کردند که از

^۱ supervised^۲ Unsupervised^۳ Semi supervised^۴ Principal component analysis^۵ Offline^۶ Batch -Based^۷ Of Mixture Gaussian^۸ Kernel density estimation^۹ ViBe^{۱۰} Sparse^{۱۱} Hidden Size^{۱۲} Generative Adversarial Network^{۱۳} Auto encoder^{۱۴} Artificial Neural Networks^{۱۵} Deep Context Prediction^{۱۶} Multiscale Fully convolutional Networks

معادل ابعاد تصویر است. وزن های شبکه به صورت برخط و روزرسانی می شوند و یادگیری تا آخرین قاب ویدیویی ادامه دارد به طوری که مدل پیشنهادی می تواند با تغییرات سازگار شود. یادگیری در این روش، به صورت بدون نظارت است به طوری که در هر گام زمانی، یک قاب ویدیویی پردازش شده و با رسیدن قاب ویدیویی جدید، وزن های شبکه روزرسانی می شود. با توجه به اینکه در هر لحظه فقط از یک تصویر برای روزرسانی شبکه استفاده می شود، محاسبات شبکه از پیچیدگی کمتری نسبت به روش هایی که از چند قاب استفاده می کنند، برخوردار است. در معماری شبکه عصبی عمیق جهت مدل سازی پس زمینه، از شبکه بازگشتی LSTM مبتنی بر سازوکار توجه استفاده شده است.

در شبکه های عصبی، سازوکار توجه باعث می شود که تمرکز بروی یک سری داده های مهم در حین فرآیند آموزش افزایش پیدا کند و اثر بقیه داده ها کاهش می یابد. در واقع در سازوکار توجه، در ورودی یک وزن به داده ها اختصاص داده می شود. این وزن نشان دهنده اهمیت و تاثیر این داده ها بر روند آموزش می باشد. روش پیشنهادی از سازوکار توجه بهره برده و از اولین قاب تا آخرین قاب ویدیویی را پردازش می کند. معماری شبکه و جزئیات پیاده سازی آن در ادامه آورده شده است.

۱-۳- معماری شبکه

در روش پیشنهادی، از شبکه عصبی بازگشتی LSTM استفاده شده است. چرا که در پردازش ویدیو، با داده های سری و متوالی سروکار داریم که از هم مستقل نیستند و هر داده اطلاعاتی مشابه داده های قبلی را در خود دارد. همچنین از سازوکار توجه جهت بهبود کارایی شبکه استفاده شده است و وزن ها با توجه به اهمیت داده ها روزرسانی و با تغییرات سازگار می شوند. در روش پیشنهاد شده، تمرکز روی برخی از قسمت های داده افزایش پیدا می کند. شبکه پیشنهادی به اختصاراً (ALSTM) نامیده شده است. شبکه با استفاده از لایه های تکراری پنهان قادر به یادگیری الگوهای متوالی و تخمین داده هایی با ابعاد کم می باشد. روش پیشنهادی به صورت برخط و به ازای هر فریم و بدون نظارت آموزش می بیند و لذا از پیچیدگی و محاسبات کمتری برخوردار است.

نمای کلی روش پیشنهادی در شکل ۱ ارائه شده است. در این روش، اثر آموزشی هر قاب ویدیویی حتی پس از گذشت زمان در شبکه باقی خواهد ماند و با گذشت زمان عملکرد مدل بهبود می یابد. همانطور که در شکل ۱ نمایش داده شده است، این شبکه از دو لایه LSTM، یک لایه توجه و یک لایه تماماً متصل تشکیل شده است. لازم به ذکر است خروجی لایه دوم LSTM از یک لایه تماماً متصل با ابعاد تصویر ورودی گذارنده می شود. در این رویکرد، معماری شبکه از کمترین پیچیدگی برخوردار است.

ویژگی های لایه های مختلف برای تفریق پس زمینه استفاده می کند و احتیاجی به استخراج تصاویر پس زمینه ندارد [۳۷]. در مطالعه دیگری، بیان فنگ و همکاران [۳۸] یک روش تشخیص شیء متحرک در صحنه های پیچیده با استفاده از معماری ReNet-18 برای دستیابی به طبقه بندی سطح پیکسل را ارائه کردند.

در مرجع [۳۹] یک روش نظارت شده دیگر برای تشخیص اجسام متحرک مبتنی بر شبکه رمزگذار-رمزگشا همگشتی برای استخراج ویژگی های سطح پیکسل معرفی شده است که به مدل سازی تغییرات پیکسل در طول زمان نیز می پردازد. علاوه بر این لایه هایی را نیز برای افزایش پایداری مدل در مقابل حرکت پس زمینه اضافه کرده است. در سال ۲۰۱۹، فرنوش و همکاران [۲۰] یک مدل پس زمینه احتمالاتی عمیق بدون نظارت به نام Deep PBM بر اساس چارچوبی از متغیرها را ارائه کردند. در Deep PBM یک مدل با ابعاد کم از پس زمینه تخمین زده شده و سپس پس زمینه با آستانه گذاری مشخص می شود. در این شبکه، یک کدگذار، نمایش کارآمدی از ویدیوهای ورودی را می آموزد و آن را در یک فضای تصادفی با ابعاد پایین تر تعیین شده توسط لایه های پنهان طراحی می کند و بخشبازایی تلاش می کند تا داده های اصلی را با توجه به متغیرهای احتمالاتی پنهان رمزگذار بازیابی کند.

در دهه های اخیر یادگیری های عمیق نیمه نظارتی مسیر جدیدی در حوزه یادگیری شبکه های عصبی عمیق ایجاد کرده است. در این مدل یادگیری، داده های برجسب خورده در کنار حجم زیادی از داده های برجسب نخورده در دسترس است. یادگیری نیمه نظارتی به دلیل حجم بالای داده های برجسب نخورده استفاده می شود. این روش می تواند بسیار مفید باشد چون برجسب گذاری همه داده ها، زمان بر و هزینه بر است و دارای حجم محاسباتی بالا می باشد.

۳- راهکار پیشنهادی

در این بخش، روش پیشنهادی جهت جداسازی پس زمینه مبتنی بر شبکه های عصبی عمیق بازگشتی و با استفاده از تکنیک توجه معرفی شده است.

در روش های کلاسیک، از جمله در مرجع [۴۰] پس زمینه و پیش زمینه ی قاب های ویدیویی بر اساس ماتریس کم رتبه^۱ L، و ماتریس تنک^۲ S مدل می شوند. در واقع تصویر اصلی از دو قسمت L و S به صورت $X = L + S$ تشکیل شده است. با الهام از این مدل ها، شبکه عصبی عمیق بازگشتی پیشنهادی مجهز به بخش تنک شده است تا ضمن تخمین پس زمینه، پیش زمینه را نیز استخراج کند. بدین ترتیب قسمت کم رتبه یک تخمین از پس زمینه است که به کمک شبکه عصبی عمیق مدل سازی می شود و قسمت تنک نمایانگر پیش زمینه است. ابعاد ماتریس کم رتبه و پیش زمینه

^۱Low - Rank Matrix

^۲Sparse Matrix

^۳Attention Long Short-Term Memory Network

یا همان طول دنباله‌ی ویدیویی است. قاب‌های ویدیویی به فضای خاکستری تبدیل می‌شوند. فرآیند آموزش روش پیشنهادی با استفاده از الگوریتم پس انتشار انجام می‌شود. به این ترتیب، حل مسئله بهینه سازی با تنظیم تابع تلفات به صورت تابع مربعات خطا^۲ (RMSE) می‌تواند مدل را با بروزرسانی وزن‌ها آموزش دهد. به منظور دستیابی به یک مدل تفویق پس‌زمینه، هر مرحله شامل بروزرسانی وزن‌های شبکه‌ی ALSTM بر اساس قاب‌های ویدیویی ورودی است. پیاده سازی روش پیشنهادی بر اساس توضیحات ذکر شده در الگوریتم ۱ ارائه شده است که در بخش‌های بعدی اجزا و عملکرد آن تشریح می‌شود.

الگوریتم ۱: شبکه عصبی بازگشتی (ALSTM) جهت تفویق پس‌زمینه

ورودی: قاب ویدیویی $X_t \in X = \{X_1, X_2, \dots, X_t, \dots, X_N\}$

خروجی: صحنه‌ی پس‌زمینه و پیش‌زمینه X_p .

- مقداردهی اولیه:

ماتریس کم رتبه برابر با صفر در نظر گرفته می‌شود ($L = 0$).

وزن‌های شبکه به صورت تصادفی در نظر گرفته می‌شوند.

- به ازای هر قاب ویدیویی مراحل زیر انجام می‌شود:

۱. تخمین مؤلفه‌ی کم رتبه‌ی خروجی شبکه.

۲. محاسبه‌ی ماتریس تنکبا استفاده از تفویق پس‌زمینه از قاب ویدیویی جاری:

$$S = X_t - L$$

۳. آموزش وزن‌های شبکه.

پایان توالی ویدیویی

۳-۴- مدل سازی پس‌زمینه

روش پیشنهادی بر اساس نگهداشت و بروزرسانی مدل پس‌زمینه کار می‌کند و با گذشت زمان، مدل الگوی پس‌زمینه را یاد می‌گیرد و از شبکه LSTM برای نگهداری اطلاعات و تاثیر آن بر آموزش شبکه و همچنین حذف اطلاعات اضافی استفاده می‌کند. این شبکه به گونه‌ای بروزرسانی و تنظیم می‌شود که صحنه پس‌زمینه را که یک الگوی ثابت با کمترین تغییرات استخراج می‌کند. خروجی آخرین لایه LSTM به یک لایه تماماً متصل منتقل می‌شود تا خروجی نهایی یا همان پس‌زمینه تصویر را تولید کند. اجسام متحرک به عنوان پیش‌زمینه در نظر گرفته می‌شوند و با تفویق پس‌زمینه از قاب جاری استخراج می‌شوند.

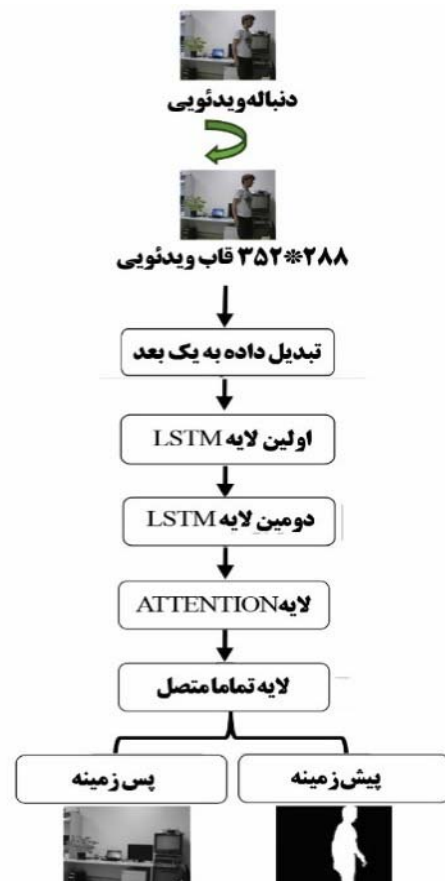
۳-۵- سازوکار توجه

همانطور که اشاره شد شبکه LSTM می‌تواند مؤلفه رتبه پایین را تخمین بزند و پس از تخمین مؤلفه با رتبه پایین، ماتریس تنک قابل استخراج است. لازم به ذکر است خروجی لایه‌ی LSTM

روش پیشنهادی، از مزایای شبکه‌های عصبی بازگشتی برای پردازش داده‌های متوالی، بدون نیاز به داده‌های برچسب گذاری شده و آموزش بدون نظارت استفاده می‌شود. در هرگام زمانی، یک قاب ویدیویی وارد مدل می‌شود و با استفاده از شبکه عصبی عمیق، یک ماتریس کم رتبه بازسازی می‌شود. ماتریس تنکبا تفویق ماتریس کم رتبه از ماتریس قاب ویدیویی حاصل می‌شود. همانطور که در ابتدا گفته شده، ماتریس کم رتبه L حاوی صحنه پس‌زمینه و ماتریس پراکنده S حاوی صحنه‌ی پیش‌زمینه است. از صحنه‌ی پس‌زمینه بازسازی شده برای محاسبه تابع خطا و آموزش شبکه با الگوریتم پس انتشار خطا استفاده می‌شود.

۲-۳- پیش پردازش داده‌ها

همانطور که گفته شد، ویدیوهای انتخاب شده از پایگاه LASIESTA هستند. این ویدیوها به فضای خاکستری تبدیل می‌شوند و با ابعاد اندازه اصلی خودشان 352×288 به صورت داده های یک بعدی در می‌آیند و وارد شبکه می‌شوند.



شکل (۱): معماری شبکه پیشنهادی ALSTM

۳-۳- آموزش شبکه پیشنهادی

توالی ویدیویی $X_t \in X = \{X_1, X_2, \dots, X_t, \dots, X_N\}$ را در نظر بگیرید که در آن قاب ویدیویی ورودی در زمان t و N تعداد قاب‌های ویدیویی

^۲Root Mean Square Error (RMSE)

^۱<http://www.gti.ssr.upm.es/data/LASIESTA>

ویدئوهای داخلی با چالش های مختلف در ۷ دسته و ویدئوهای خارجی در ۵ دسته تقسیم بندی شده اند.

۵- ارزیابی

اغلب الگوریتم های تفریق پس زمینه در استخراج پیش زمینه در شرایط ایده آل عملکرد خوبی دارند [۱]. اما گاهی اوقات توقف ناگهانی یک شیء متحرک، حرکت شاخه های درخت، استتار جسم متحرک، تغییرات مداوم پس زمینه و شرایط بد آب و هوایی تشخیص پیش زمینه را دچار مشکل می کنند. الگوریتم پیشنهادی بر روی یک مجموعه داده جامع و چالش برانگیز ارزیابی شده است تا قابلیت تعمیم آن را نشان دهد. به منظور مقایسه راهکار پیشنهادی جدیدترین و متناسب ترین راهکارهای موجود انتخاب شدند. یکی از این راهکارها، روش Deep PBM که یک روش پیشرفته و بدون نظارت است. کد این مقاله توسط نویسندگان به اشتراک گذاشته شده است [۴۲]. همچنین روش GRU [۱۵] نیز روی پایگاه داده فوق مقایسه و ارزیابی شده است. مدل پیشنهادی با استفاده از زبان پایتون و در کتابخانه pytorch نوشته شده است. برای به روزرسانی وزن های شبکه پیشنهادی از روش بهینه سازی Adam استفاده شده است. این الگوریتم از ترکیب دو روش بهینه سازی RMSprop و Momentum برای بهبود سرعت و کارایی شبکه استفاده می کند. همچنین نرخ یادگیری برابر با 2×10^{-4} تنظیم شده است.

۱-۵- معیارهای ارزیابی

با آزمایش بر روی مجموعه داده ی ذکر شده، یک ماتریس درهم ریختگی^۳ حاصل از مقایسه ی ماسک های پیش زمینه باینری با ماسک های برجسب گذاری شده مجموعه داده، بدست می آید که در آن^۴ (TP)،^۵ (TN)،^۶ (FP)،^۷ (FN) به ترتیب تعداد پیکسل های مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب را نشان می دهند. در جدول ۱ چگونگی تعریف این پارامترها مشخص شده است.

برای ارزیابی عملکرد روش پیشنهادی، از معیارهای یادآوری، دقت و اندازه ی F که به ترتیب در روابط ۱ تا ۳ تعریف شده اند، استفاده شده است.

$$RECALL = \frac{1}{2} \left(\frac{TP}{TP+FN} + \frac{T}{FN} \right) \quad (1)$$

$$Precision = \frac{1}{2} \left(\frac{TP}{TP+FP} + \frac{T}{FN} \right) \quad (2)$$

$$F\text{-Measure} = \frac{1}{n} \sum_{i=1}^n \frac{Precision \times RE}{Precision + RE} \quad (3)$$

^۳Confusion matrix

^۴True Positive

^۵True Negative

^۶False Positive

^۷False Negative

دوم از یک لایه ی تمام متصل با ابعاد تصویر ورودی گذارنده می شود. سازوکار توجه امکان مدلسازی و انعکاس وابستگی هارا بدون توجه به فاصله آن ها در توالی ورودی فراهم می کند [۴۱]. یک تابع توجه را می توان به عنوان نگاشت یک پرس و جو و مجموعه ای از جفت های کلید-مقدار به یک خروجی توصیف کرد که در آن پرس و جو، کلیدها و خروجی همه بردار هستند. خروجی به عنوان مجموع وزنی از مقادیر ورودی محاسبه می شود، که در آن وزن اختصاص داده شده به هر مقدار توسط تابع سازگاری پرس و جو با کلید مربوطه محاسبه می شود [۴۱].

استفاده از سازوکار توجه در شبکه های عصبی عمیق باعث بهبود و کیفیت شبکه های عصبی عمیق است و این امکان را به داده ها می دهد تا تمرکز را روی داده های ورودی افزایش دهد. این کار با وزن دادن به داده های ورودی انجام می شود تا برخی از ویژگی های ورودی را نسبت به سایرین اولویت دهد. این وزن ها نشان دهنده این است که هر قسمت از داده های ورودی چقدر اهمیت دارد و به چه میزان باید بر روی آنها تمرکز شود این وزن ها به طور خودکار تنظیم می شوند. ساز و کار توجه این امکان را فراهم می کند که در حین پردازش قاب به قاب تصویر بر روی اساسی ترین بخش داده ها تمرکز شود.

در مدل پیشنهادی از یک توجه چند سر^۱ استفاده شده است که به موقعیت های مختلف و موقعیت های متفاوت توجه می کند. این تکنیک کاربردهای وسیعی دارد. سازوکار توجه مدل را قدرمی سازد تا به طور انتخابی بر بخش های مختلف ورودی تمرکز کند.

۴- پایگاه داده

مجموعه داده استفاده شده LASIESTA نام دارد که شامل ۱۸۴۲۵ قاب ویدئو در اندازه 288×352 است که در ۴۸ ویدئو و ۱۴ دسته مختلف تقسیم بندی شده اند و به صورت رایگان در دسترس عموم است [۷]. این پایگاه داده یک پایگاه داده جامع و فشرده و مناسب برای تشخیص شیء متحرک می باشد. این پایگاه داده شامل مجموعه ای از داده ها است که شامل سناریوهای داخلی و خارجی است. قاب های واقعی بیرونی و داخلی زیادی در این پایگاه داده وجود دارد که در دسته بندی های مختلف سازمان دهی شده اند و هر دسته بندی چالش خاصی را پوشش را می دهد مانند تغییرات شدید روشنایی، خود راه اندازی، استتار، انسداد، پس زمینه اصلاح شده، صحنه های ساده، تغییرات مدام پس زمینه. یکی دیگر از ویژگی های برجسته آن داشتن برجسب^۲ برای تمام قاب های ویدئویی می باشد. همان طور که قبلا اشاره شد، این پایگاه داده دارای صحنه های داخلی و خارجی است. تمام

^۱Multi-Head Attention

^۲Ground truth

روش DeepPBM و محدودیت منابع، این روش تنها بر ویدیوهای شماره ۱ این پایگاه داده ارزیابی و اجرا شده است.

جدول (۲): نتایج کمی صحنه‌های داخلی بروی پایگاه داده LASIESTA (برحسب درصد).

طبقه بندی	Method	Recall	Precision	F-Measure
صحنه ساده (I_SI_01)	ALSTM	۵۸	۸۴	۷۱
	GRU	۵۶	۸۰	۶۸
	DeepPBM	۵۷	۶۳	۶۳
صحنه ساده (I_SI_02)	ALSTM	۵۱	۷۰	۶۰
	GRU	۴۹	۶۸	۵۸
صحنه استتار (I_CA_01)	ALSTM	۵۱	۷۱	۶۱
	GRU	۴۹	۷۰	۵۴
	DeepPBM	۶۲	۶۱	۶۱
صحنه استتار (I_CA_02)	ALSTM	۵۳	۷۶	۶۴
	GRU	۵۲	۷۲	۶۲
صحنه انسداد (I_OC-01)	ALSTM	۵۱	۵۶	۵۴
	GRU	۵۰	۵۶	۵۱
	DeepPBM	۵۱	۵۱	۵۳
صحنه انسداد (I_OC-02)	ALSTM	۴	۵۹	۵۲
	GRU	۴۵	۵۶	۵۱
صحنه تغییرات روشنایی (I-IL-01)	ALSTM	۵۳	۶۲	۵۸
	GRU	۵۱	۶۰	۵۹
	DeepPBM	۴۸	۵۲	۵۰
صحنه تغییرات روشنایی (I-IL-02)	ALSTM	۶۰	۵۹	۵۵
	GRU	۴۹	۵۳	۵۱
صحنه پس‌زمینه اصلاح شده (I-MB-01)	ALSTM	۵۱	۶۳	۵۶
	GRU	۴۹	۵۷	۵۲
	DeepPBM	۵۵	۶۲	۶۱
صحنه پس‌زمینه اصلاح شده (I-MB-02)	ALSTM	۵۳	۷۲	۶۴
	GRU	۵۱	۶۶	۶۱
صحنه خود راه اندازی (I-BS-01)	ALSTM	۵۲	۶۸	۶۲
	GRU	۵۳	۶۵	۶۰
	DeepPBM	۵۵	۶۰	۶۰
صحنه خود راه اندازی (I-BS-02)	ALSTM	۵۱	۵۹	۵۴
	GRU	۵۰	۵۳	۵۱

جدول (۱): تعیین پارامترهای ماتریس درهم ریختگی.

ماتریس تنک (صحنه پیش‌زمینه)	ماتریس کم‌رتبه (صحنه پس‌زمینه)	ماتریس تنک (صحنه پیش‌زمینه)
مثبت کاذب (FP)	منفی واقعی (TN)	پس‌زمینه (طبق ماسک برچسب شده در پایگاه داده)
مثبت واقعی (TP)	منفی کاذب (FN)	صحنه پیش‌زمینه (طبق ماسک برچسب شده در پایگاه داده)

یکی از رایج‌ترین معیارها، میانگین اندازه‌ی F است. اندازه‌ی F با ترکیب دو معیار مهم ارزیابی شامل یادآوری و دقت پس‌زمینه محاسبه می‌شود. بنابراین عملکرد کلی یک الگوریتم تفریق پس‌زمینه توسط مقدار اندازه‌ی F و معیار دقت آن قابل بررسی است و برای ارزیابی و تعمیم‌پذیری آن در موقعیت‌های مختلف مناسب است. بنابراین در مقایسه‌ها، بیشترین توجه به معیار اندازه‌ی F و دقت معطوف شده است.

۲-۵- نتایج کمی

جهت ارزیابی، روش پیشنهادی روی پایگاه داده پیاده سازی و اجرا شده است. نتایج با روش [Deep PBM ۴۲] و [GRU ۱۵] مقایسه شده است.

در جدول ۲ معیارهای ارزیابی محاسبه و برای صحنه‌های داخلی، مجموعه داده انتخابی نمایش داده شده است. قابل توجه است که در هر دسته چالش، دو ویدیو وجود دارد به عنوان مثال برای چالش صحنه‌های ساده، دو ویدیوی I_SI_01 و I_SI_02 ارائه شده است.

می‌توان دریافت که ALSTM به اندازه‌ی F بالاتری نسبت به روش Deep PBM که در بین روش‌های بدون نظارت، پیشرفته‌تر است، دست پیدا کرده است. همچنین نسبت به روش GRU به مقادیر بهتری دست یافته است. این معیار برای دسته‌های چالش برانگیزی مانند انسداد، تغییرات روشنایی، و استتار نیز به خوبی عمل کرده است.

یادآوری می‌شود ALSTM از اولین قاب یک ویدیو از مجموعه داده LASIESTA، بدون در نظر گرفتن مرحله آموزشی، ارزیابی شده است و قاب‌ها را یک به یک دریافت می‌کند. همچنین این نکته حائز اهمیت است که فرصت تصمیم‌گیری در مورد هر قاب تنها یک بار است.

همچنین در این جدول معیار دقت در روش پیشنهادی نسبت به روش DeepPBM و GRU به مقادیر بهتری دست یافته است. معیار بازخوانی در بعضی از چالش‌های این پایگاه داده هم اندازه بوده و در بسیاری از موارد نسبت به دو روش دیگر به مقدار بهتری داشته است. لازم به ذکر است که در این پایگاه داده، هر چالش شامل دو ویدیو می‌باشد که به دلیل نیاز به توان محاسباتی بالا برای

زیر در جدول (۴) ارائه شده است. همانطور که نتایج نشان می دهد روش پیشنهادی نتایج قابل قبولی به دست آورده ضمن اینکه یک روش بدون نظارت و برخط است. بقیه روش ها در چندین تکرار قاب های ویدیو را چندین بار پردازش می کنند و از اطلاعات برچسب نیز بهره می برند.

جدول (۳) نتایج کمی صحنه های خارجی بر روی پایگاه داده LASIESTA (برحسب درصد).

طبقه بندی	Method	Recall	Precision	F-Measure
صحنه های ابری (O_CL_01)	ALSTM	۵۳	۶۵	۶۲
	GRU	۵۱	۶۱	۵۸
	DeepPBM	۵۴	۶۱	۶۱
صحنه های ابری (O_CL_02)	ALSTM	۵۳	۹۰	۶۸
	GRU	۵۲	۷۸	۶۳
صحنه های شرایط بارانی (O_RA_01)	ALSTM	۵۳	۶۵	۶۵
	GRU	۵۲	۶۱	۵۸
	DeepPBM	۵۴	۶۰	۶۰
صحنه های شرایط بارانی (O_RA_02)	ALSTM	۵۲	۷۰	۶۸
	GRU	۵۰	۶۵	۶۵
صحنه های شرایط برفی (O_SN_01)	ALSTM	۶۷	۶۰	۶۹
	GRU	۶۳	۵۸	۶۵
	DeepPBM	۶۱	۵۶	۶۵
صحنه های شرایط برفی (O_SN_02)	ALSTM	۶۵	۶۳	۷۲
	GRU	۶۴	۵۴	۷۰
صحنه های شرایط آفتابی (O_SU_01)	ALSTM	۶۳	۸۶	۷۵
	GRU	۶۲	۸۹	۷۳
	DeepPBM	۶۱	۶۰	۶۴
صحنه های شرایط آفتابی (O_SU_02)	ALSTM	۵۱	۸۶	۶۵
	GRU	۵۰	۸۲	۶۳

نتایج نشان می دهد که روش پیشنهادی به عملکرد مناسبی در پایگاه داده LASIESTA دست یافته است و قادر است روی داده های کاملاً ناآشنا و دیده نشده پیاده سازی شود.

این نکته حائز اهمیت است که این پایگاه داده از دو مجموعه ویدیوی داخلی و خارجی تشکیل شده است. جدول شماره ۳ تمام معیارهایی که برای فضای داخلی محاسبه شده بودند را برای صحنه های خارجی نیز نمایش می دهد.

تحلیل نتایج جدول ۳ برتری روش پیشنهادی را در صحنه های خارجی نیز تایید می کند. بر این اساس می توان گفت که روش پیشنهادی در مجموعه داده LASIESTA توانسته بهتر از روش های دیگر عمل کند.

روش پیشنهادی یک رویکرد بدون نظارت و برخط است که هر قاب را فقط یک بار پردازش می کند. در مقابل، روش های یادگیری عمیق مورد مقایسه برون خط هستند و اغلب در چندین تکرار و تحت نظارت فرآیند آموزش را انجام می دهند. در ادامه برای ارائه ارزیابی کامل تر، روش پیشنهادی با تعدادی از روش های مبتنی بر یادگیری عمیق تحت نظارت، مقایسه شد و نتایج به شرح

جدول (۴): نتایج اندازه گیری F-measures در روش های نظارت شده بر روی پایگاه داده LASIESTA (برحسب درصد).

Method	I_SI-02	I_CA-02	I_OC-02	I-IL-02	I-MB-02	I-MS-02	O-CL-02	O-RA-02	O-SN-02	O-SU-02	AVG
BSUV-Net [۴۳]	۸۹	۶۰	۹۵	۸۹	۷۶	۶۹	۸۹	۹۳	۷۰	۹۱	۸۲
3DCD [۴۴]	۸۶	۴۹	۹۳	۸۵	۷۹	۸۷	۸۷	۸۷	۴۹	۸۳	۷۹
FgSegNet-s [۴۵]	۲۰	۶۰	۵۳	۲۵	۶۰	۲۸	۱۹	۱۶	۵	۱۸	۳۰
FgSegNet-M [۴۵]	۵۶	۵۵	۶۵	۴۲	۵۶	۱۹	۲۸	۱۸	۱	۳۳	۳۷
MSFS [۴۶]	۵۳	۵۸	۲۵	۴۱	۶۳	۲۵	۵۴	۵۴	۵	۲۹	۴۱
ChangeDet [۴۷]	۸۳	۶۶	۸۹	۸۷	۷۷	۸۲	۹۰	۸۵	۵۱	۸۱	۷۹
ALSTM	۶۰	۶۴	۵۲	۵۵	۶۴	۵۴	۶۸	۶۸	۷۲	۷۵	۶۳

۳-۵- نتایج کیفی

ویدیویی ها که مورد مطالعه قرار گرفته اند شامل اکثر چالش هایی هستند که در تفریق پس زمینه از پیش زمینه وجود دارند؛ مانند: شرایط انسداد، استتار، سایه ها، تغییرات نور و روشنایی و پس زمینه پویا.

قاب ورودی	GROUND Truth	ALSTM	GRU	Deep PBM
-----------	--------------	-------	-----	----------

شکل ۲ نتایج سه روش ذکر شده را نشان می دهد. از نظر بصری می توان دید که نتایج روش ALSTM بهتر از روش GRU و Deep PBM است. نتایج تشخیص پیش زمینه ALSTM دقیق تر است. همچنین در صحنه های ساده بدون استتار، بدون انسداد، تغییر نور، تغییرات مداوم پس زمینه و خود راه اندازی، جداسازی پس زمینه از پیش زمینه به راحتی قابل مشاهده است. در شرایط ابری، بارانی، برفی و آفتابی که به دلیل حرکت شاخه های درخت و سایه ها پس زمینه های پویا هستند، روش پیشنهادی می تواند اشیاء پیش زمینه را استخراج کند



الف - صحنه ساده



ب- صحنه پس زمینه اصلاح شده



پ- صحنه استتار



ت- صحنه برفی

شکل (۲): مقایسه کیفی نتایج. تصاویر از چپ به ترتیب تصویر اصلی، جواب صحیح، و نتایج روش های GRU، DEEP PBM و ALSTM هستند.

۶- نتیجه گیری

جداسازی پس زمینه از پیش زمینه یکی از مسائل مهم در پردازش تصویر و شبکه های عصبی عمیق است. در این تحقیق روشی برای حل مسئله تفریق پس زمینه با تعمیم چارچوب قوی $X=L+S$ با استفاده از شبکه های عصبی عمیق با حافظه طولانی-کوتاه مدت مبتنی بر تکنیک توجه پیشنهاد شده است. این روش، یک رویکرد بدون نظارت و برخاسته از هر تکرار آموزش فقط از یک قاب استفاده می کند.

برای ارزیابی روش پیشنهادی از پایگاه داده LASIESTA استفاده شده که یک پایگاه داده جامع و کامل بوده، تمام چالش ها را در بر می گیرد و امکان مقایسه و ارزیابی با مدل های دیگر را می دهد. مدل پیشنهادی با روش DeepPBM و GRU که از روش های به روز و بدون نظارت می باشند، مقایسه شده است. این روش را می توان برای صحنه های دیده نشده که حاوی تغییرات روشنایی، استتار، انسداد، سایه ها، خود راه اندازی، تغییرات مداوم پس زمینه و شرایط بد آب و هوایی هستند، اعمال کرد. بنابراین روش پیشنهادی برای توالی های ویدیویی که دارای پیچیدگی بالا و دنباله های طولانی در کاربردهای نظارت بر فعالیت های انسانی، نظارت بر ترافیک، نظارت بر فرودگاه ها و دریاها هستند کاربرد دارد. توسعه این روش به ویدیوهای با دوربین متحرک می تواند در تحقیقات آتی دنبال شود.

مراجع

- [14] H. Ahn and M. Kang, "Dynamic background subtraction with masked RPCA," *Signal, Image and Video Processing*, vol. 15, pp. 467–474, 2021.
- [15] A. Sedghi, E. Rashedi, M. Amoozgar, and F. Afsari, "Online vehicle detection using gated recurrent units," in *international conference on Artificial intelligence and smart Vehicle*, 2023.
- [16] K. Cho, B. Van Merriënboer, D. Bahdanau, and Y. Bengio, "On the properties of neural machine translation: Encoder–decoder approaches," *arXiv preprint arXiv:1409.1259*, 2014.
- [17] A. Sedghi, M. Amoozger, E. Rashedi, and F. Afsari, "ORGU: Online Robust Gated Recurrent Units for Real Time Background Subtraction in video sequences," 10.21203/rs.3.rs-3138445/v1, 2023.
- [18] [18] مریم، آموزگار. مرتضی، فائزی نیا، بهروز، مینایی بیدگلی "تشخیص برخط ناهنجاری با استفاده از شبکه عصبی بازگشتی" نشریه مدلسازی در مهندسی ۱۴۰۲
- [19] G. Li and J. J. Jung, "Deep learning for anomaly detection in multivariate time series: Approaches, applications, and challenges," *Information Fusion*, vol. 91, pp. 93–102, 2023.
- [20] A. Farnoosh, B. Rezaei, and S. Ostadabbas, "DeepPBM: deep probabilistic background model estimation from video sequences," in *International Conference on pattern Recognition (ICPR)*, 2021, pp. 608–621
- [21] D. P. Kingma and M. Welling, "Auto–encoding variational bayes," *arXiv preprint arXiv:1312.6114*, 2013.
- [22] S.choo,w.seo,Dudhance ,and N.I.Cho."Multi–scale recurrent encoder–decoder network for dense temporal classification '. In 2018 24 th International Conference on Pattern Recognition (ICPR) ,2018,pp.103_108
- [23] P. Liu, J. Feng, J. Sang, and Y. K. Kim, "Fusion Attention Mechanism for Foreground Detection Based on Multiscale U–Net Architecture," *Computational Intelligence and Neuroscience*, vol. 2022, 2022.
- [24] H. Ahn and M. Kang, "Daynamic background subtraction with masked RPCA" *signalImage Video Proscess*, vol. 15. no. 3 pp. 467–474, 2021
- [25] T. Bouwmans, F. El Baf, and B. Vachon, "Background modeling using mixture of gaussians for foreground detection–a survey," *Recent patents on computer science*, vol. 1, no. 3, pp. 219–237, 2008.
- [26] S. Javed, A. Mahmood, T. Bouwmans, and S. K. Jung, "Background–foreground modeling based on spatiotemporal sparse subspace clustering," *IEEE Transactions on Image Processing*, vol. 26, no. 12, pp. 5840–5854, 2017.
- [27] T. Bouwmans, "Background subtraction for visual surveillance: A fuzzy approach," *Handbook on soft computing for video surveillance*, vol. 5, pp. 103–138, 2012.
- [28] S. Liao, G. Zhao, V. Kellokumpu, M. Pietikäinen, and S. Z. Li, "Modeling pixel process with scale invariant local
- [1] مریم. آموزگار، معصومه. اکبری زاده، "بهبود فرآیند مدل در مسئله تفریق پس زمینه" نشریه علوم رایانش و فناوری اطلاعات ۱۴۰۰
- [2] W. Farag and Z. Saleh "An advanced vehicle detection and tracking scheme for self-driving cars," 2nd Smart Cities Symposium (SCS 2019), 2019, pp. 1–6.
- [3] P. Zhang, W. Liu, Y. Lei, H. Wang, and H. Lu, "RAPNet: Residual atrous pyramid network for importance–aware street scene parsing," *IEEE Trans. Image Process.*, vol. 29, pp. 5010–5021, 2020.
- [4] K. M. Biradar, A. Gupta, M. Mandal, and S. K. Vipparthi, "Challenges in time–stamp aware anomaly detection in traffic videos," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops*, Jun. 2019, pp. 13–20.
- [5] X. Dong, J. Shen, D. Wu, K. Guo, X. Jin, and F. Porikli, "Quadruplet network with one–shot learning for fast visual object tracking," *IEEE Trans. Image Process.*, vol. 28, no. 7, pp. 3516–3527, Jul. 2019.
- [6] Z. Fu, Y. Chen, H. Yong, R. Jiang, L. Zhang, and X.–S. Hua, "Foreground gating and background refining network for surveillance object detection," *IEEE Trans. Image Process.*, vol. 28, no. 12, pp. 6077–6090, Dec. 2019.
- [7] C. Cuevas, E. M. Yáñez, and N. García, "Labeled dataset for integral evaluation of moving object detection algorithms: LASIESTA," *Computer Vision and Image Understanding*, vol. 152, pp. 103–117, 2016.
- [8] D. Comaniciu, V. Ramesh, and P. Meer, "Kernel–based object tracking," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 25, no. 5, pp. 564–577, 2003.
- [9] X. Yin, B. Wang, W. Li, Y. Liu, and M. Zhang, "Background Subtraction for Moving Cameras based on trajectory–controlled segmentation and Label Inference," *Ksii Transactions on Internet & Information Systems*, vol. 9, no. 10, 2015.
- [10] T. Bouwmans, Ja, Sved, M. Sultana, and S. k. Jung, "Deep neural network concept for background subtraction :A systematic review and comparative evaluation ," *Neural Network* , vol. 117, pp 8–66, 2019
- [11] C. Rao and Y. Liu, "Three–dimensional convolutional neural network (3D–CNN) for heterogeneous material homogenization," *Computational Materials Science*, vol. 184, p. 109850, 2020.
- [12] D. Alapatt *et al.*, "Temporally Constrained Neural Networks (TCNN): A framework for semi–supervised video semantic segmentation," *arXiv preprint arXiv:2112.13815*, 2021.
- [13] D. Zeng, M. Zhu, and A. Kuijper, "Combining background subtraction algorithms with convolutional neural network," *Journal of Electronic Imaging*, vol. 28, no. 1, pp. 013011–013011, 2019.

- [41] A. Vaswani *et al.*, "Attention is all you need," *Advances in neural information processing systems*, vol. 30, 2017.
- [42] "Deep PBM".<https://github.com/ostadabbas/DeepPBM>.
- [43] M. O. Tezcan, P. Ishwar, and J. Konrad, "BSUV-Net 2.0: Spatio-temporal data augmentation for video-agnostic supervised background subtraction," *IEEE Access*, vol. 9, pp. 53849-53860, 2021.
- [44] M. Mandal, V. Dhar, A. Mishra, S. K. Vipparthi, and M. Abodel-Mottaleb, "3DCD: Scene independent end-to-end spatiotemporal feature learning framework for change detection in unseen videos," *IEEE Trans. Image Process.* Vol. 30, pp. 546-558, 2020.
- [45] L. A. Lim, H. Y. Keles, "Foreground segmentation using a triplet convolution neural network for multiscale feature encoding," *arXiv preprint arXiv:1801.02225*, 2018.
- [46] L. A. Lim, H. Y. Keles, "Learning multi-scale features for foreground segmentation," *Pattern Anal. Appl.*, vol. 23, no. 3, pp. 1369-1380, 2020.
- [47] M. Mandal and S. K. Vipparthi, "Scene independency matters: An empirical study of scene dependent and scene independent evaluation for CNN-based change detection," *IEEE Trans. Intell. Transp. Syst.*, 2020.
- [29] O. Barnich and M. Van Droogbroeck, "ViBe: A universal background subtraction algorithm for video sequence," *IEEE Trans. Image Process.* Vol. 20, no. 6, pp. 1709-1724, 2010.
- [30] A. Stagliano, N. Noceti, A. Verri, and F. Odone, "Online space-variant background modeling with sparse coding," *IEEE Trans. Image Process.* Vol. 24, no. 8, pp. 2010-2020, 2015.
- [31] Y. Zhang, X. Li, Z. Zhang, F. Wu, and L. Zhao, "Deep learning driven blockwise moving object detection with binary scene modeling," *Neurocomputing*, vol. 168, pp. 454-463, 2015.
- [32] M. C. Bakay, H. A. Rashwan, H. Salmane, L. Khoudour, D. Puig, and Y. Ruichek, "BSCGAN: Deep background subtraction with conditional generative adversarial networks," in *2018 25th IEEE International Conference on Image Processing (ICIP)*, 2018: IEEE, pp. 4018-4022.
- [33] W. Zheng, K. Wang, F. Y. Wang, "A novel background subtraction algorithm based on parallel vision and Bayesian GANs," *Neurocomputing*, Volume 394, pp. 178-200, 2020.
- [34] B. Sauvalle, A. Fortelle, "Autoencoder-based background reconstruction and foreground segmentation with background noise estimation," *cvf open access*, 2023.
- [35] M. Sultana, A. Mahmood, S. Javed, and S. K. Jung, "Unsupervised deep context prediction for background estimation and foreground segmentation," *Machine Vision and Applications*, vol. 30, pp. 375-395, 2019.
- [36] G. Rahmon, F. Bunyak, G. Seetharaman, and K. Palaniappan, "Motion U-Net: Multi-cue encoder-decoder network for motion segmentation," in *2020 25th International Conference on Pattern Recognition (ICPR)*, 2021: IEEE, pp. 8125-8132.
- [37] D. Zeng and M. Zhu, "Background subtraction using multiscale fully convolutional network," *IEEE Access*, vol. 6, pp. 16010-16021, 2018.
- [38] X. Bian, S. N. Lim, and N. Zhou, "Multiscale Fully convolutional network with application to industrial inspection," in *2016 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2016.
- [39] Y. Chen, J. Wang, B. Zhu, M. Tang, and H. Lu, "Pixelwise deep sequence learning for moving object detection," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 29, no. 9, pp. 2567-2579, 2017.
- [40] C. Zhou and R. C. Paffenroth, "Anomaly detection with robust deep autoencoders," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Aug. 2017, Vol. Part F1 29685, pp. 665-674. doi:10.1145/3097983.3098052.



مهشام کوشکی مدرک کارشناسی را سال ۱۳۹۸ و کارشناسی ارشد خود را در سال ۱۴۰۲ در رشته مخابرات سیستم در دانشگاه تکمیلی صنعتی و فناوری‌های پیشرفته دریافت کرد. هم‌اکنون دانشجوی دکتری مخابرات سیستم در دانشگاه تکمیلی صنعتی و فناوری‌های پیشرفته می‌باشد. زمینه علاقمندی ایشان پردازش تصویر، یادگیری ماشین و هوش مصنوعی است.



عصمت راشدی دارای دکترای در رشته مهندسی برق گرایش مخابرات سیستم می‌باشد. وی هم‌اکنون دانشیار گروه مهندسی برق دانشگاه تحصیلات تکمیلی صنعتی و فناوری‌های پیشرفته در شهر کرمان است. زمینه‌های پژوهشی ایشان پردازش تصویر و ویدیو، بازشناسی الگو، الگوریتم‌های بهینه‌سازی ابتکاری و شبکه‌های عصبی عمیق است.



مریم آموزگار مدرک دکتری خود در رشته مهندسی نرم افزار را از دانشگاه علم و صنعت ایران دریافت کرده است. وی هم‌اکنون استادیار پژوهشکده کامپیوتر و فناوری اطلاعات در پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی در دانشگاه تحصیلات تکمیلی صنعتی و فناوری‌های پیشرفته است. علایق تحقیقاتی او تشخیص ناهنجاری، پردازش داده‌های جریانی، یادگیری ماشین و الگوریتم‌های فراابتکاری می‌باشد.