

تشخیص خودکار باران از ویدئوهای دیجیتال با استفاده از الگوریتم جریان نوری فارنباک

فاطمه حیدری^۱، اصغر میلان^{۲*}، علیرضا وفائی نژاد^۳

^۱ دانشجوی، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. fateme.heydari2@mail.sbu.ac.ir

^{۲*} نویسنده مسئول، استادیار، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. a_milan@sbu.ac.ir

^۳ دانشیار، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. a_vafaei@sbu.ac.ir

تاریخ پذیرش: ۱۴۰۴/۱۱/۱۷

تاریخ بازنگری: ۱۴۰۴/۱۰/۱۰

تاریخ دریافت: ۱۴۰۴/۰۹/۲۳

چکیده

تشخیص خودکار باران از تصاویر دیجیتال، به‌ویژه در مناطق فاقد تجهیزات سنتی، ابزاری کم‌هزینه و مؤثر برای پایش جوی و ارائه هشدار سریع است. در این پژوهش، الگوریتم جریان نوری فارنباک (Farneback) برای شناسایی حرکت‌های ناشی از باران در فریم‌های متوالی ویدئو به کار گرفته شد. این روش با تحلیل حرکت عمودی پیکسل‌ها قادر به تشخیص بارش است و به‌عنوان روشی ساده و نسبتاً پایدار در شرایط واقعی عمل می‌کند. برای ارزیابی، مجموعه‌ای از ویدئوهای بارانی و غیر بارانی انتخاب و نتایج با برچسب‌گذاری دستی مقایسه شدند. دقت میانگین الگوریتم حدوداً ۷۸/۷۲ درصد است که نشان‌دهنده توانایی مناسب آن در تشخیص باران است، به‌ویژه در ویدئوهای با نرخ فریم ثابت و روشنایی نسبتاً بالاتر. نتایج نشان می‌دهد که این روش می‌تواند با ترکیب شدن با سایر روش‌ها و آموزش دیدن به نتایج مطلوب‌تری دست پیدا کند و از نظر هزینه و پیاده‌سازی مقرون‌به‌صرفه باشد. این رویکرد برای کاربردهای بلادرنگ و نظارتی مناسب است و می‌تواند جایگزینی کم‌هزینه برای تجهیزات سنتی محسوب شود. با توجه به اهمیت تشخیص باران در مدیریت بلایای طبیعی و تغییرات اقلیمی، این حوزه به زمینه‌ای حیاتی در پژوهش‌های اخیر تبدیل شده است و بهبودهای آتی می‌تواند کارایی و دقت را افزایش دهد.

واژه‌های کلیدی: تشخیص خودکار قطرات و نوارهای باران، پردازش تصویر، الگوریتم جریان نوری فارنباک، ویدئوهای

دوربین مداربسته

۱. مقدمه

پدیده‌های هیدرومثنورولوژیکی مانند بارش‌های شدید و سیلاب‌های شهری، به‌ویژه در شرایطی که تراکم ابزارهای اندازه‌گیری بارش پایین است، چالش‌های مهمی ایجاد کرده‌اند. در این راستا، استفاده از دوربین‌های مداربسته به‌عنوان یک راهکار نوآورانه مطرح شده است. این دوربین‌ها که به‌طور گسترده در مناطق شهری نصب شده‌اند، علاوه بر کاربردهای نظارتی، قابلیت ثبت اطلاعات تصویری مرتبط با بارش را دارند. پژوهش‌ها نشان داده‌اند که با به‌کارگیری الگوریتم‌هایی مانند طبقه‌بندی نزدیک‌ترین همسایگی^۱ (KNN) و روش‌های یادگیری ماشین، می‌توان تصاویر دوربین‌های مداربسته را به داده‌های کمی بارش تبدیل کرد و به دقتی بالاتر از ۹۸٪ در تشخیص باران دست یافت. این روش‌ها ضمن کاهش هزینه‌ها، اطلاعات بارش با رزولوشن مکانی بالاتری فراهم کرده و می‌توانند نقش مؤثری در بهبود سیستم‌های هشدار سریع و کاهش خسارات بلایای طبیعی داشته باشد [۱].

تشخیص خودکار باران از تصاویر دیجیتال به دلیل تأثیر گسترده بارش بر زندگی روزمره و صنایع مختلف اهمیت زیادی دارد. یکی از چالش‌های اصلی در این حوزه، تفکیک باران از پدیده‌های مشابه مانند مه و ابر است که می‌تواند دقت مدل‌ها را کاهش دهد [۲]. روش‌های سنتی نظیر رادار و ایستگاه‌های باران‌سنج با محدودیت پوشش مکانی و هزینه‌های بالا مواجه‌اند و همین موضوع باعث شده است استفاده از تکنیک‌های پردازش تصویر، بینایی ماشین و یادگیری عمیق به‌عنوان جایگزینی کارآمد مورد توجه قرار گیرد. این روش‌ها قادرند علاوه بر تشخیص وقوع باران، شدت آن را نیز تخمین بزنند و در بارش‌های شدید عملکرد بهتری داشته باشند، هرچند همچنان در پس‌زمینه‌های پیچیده و نورهای متغیر با چالش‌هایی روبه‌رو هستند [۳].

در مطالعات مختلف، روش‌های متنوعی برای تشخیص باران ارائه شده است؛ از جمله شبکه‌های عصبی کانولوشنی^۲ (CNN) که دقتی بیش از ۹۵٪ گزارش کرده‌اند [۲]، سیستم‌های مبتنی بر ویدئوهای مادون قرمز همراه با الگوریتم

نزدیک‌ترین همسایگی برای تحلیل رگه‌های باران و محاسبه شدت بارش [۴]، و تکنیک جریان نوری فارنبرگ که با تخمین دقیق حرکت پیکسل‌ها، اطلاعات مفیدی از دینامیک بارندگی استخراج می‌کند [۵]. این روش‌ها امکان تحلیل جامع‌تر و دقیق‌تر شرایط بارندگی را فراهم می‌سازند.

تشخیص باران از تصاویر با چالش‌های دیگری نیز همراه است، از جمله تغییرات شرایط نوری، حرکت پس‌زمینه، چگالی و اندازه قطرات، زاویه و سرعت سقوط باران و همچنین نیاز به پردازش آنی داده‌ها. تغییرات نور طبیعی و مصنوعی می‌تواند باعث خطای تشخیص شود و حرکات اشیای متحرک در محیط‌های شهری نیز تفکیک باران را دشوار می‌کند. برای مقابله با این مسائل، از الگوریتم‌های تطبیقی و مدل‌های یادگیری ماشین و عمیق استفاده می‌شود، هرچند این روش‌ها هزینه محاسباتی بالایی دارند و به داده‌های آموزشی گسترده نیازمندند [۶][۷]. همچنین مدل‌سازی ویژگی‌های فیزیکی و دینامیکی قطرات باران نقش مهمی در افزایش دقت تشخیص دارد [۸][۹].

در مجموع، تشخیص خودکار باران از تصاویر دیجیتال به دلیل پوشش مکانی گسترده، هزینه پایین و قابلیت ارائه اطلاعات دقیق، راهکاری نوین و مؤثر برای پیش‌بارش و مدیریت بلایای طبیعی مطرح است و می‌تواند جایگزین یا مکمل مناسبی برای روش‌های سنتی در آینده باشد.

۲. مروری بر تحقیقات گذشته

در سال‌های اخیر، تشخیص و حذف باران از تصاویر و ویدئوها به یکی از موضوعات مهم در پردازش تصویر و بینایی ماشین تبدیل شده است، زیرا حضور باران می‌تواند کیفیت داده‌های تصویری و عملکرد سامانه‌های نظارتی و هواشناسی را کاهش دهد. در پژوهش‌های اولیه، تمرکز عمدتاً بر ویدئوها بود؛ چرا که رشته‌های باران معمولاً تنها در یک فریم دیده می‌شوند. گرگ و نایار (۲۰۰۴) با استفاده از قید فوتومتريک و تحلیل مورفولوژیک، و بارنوم و همکاران (۲۰۱۰) با تحلیل فرکانسی و تبدیل فوری، روش‌هایی برای شناسایی باران ارائه کردند [۱۰].

با پیشرفت یادگیری ماشین، تخمین شدت بارش از تصاویر اهمیت بیشتری یافت. رحایو و همکاران (۲۰۲۳) با استفاده از KNN و تصاویر دوربین مدار بسته شدت بارش را با دقت بیش از ۹۸٪ پیش‌بینی کردند و تطابق ۹۴٪ با داده‌های واقعی ایستگاه هواشناسی خودکار نشان دادند [۱]. مشابه آن، لی و همکاران (۲۰۲۳) با ترکیب الگوریتم KNN و تحلیل اپتیک فیزیکی توانستند شدت بارش را تخمین بزنند و میانگین درصد خطای قدرمطلق (MAPE) بین ۲۳٪ تا ۴۹٪ گزارش شد. علاوه بر این، فیالوس-سالگرو و همکاران (۲۰۲۴) با بهره‌گیری از بینایی کامپیوتری، CNN و اپتیک هندسی توانستند MAPE بین ۳/۹٪ تا ۱۲/۷٪ برای تخمین بارش ارائه دهند [۱]. حکیم و دویی (۲۰۲۱) با شبکه عصبی کانولوشنی دقت آموزش ۹۸/۸٪، دقت تست ۹۶/۴٪ و دقت کلی ۹۶/۷٪ با داده‌های رصدی را به دست آوردند [۲].

در زمینه حذف باران از تصاویر منفرد، فو و یوهسینگ (۲۰۱۱) با تحلیل اجزای مورفولوژیکی و فیلتر دوطرفه، هوانگ و همکاران (۲۰۱۶) با تفکیک مؤلفه‌های فرکانس بالا و پایین، کیم و همکاران (۲۰۱۸) با فیلتر میانگین غیرمحملی تطبیقی، و آینگن و همکاران (۲۰۱۶) با آموزش CNN ها، روش‌های مؤثری برای حذف باران ارائه کرده‌اند [۱۱]. ژنگ و همکاران (۲۰۱۹-۲۰۲۱) نیز با استفاده از شبکه‌های چندمقیاس، حذف رشته‌های باران را بهبود داده‌اند. شبکه‌های عصبی کانولوشنی نقش مهمی در هر دو وظیفه

تشخیص و حذف باران ایفا کرده‌اند. ونگ و همکاران (۲۰۲۰) با یادگیری باقیمانده ساختاریافته دقت حذف باران از تصاویر واقعی را افزایش دادند [۱۲]. در حوزه ویدئو، یانگ و همکاران (۲۰۲۰) با روش یادگیری خودنظارتی موفق شدند به نسبت سیگنال به نویز بیشینه^۴ (PSNR) با مقدار ۳۴/۸۹ دسی‌بل و شاخص شباهت ساختاری^۵ (SSIM) با مقدار ۰/۹۵۴ در مجموعه داده NTURain به‌دست آورند [۱۳]. همچنین، یین و همکاران (۲۰۲۱) و اسلام و همکاران (۲۰۲۱) با روش‌هایی مبتنی بر هم‌ترازسازی و ترکیب ویژگی‌های فیزیکی صحنه، کیفیت حذف باران از ویدئوها را بهبود دادند [۱۴][۱۵]. ونگ و همکاران (۲۰۲۲) با معرفی مدل سنتز جدید برای شبیه‌سازی حرکت نوارهای باران، عملکرد شبکه‌های حذف باران ویدئویی را ارتقا دادند [۱۶].

در مجموع، مطالعات اخیر نشان می‌دهند که استفاده از یادگیری عمیق، تحلیل چندمقیاس، ادغام جریان نوری با شبکه‌های عصبی و مدل‌سازی دقیق ساختار باران موجب بهبود قابل توجه دقت و پایداری سامانه‌های تشخیص و حذف باران شده است. با وجود چالش‌هایی مانند پیچیدگی محاسباتی و نیاز به داده‌های آموزشی گسترده، این پیشرفت‌ها چشم‌انداز روشنی برای توسعه سامانه‌های کارآمد در کاربردهای نظارتی و هواشناسی فراهم کرده‌اند، به‌طوری‌که نتایج کمی و دقت روش‌های مختلف در جدول ۱ ارائه شده است.

جدول ۱: نتایج مطالعات اخیر در حوزه حذف باران

پژوهشگران	سال	روش مورد استفاده	دقت به دست آمده
رحایو و همکاران	۲۰۲۳	KNN	دقت تخمین شدت بارش = بالای ۹۸ درصد دقت مقایسه با داده‌های AWS = ۹۴ درصد
حکیم و دویی	۲۰۲۱	CNN	دقت در آموزش = ۹۸/۸ درصد دقت در تست = ۹۶/۴ درصد دقت کلی در ارزیابی با داده‌های رصدی = ۹۶/۷ درصد
فیالوس-سالگرو و همکاران	۲۰۲۴	بینایی کامپیوتری، شبکه عصبی کانولوشنی (CNN) و اپتیک هندسی	مقدار گزارش شده MAPE = بین ۳/۹ تا ۱۲/۷ درصد
لی و همکاران	۲۰۲۳	الگوریتم KNN و تحلیل اپتیک فیزیکی	مقدار گزارش شده MAPE = بین ۲۳ تا ۴۹ درصد
یانگ و همکاران	۲۰۲۰	یادگیری خودنظارتی	مقدار PSNR = ۳۴/۸۹ دسی‌بل مقدار SSIM = ۰/۹۵۴



شکل ۱. نمونه‌هایی از فریم‌های برخی ویدئوهای انتخاب شده. تصاویر اول و سوم فریم‌هایی از ویدئوهای غیر بارانی، تصاویر دوم و چهارم فریم‌هایی از ویدئوهای بارانی.

۳-۲. روش پیشنهادی تحقیق

از آنجا که جابجایی‌های نقطه به نقطه می‌تواند نویز داشته باشد، برای بهبود دقت تخمین حرکت، اطلاعات جابجایی در ناحیه‌های بزرگ‌تر از همسایگی یک پیکسل ترکیب می‌شود. این فرض در نظر گرفته می‌شود که حرکت در یک ناحیه کوچک به‌طور تدریجی تغییر می‌کند و همین امر باعث کاهش نویز و بهبود تخمین نهایی حرکت می‌شود. برای مقابله با حرکت‌های بزرگ، از تکنیک مقیاس‌های چندگانه استفاده می‌شود. ابتدا تصویر در مقیاس‌های درشت‌تر پردازش می‌شود تا یک تخمین اولیه از حرکت به دست آید. سپس این تخمین در مقیاس‌های دقیق‌تر و جزئی‌تر بهبود داده می‌شود. این فرآیند باعث می‌شود که الگوریتم بتواند حرکت‌های بزرگ را به درستی شناسایی کرده و سپس آن‌ها را با دقت بیشتری اصلاح کند [۵]. فرایند صورت گرفته در این تحقیق در شکل (۲) آمده است و در ادامه هر مرحله شرح داده شده است.

۳. مواد و روش‌ها

۳-۱. داده‌ها و نرم‌افزارهای مورد استفاده در این

تحقیق

در این تحقیق، داده‌های ویدئویی از منابع مختلف نظیر وبسایت‌های YouTube، Pixabay و آپارات و غیره جمع‌آوری و مورد استفاده قرار گرفته‌اند. ویدئوهای بارانی‌ای دانلود شدند که شامل بارش باران به‌صورت طبیعی در یک محیط شهری و یا ویدئوهای بارانی سینماتیک بود. این ویدئوها برای شبیه‌سازی شرایط واقعی و ارزیابی حساسیت روش نسبت به تغییرات بارانی انتخاب شدند. ویدئوهای دیگری نیز دریافت شدند که شامل تصاویری بودند که در شرایط آب و هوایی خشک ضبط شده بودند. این ویدئوها به‌عنوان نمونه‌ای از شرایط بدون باران جهت مقایسه و تحلیل عملکرد روش در محیط‌های بدون باران مورد استفاده قرار گرفتند. همه‌ی ویدئوها به‌طور تصادفی انتخاب و فریم‌های آنها برای پردازش و تحلیل با استفاده از روش جریان نوری فارنبرگ استخراج شدند. شکل شماره (۱) یک مجموعه از نمونه‌هایی از فریم‌های این ویدئوها را نشان می‌دهد. در این شکل، فریم‌های مربوط به ویدئوهای بارانی و غیر بارانی به‌طور جداگانه نمایش داده شده‌اند تا تفاوت‌های بصری و تأثیر باران بر روی پردازش جریان اپتیکال به وضوح قابل مشاهده باشد.

برای پیاده‌سازی روش پیشنهادی در این تحقیق از نرم‌افزار Python 3.11 و کتابخانه‌های معتبر OpenCV و NumPy استفاده شده است.

ادامه، الگوریتم جریان نوری فارنبرگ بر جفت فریم‌های متوالی اعمال شد. در این روش، شدت تصویر در یک ناحیه محلی با یک مدل چندجمله‌ای درجه دوم که در رابطه‌ی (۲) ارائه شده است تقریب زده می‌شود.

$$I(x) \approx x^T A x + b^T x + c \quad (2)$$

که در آن $x = (x, y)$ مختصات پیکسل، A ماتریس ضرایب درجه دوم، b بردار ضرایب خطی و c مقدار ثابت است [۵]. با تحلیل ضرایب مدل بین دو فریم، بردار جابجایی هر پیکسل محاسبه شده و به مختصات قطبی تبدیل می‌شود.

برای شناسایی قطرات باران، تنها آن دسته از پیکسل‌هایی که دارای زاویه حرکت بین ۷۵ درجه تا ۱۰۵ درجه [۲۰] (یعنی در راستای عمودی) و شدت حرکت معنادار باشند انتخاب شدند. سپس دو ویژگی کلیدی محاسبه شد، نسبت پیکسل‌هایی با حرکت عمودی به کل پیکسل‌های متحرک که نحوه محاسبه‌ی آن‌ها در رابطه‌های (۳) و (۴) نشان داده شده است.


$$\text{Vertical_Ratio} = \frac{N_{\text{vertical}}}{N_{\text{moving}}} \quad (3)$$

$$\text{VerticalMotion} = \left(\frac{1}{N_{\text{vertical}}} \right) \sum m_i \quad (4)$$

که در رابطه شماره (۴) m_i شدت حرکت بردار جابجایی هر پیکسل i با جهت عمودی است [۵]. در صورتی که هر دو مقدار از آستانه‌های تعیین شده عبور کنند، آن فریم به عنوان «بارانی» شناخته می‌شود. برای اطمینان از تداوم بارش، این تحلیل برای چند فریم متوالی تکرار شد و اگر در حداقل سه فریم پیوسته شرایط برقرار بود، نتیجه به صورت «باران شناسایی شد» اعلام می‌شود.

برای ارزیابی عملکرد الگوریتم، از روش مقایسه با برجسب‌های دستی استفاده شد. ۳۰ فریم با فواصل یکسان مشخص شده و در هر یک به شکل دستی تعیین شد که آیا در آن فریم باران مشاهده می‌شود یا خیر. این برجسب‌های دستی به عنوان داده‌های مرجع^۷ در نظر گرفته شدند.

الگوریتم نیز بر اساس همین فریم‌ها پیش‌بینی خودکار را ارائه



شکل ۲. الگوریتم فرایند انجام تحقیق

فرآیند تحلیل شامل چند مرحله‌ی متوالی است. نخست، تصاویر ویدئویی بارانی و غیر بارانی وارد سیستم شده و به فریم‌های جداگانه تقسیم شدند. برای هر فریم، مرحله پیش‌پردازش شامل کاهش نویز با استفاده از ترکیب دو فیلتر استاندارد انجام شد. ابتدا فیلتر گوسین و سپس فیلتر میانه به منظور حذف نویزهای لکه‌ای اعمال گردیده است [۱۷]. در گام بعد، برای حذف عناصر ثابت پس‌زمینه و تمرکز بر نواحی متحرک، از مدل گوسی تطبیقی^۸ (MOG2) استفاده شد که مقدار شدت هر پیکسل را با ترکیب چند توزیع گوسی با بکارگیری رابطه (۱) مدل می‌کند.

$$P(xt) = \sum (\omega_i \times N(xt; \mu_i, \sigma_i^2)) \quad (1)$$

که در آن ω_i وزن یا احتمال حضور مؤلفه i -ام، μ_i میانگین شدت آن مؤلفه، و σ_i^2 واریانس آن است و $N(xt; \mu_i, \sigma_i^2)$ نیز تابع توزیع نرمال با این پارامترها را نشان می‌دهد [۱۸][۱۹]. در

جریان نوری فارنبرگ بر روی جفت فریم‌های متوالی اعمال می‌شود. این جفت‌ها به ما کمک می‌کنند تا تغییرات حرکتی را در طول زمان شناسایی کنیم. با استفاده از روش فارنبرگ، جابجایی پیکسل‌ها محاسبه می‌شود که به ما امکان می‌دهد تا حرکات عمودی و افقی را شناسایی کنیم.

برای بهبود کیفیت نتایج، از فیلتر گاوسی و میانه برای حذف نویز و افزایش وضوح تصویر استفاده می‌شود. فیلترهای پایین گذر به ما کمک می‌کنند تا تغییرات ناگهانی در تصویر را کاهش دهیم و حرکات مرتبط با باران را بهتر شناسایی کنیم. شکل (۳) یک مقایسه تصویری بین قبل و بعد از اعمال فیلتر گاوسی بر تصویر را نشان می‌دهد.



شکل ۳. تصویر سمت چپ تصویر اصلی، تصویر سمت راست پس از اعمال فیلتر گاوسی.

و شکل (۴) یک مقایسه تصویری بین قبل و بعد از اعمال فیلتر میانه بر تصویر را نشان می‌دهد.



شکل ۴. تصویر سمت چپ تصویر اصلی، تصویر سمت راست پس از اعمال فیلتر میانه.

سپس، برای هر فریم، زاویه و شدت حرکت پیکسل‌های متحرک با دقت تحلیل می‌شود. الگوریتم تنها پیکسل‌هایی را در نظر می‌گیرد که حرکت تقریباً عمودی دارند (زاویه بین ۷۵ تا ۱۰۵ درجه) و شدت حرکت آن‌ها قابل توجه است. با این کار، الگوهای حرکت مرتبط با باران از سایر حرکات متحرک پس‌زمینه یا اشیای محیط جدا می‌شوند. سپس دو ویژگی کلیدی برای فریم محاسبه می‌شود: نسبت پیکسل‌های

داد و سپس یک ماتریس درهم ریختگی^۸ به صورت جدول (۲) تشکیل شد.

جدول ۲. درایه‌های ماتریس درهم ریختگی

	پیش‌بینی بدون باران	پیش‌بینی باران
باران واقعی	FN	TP
بدون باران واقعی	TN	FP

ماتریس درهم ریختگی، ابزاری مهم برای ارزیابی عملکرد مدل‌های دسته‌بندی دودویی است که شامل چهار مؤلفه کلیدی می‌باشد:

۱. مثبت‌های درست^۹ (TP)
۲. منفی‌های درست^{۱۰} (TN)
۳. مثبت‌های نادرست^{۱۱} (FP)
۴. منفی‌های نادرست^{۱۲} (FN) [۲۱].

و در نهایت دقت کلی الگوریتم از طریق رابطه (۹) محاسبه گردید [۲۲].

$$\text{Accuracy} = \frac{TN + TP}{TN + TP + FN + FP} \quad (5)$$

۴. پیاده سازی و ارائه نتایج

در این بخش، پیاده‌سازی الگوریتم تشخیص باران با استفاده از روش جریان نوری فارنبرگ به‌طور دقیق و جامع بررسی می‌شود. در ابتدا، ویدئوهای بارانی و غیر بارانی به‌عنوان ورودی بارگذاری می‌شوند. این ویدئوها می‌توانند از منابع مختلفی مانند دوربین‌های نظارتی یا آرشیوهای آنلاین باشند. پس از بارگذاری، ویدئوها به فریم‌های جداگانه تقسیم می‌شوند. این فرآیند به ما اجازه می‌دهد تا هر فریم را به‌طور مستقل تحلیل کنیم. هر ویدئو ممکن است شامل صدها یا هزاران فریم باشد، بنابراین باید دقت و کارایی در این مرحله مدنظر قرار گیرد.

پس از تقسیم ویدئو به فریم‌ها، هر فریم به تصویر سیاه و سفید تبدیل می‌شود. این کار باعث کاهش حجم داده‌ها و تسهیل در پردازش می‌شود، زیرا جزئیات رنگی معمولاً برای تشخیص باران ضروری نیستند. در مرحله بعد، الگوریتم

جدول ۳. نتایج ارزیابی دقت الگوریتم پیشنهادی در تشخیص باران بر اساس ویدئوهای بارانی و غیر بارانی

ویدئو	TN	FN	FP	TP	دقت (%)
۱	۰	۰	۰	۳۰	۱۰۰
۲	۲۱	۰	۹	۰	۷۰
۳	۲۲	۰	۸	۰	۷۳/۳۳
۴	۱۵	۰	۱۵	۰	۵۰
۵	۳۰	۰	۰	۰	۱۰۰
۶	۰	۰	۰	۳۰	۱۰۰
۷	۰	۰	۰	۳۰	۱۰۰
۸	۸	۰	۲۲	۰	۲۶/۶۷
۹	۱۱	۰	۹	۱۰	۷۰
۱۰	۰	۳	۰	۲۷	۹۰
۱۱	۲۴	۰	۶	۰	۸۰
۱۲	۲۹	۰	۱	۰	۹۶/۶۷
۱۳	۲	۷	۳	۱۸	۶۶/۶۷
میانگین دقت (%)					۷۸/۷۲

همچنین شکل (۶) مجموعه تصاویری از کیفیت عملکرد الگوریتم برای چند ویدئوی انتخابی را نشان می‌دهد.



شکل ۶. نمونه‌هایی از فریم‌های انتخاب شده. تصاویر اول و سوم دو فریم از ویدئوهای غیر بارانی به همراه نتیجه‌ی پردازش، تصاویر دوم و چهارم دو فریم از ویدئوهای بارانی به همراه نتیجه‌ی پردازش

متحرک عمودی به کل پیکسل‌های متحرک و میانگین شدت حرکت عمودی این پیکسل‌ها. اگر هر دو ویژگی از آستانه مشخصی بالاتر باشند، الگوریتم فریم را «بارانی» تشخیص می‌دهد. برای افزایش اطمینان و جلوگیری از شناسایی اشتباه، این تحلیل برای چند فریم متوالی انجام می‌شود و تنها در صورتی که شرایط باران در حداقل تعداد مشخصی از فریم‌های پشت سر هم برقرار باشد، نتیجه نهایی به عنوان «باران شناسایی شد» اعلام می‌شود.

پس از اجرای الگوریتم بر روی ویدئوهای بارانی و غیر بارانی، نتایج به‌دست‌آمده مورد مقایسه قرار می‌گیرند. برای نمایش نتایج بصری، جریان نوری به‌صورت ویدئوی باینری ارائه می‌شود که حرکت پیکسل‌ها را به‌وضوح نمایش می‌دهد. شکل (۵) یک نمونه از تصاویر باینری شده را نمایش می‌دهد.



شکل ۵. تصویر سمت چپ تصویر اصلی، تصویر سمت راست پس از باینری شدن.

نتایج نشان می‌دهد که روش فارنبرگ توانسته است در ویدئوهای بارانی، حرکات عمودی مرتبط با قطرات باران را با دقت نسبتاً خوبی تشخیص دهد. در ویدئوی غیر بارانی، حرکات کاذب به‌درستی شناسایی و حذف می‌شوند، که این امر نشان‌دهنده کارایی و دقت بالای الگوریتم است. البته الگوریتم در ویدئوهای غیر بارانی‌ای که زمینه‌ی شلوغ و پویا دارند، ممکن است خیلی عملکرد خوبی نداشته باشد. نتایج نشان داد که الگوریتم توانسته است با میانگین دقت ۷۸/۷۲ درصد حضور یا عدم حضور باران را در ویدئوها تشخیص دهد که بیانگر عملکرد نسبتاً قابل قبول مدل است. جدول (۳) دقت‌های حاصل انجام پژوهش را برای ۱۳ ویدئوی انتخابی نشان می‌دهد.

۵. نتیجه گیری و پیشنهادها

در این پژوهش، الگوریتم جریان نوری فARNBK برای تشخیص خودکار بارش باران از ویدئوهای دیجیتال مورد استفاده قرار گرفت. این الگوریتم با تحلیل حرکتهای عمودی پیکسلها در فریمهای متوالی، توانست الگوهای حرکتی مرتبط با قطرات باران را شناسایی کند. نتایج عددی حاصل از آزمایشها (جدول ۳) نشان داد که دقت کلی الگوریتم برابر با ۷۸/۷۲ درصد بوده است که نشان دهندهی عملکرد متوسط اما قابل قبول در تفکیک شرایط بارانی از غیر بارانی است. این میزان دقت از طریق مقایسهی برجسبهای دستی و خروجی خودکار در فریمهای انتخاب شده به دست آمده و بیانگر توان نسبی مدل در تشخیص صحیح الگوهای بارش است.

تحلیل کیفی جریان نوری استخراج شده از ویدئوها نیز نشان داد که در بیشتر موارد، حرکات عمودی قطرات باران به درستی شناسایی شده اند، در حالی که در ویدئوهای غیر بارانی، حرکات کاذب ناشی از نویز یا تغییرات نوری تا حد زیادی حذف گردیده اند. با این حال، نتایج بصری و عددی هر دو حاکی از وجود برخی محدودیتها در پایداری عملکرد الگوریتم هستند. به ویژه در شرایطی که پس زمینه دارای تحرک زیاد (مانند حرکت شاخ و برگ درختان) یا روشنایی متغیر باشد، نرخ خطای الگوریتم افزایش می یابد. افزون بر این، قطرات باران دورین محور با اندازهی کوچک یا وضوح پایین، گاه توسط الگوریتم تشخیص داده نمی شوند. همچنین، حرکات سریع و غیرعمودی ناشی از اشیاء متحرک یا سایه ها می توانند به اشتباه به عنوان باران شناسایی شوند. این موارد نشان می دهد که عملکرد الگوریتم فARNBK تا حدی به سادگی صحنه و ثبات نوری محیط وابسته است.

در مقایسه با نتایج گزارش شده در پژوهشهای پیشین، عملکرد الگوریتم فARNBK به کاررفته در این مطالعه را می توان در بازه ای قابل قبول و هم راستا با چالشهای ذاتی مسئله تشخیص بارش از ویدئو ارزیابی کرد. برای نمونه، یی و همکاران نشان دادند که برآورد جریان نوری در مواجهه با اغتشاشهایی نظیر نویز، تاری حرکتی و تغییرات نوری، با

افزایش خطای انتهایی همراه است (حدود ۲۸ درصد) [۱۶]، که این موضوع بیانگر حساسیت بالای روشهای کلاسیک جریان نوری به شرایط غیرایده آل تصویربرداری است. از سوی دیگر، لی و همکاران با بهره گیری از چارچوبهای یادگیری عمیق و اطلاعات ژيروسکوپ، به دقت بالاتری (حدود ۸۶ درصد پیکسلها با خطای کمتر از ۵ پیکسل) دست یافته اند [۲۳]، اما این بهبود عملکرد به بهای افزایش پیچیدگی محاسباتی و نیاز به داده های آموزشی حاصل شده است. همچنین، مطالعه ی لی، هیون و چوی که بر تشخیص بارش از ویدئوهای نظارتی جاده ای متمرکز است، دقت میانگین حدود ۵۴/۹ درصد را برای روش مبتنی بر جریان نوری گزارش می کند [۲۴] که از نظر عددی پایین تر از دقت کلی ۷۲/۷۸ درصد به دست آمده در این پژوهش است. این مقایسه ها نشان می دهد که اگرچه الگوریتم فARNBK در مواجهه با پس زمینه های متحرک و تغییرات نوری شدید با محدودیت هایی روبه روست، اما بدون اتکا به مدل های یادگیری عمیق یا داده های کمکی، توانسته است عملکردی رقابتی و پایدار ارائه دهد. بنابراین، می توان نتیجه گرفت که این الگوریتم، با وجود سادگی ساختاری، توازن مناسبی میان دقت، سرعت پردازش و هزینه ی محاسباتی برقرار کرده و گزینه ای عملی برای کاربردهای بلادرنگ و سامانه های نظارتی با منابع محدود محسوب می شود.

در نهایت، برای ارتقای دقت و پایداری الگوریتم در آینده، پیشنهاد می شود که مدل فARNBK با روشهای یادگیری عمیق ادغام گردد تا بتواند از قدرت شبکه های عصبی در استخراج ویژگی های غیرخطی و پیچیده بهره مند شود. همچنین، توسعه و به کارگیری مجموعه داده های متنوع تر شامل شرایط نوری، محیطی و بارشی متفاوت، می تواند به بهبود تعمیم پذیری مدل کمک کند. افزون بر این، استفاده از ساختارهای پیچیده تر و شبکه های کانولوشنی ساختاریافته مشابه آنچه در مطالعات جدیدتر ارائه شده است، می تواند مسیر ارتقای مدل های جریان نوری کلاسیک به سمت سامانه های ترکیبی هوشمند و دقیق تر را هموار سازد.

- [10] Haurum JB, Bahnsen CH, Moeslund TB. Is it Raining Outside? Detection of Rainfall using General-Purpose Surveillance Cameras. InCVPR Workshops 2019 Aug 12 (pp. 55-64).
- [11] Shorman SM, Pitchay SA. A review of rain streaks detection and removal techniques for outdoor single image. ARPN J. Eng. Appl. Sci. 2016 May;11(10):6303-8.
- [12] Wang H, Xie Q, Zhao Q, Meng D. A model-driven deep neural network for single image rain removal. InProceedings of the IEEE/CVF conference on computer vision and pattern recognition 2020 (pp. 3103-3112).
- [13] Yang W, Tan RT, Wang S, Liu J. Self-learning video rain streak removal: When cyclic consistency meets temporal correspondence. InProceedings of the IEEE/CVF conference on computer vision and pattern recognition 2020 (pp. 1720-1729).
- [14] Yan W, Tan RT, Yang W, Dai D. Self-aligned video deraining with transmission-depth consistency. InProceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2021 (pp. 11966-11976).
- [15] Islam MR, Paul M. Video rain-streaks removal by combining data-driven and feature-based models. Sensors. 2021 Oct 15;21(20):6856.
- [16] Yi Z, Shi H, Jiang Q, Gao Y, Wang Z, Zhang Y, Yang K, Wang K. Benchmarking the Robustness of Optical Flow Estimation to Corruptions. arXiv preprint arXiv:2411.14865. 2024 Nov 22.
- [17] Gonzalez RC, Woods RE. Digital Image Processing, 3rd Edition. Pearson Prentice Hall, Upper Saddle River; 2008. - References - Scientific Research Publishing, www.scirp.org. <https://www.scirp.org/reference/ReferencesPapers?ReferenceID=1258015>
- [18] Stauffer C, Grimson WE. Adaptive background mixture models for real-time tracking. InProceedings. 1999 IEEE computer society conference on computer vision and pattern recognition (Cat. No PR00149) 1999 Jun 23 (Vol. 2, pp. 246-252). IEEE.
- [19] Zivkovic Z. Improved adaptive Gaussian mixture model for background subtraction. InProceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004. 2004 Aug 26 (Vol. 2, pp. 28-31). IEEE.
- [20] Deng LJ, Huang TZ, Zhao XL, Jiang TX. A directional global sparse model for single image rain removal. Applied Mathematical Modelling. 2018 Jul 1;59:662-79.
- [21] Navin MJR, Pankaja R. Performance analysis of text classification algorithms using confusion matrix. International Journal of

سپاسگزاری

نویسندگان مقاله از مجموعه دو فصلنامه هیدروفیزیک و سردبیر محترم آن، جناب آقای دکتر مرادی، به دلیل کمکهای صبورانه و سخاوتمندانه‌شان در انتشار این مقاله، از داوران محترم فصلنامه که با صرف وقت و ارائه نظرات سازنده و دقیق خود، به ارتقاء کیفیت این مقاله یاری رساندند، صمیمانه تشکر می‌کنند.

مراجع

- [1] Rahayu SA, Sipayung SB, Witono A, Suprihatin LS. The Performance of K-Nearest Neighbor (KNN) Approach for Estimating Extreme Rain Events based on CCTV Images Camera Data. Jurnal EECCIS (Electrics, Electronics, Communications, Controls, Informatics, Systems). 2023 Sep 1;17(2):59-65.
- [2] Hakim AL, Dewi R. Automatic rain detection system based on digital images of CCTV cameras using convolutional neural network method. InIOP Conference Series: Earth and Environmental Science 2021 Nov 1 (Vol. 893, No. 1, p. 012048). IOP Publishing.
- [3] Fiallos-Salguero M, Khu ST, Guan J, Wang T, Wang M. Computer Vision-Based Method for Rainfall Estimation Using CCTV Cameras and Smartphone Videos. In15th International Conference on Hydroinformatics 2024 (p. 284).
- [4] Lee J, Byun J, Baik J, Jun C, Kim HJ. Estimation of raindrop size distribution and rain rate with infrared surveillance camera in dark conditions. Atmospheric Measurement Techniques. 2023 Feb 8;16(3):707-25.
- [5] Farneback G. Two-frame motion estimation based on polynomial expansion. InScandinavian conference on Image analysis 2003 Jun 24 (pp. 363-370). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [6] Tripathi AK, Mukhopadhyay S. Removal of rain from videos: a review. Signal, Image and Video Processing. 2014 Nov;8(8):1421-30.
- [7] Garg K, Nayar SK. Vision and rain. International Journal of Computer Vision. 2007 Oct;75(1):3-27.
- [8] Barnum PC, Narasimhan S, Kanade T. Analysis of rain and snow in frequency space. International journal of computer vision. 2010 Jan;86(2):256-74.
- [9] Roser M, Geiger A. Video-based raindrop detection for improved image registration. In2009 IEEE 12th International Conference on Computer Vision Workshops, ICCV Workshops 2009 Sep 27 (pp. 570-577). IEEE.

- Engineering and Technical Research (IJETR). 2016; 869–2321.
- [22] Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks. Information processing & management. 2009 Jul 1;45(4):427-37.
- [23] Li H, Luo K, Zeng B, Liu S. Gyroflow+: Gyroscope-guided unsupervised deep homography and optical flow learning. International Journal of Computer Vision. 2024 Jun;132(6):2331-49.
- [24] Li Z, Hyeon J, Choi HJ. Rainfall recognition from road surveillance videos using TSN. Journal of Korean Society for Atmospheric Environment. 2018;34(5):735-47.

پی‌نوشت‌ها

1. K-Nearest Neighbor (KNN)
2. Convolutional Neural Network (CNN)
3. Mean Absolute Percentage Error
4. Peak Signal-to-Noise Ratio
5. Structural Similarity Index
6. Gaussian Mixture-based Background/Foreground Segmentation Algorithm, version 2 (MOG2)
7. Ground Truth
8. Confusion Matrix
9. True Positives (TP)
10. True Negatives (TN)
11. False Positives (FP)
12. False Negatives (FN)