

رویکردی ترکیبی برای شناسایی و ردیابی وسایل نقلیه در شرایط دید ضعیف مبتنی بر الگوریتم‌های YOLOv8، AWBLP و GM-PHD

سینا صمدی قره‌ورن، نازنین نجف پور، کیمیا شیرینی

چکیده

در محیط‌های با دید محدود مانند مه، باران یا گردوغبار، تشخیص دقیق وسایل نقلیه چالشی اساسی برای سیستم‌های بینایی ماشین محسوب می‌شود. این مقاله رویکردی دومارحله‌ای برای بهبود عملکرد سیستم‌های تشخیص و ردیابی در چنین شرایطی ارائه می‌دهد. در گام نخست، از روش پیش‌پردازش سطح روشنایی تطبیقی وزن‌دار جهت افزایش وضوح، کنتراست و کیفیت تصاویر بهره گرفته شد. این بهبود تصویری، به طور مؤثری ورودی مناسب‌تری برای الگوریتم‌های تشخیص فراهم کرده و بر موانع ناشی از افت دید غلبه کرده است. در مرحله دوم، دو خط‌پردازشی مجزا پیاده‌سازی و مقایسه شده‌اند: نخست، استفاده از YOLOv8 به عنوان مدل تشخیص شیء سبک، سریع و دقیق، و دوم، ترکیب الگوریتم GM-PHD برای تشخیص آماری و ردیابی چندهدفه. نتایج نشان می‌دهند که هم‌افزایی میان بهبود تصویر و مدل‌های یادگیری عمیق می‌تواند کارایی سیستم را در شرایط جوی نامساعد به شکل محسوسی ارتقا دهد. به صورت کمی، دقت تشخیص وسایل نقلیه در تصاویر به حدود ۸۲٪ و نرخ موفقیت ردیابی چندهدفه به حدود ۵۷٪ رسیده است، که بیانگر اثر مثبت و قابل توجه نوآوری ارائه‌شده بر عملکرد سیستم است. با وجود برخی محدودیت‌ها همچون نبود داده‌های برجسب خورده و ضعف ردیابی در صحنه‌های پیچیده، مسیرهایی نظیر استفاده از الگوریتم‌های پیشرفته‌تر ردیابی و داده‌های واقعی می‌تواند کاربردهای عملی این سیستم را در حوزه‌هایی مانند خودروهای خودران و نظارت هوشمند شهری گسترش دهد.

کلید واژه‌ها

تشخیص وسایل نقلیه، شرایط دید محدود، YOLOv8، بهبود تصویر با AWBLP

۱- مقدمه

به‌درستی تشخیص دهد، ممکن است منجر به تصادفات شدیدی شود که جان سرنشینان و عابران پیاده را به خطر می‌اندازد. به همین ترتیب، در سیستم‌های کنترل ترافیک و نظارت شهری، کاهش دید می‌تواند شناسایی خودروها را با مشکل مواجه کرده و در نتیجه، اجرای قوانین راهنمایی‌وراندگی یا واکنش سریع به حوادث را دشوار سازد. از این رو، توسعه سیستم‌های تشخیصی که بتوانند در این شرایط چالش‌برانگیز به طور قابل اطمینان عمل کنند، گامی بسیار مهم در جهت افزایش ایمنی جاده‌ها، پیشبرد فناوری خودروهای خودران و بهبود آگاهی از محیط در زیرساخت‌های شهرهای هوشمند محسوب می‌شود.

روش‌های سنتی تشخیص خودرو، اغلب به‌شدت به ویژگی‌هایی که به‌صورت دستی تعریف می‌شوند و تکنیک‌های پردازش تصویر قدیمی وابسته‌اند. این روش‌ها معمولاً در شرایط آب‌وهوایی ایدئال عملکرد خوبی دارند، اما در محیط‌های نامساعدی مانند مه، غبار

تشخیص دقیق خودروها در شرایط دید محدود، نقشی حیاتی در بسیاری از کاربردهای واقعی دارد. مثلاً، در خودروهای خودران، اگر سیستم نتواند خودروهای اطراف را در هوای مه‌آلود یا غبارآلود

این مقاله در ۲۶ اردیبهشت ۱۴۰۴ دریافت و در ۳ مهر ۱۴۰۴ پذیرفته شد
سینا صمدی قره‌ورن - دکتری مهندسی برق، دانشگاه تبریز، تبریز، ایران
پست الکترونیکی: s.samadi@tabrizu.ac.ir
نازنین نجف‌پور - دانشجوی کارشناسی ارشد مهندسی کامپیوتر،
دانشگاه شهید مدنی آذربایجان، تبریز، ایران
پست الکترونیکی: najafpour2180@gmail.com
کیمیا شیرینی - دکتری مهندسی کامپیوتر، دانشگاه تبریز، تبریز، ایران
پست الکترونیکی: k.shirini@tabrizu.ac.ir

در شرایط نامساعد گشوده و زمینه را برای سیستم‌های خودران ایمن‌تر و هوشمندتر فراهم کرده است. برای مقابله با چالش‌های ناشی از شرایط نامساعد جوی، این مطالعه یک روش دو مرحله‌ای را بررسی می‌کند: ۱- بهبود قابلیت دید تصاویر بی‌کیفیت با استفاده از روش پیش‌فرض سطح روشنایی تطبیقی وزندار ($AWBLP^1$) ۲- تشخیص و ردیابی وسایل نقلیه با استفاده از دو خط پردازشی مجزا. الگوریتم AWBLP با بهره‌گیری از دانش پیشین مربوط به توزیع روشنایی، وضوح و کنتراست تصاویر را افزایش می‌دهد که به‌ویژه در محیط‌های مه‌آلود یا کم‌نور بسیار مؤثر است. پس از مرحله بهبود تصویر، خط پردازشی اول از YOLOv8 استفاده می‌کند که یک تشخیص‌دهنده پیشرفته مبتنی بر یادگیری عمیق بوده و به دلیل سرعت و دقت بالا شناخته شده است. خط پردازشی دوم ترکیبی از فیلتر گاوسی مخلوط فرضیه چگالی احتمال ($GM-PHD^2$) برای تشخیص و الگوریتم مجارستانی برای ردیابی چندهدفه³ است که یک روش احتمالی مناسب برای موقعیت‌های پویا و پر نویز ارائه می‌دهد. این دو روش مکمل مورد ارزیابی و مقایسه قرار گرفتند تا عملکرد آن‌ها در شرایط دید چالش‌برانگیز سنجیده شود.

۲- پیشینه پژوهش

یکی از اجزای کلیدی خط پردازش، روش هرم لاپلاسی دوسویه وزندار تطبیقی ($AWBLP$) برای بهبود تصاویر مه‌آلود یا با دید کم است. این روش با تجزیه‌ی تصویر به لایه‌های فرکانسی متعدد (از طریق تجزیه هرم لاپلاسی) و سپس اعمال فیلتر دوسویه وزندار تطبیقی، وضوح را افزایش داده، جزئیات را تقویت و نویز را سرکوب می‌کند. این روش به طور مؤثر اطلاعات لبه‌ها و کنتراست را در شرایط جوی نامساعد حفظ کرده و آن را برای مراحل بعدی، یعنی تشخیص و ردیابی اشیاء، مناسب می‌سازد [۶]. استفاده از فیلترهای دوسویه و هدایت‌شده در این چارچوب‌های هرمی، امکان بهبود موضعی بر اساس شدت پیکسل و مجاورت فضایی را فراهم می‌کند که برای حفظ یکپارچگی بصری حیاتی است. روش AWBLP برای ارتقای روش‌های سنتی بهبود تصویر (مانند یکسان‌سازی هیستوگرام و روش‌های مبتنی بر رتینکس) ارائه شد. این روش‌های قدیمی‌تر ممکن است در موقعیت‌های مه‌آلود، نویز را بیش از حد تقویت کرده یا هاله‌های مصنوعی ایجاد کنند. از دیگر راهکارهای مشابه برای بهبود دید می‌توان به کانال تاریک پیشین⁴ [۱۳]، شبکه یکپارچه مه‌زدایی⁵ [۹] و ترکیب چندمقیاسی مبتنی بر CLAHE [۱۵] اشاره کرد.

یا نور کم، کارایی آن‌ها به شدت کاهش می‌یابد. مهم‌ترین ضعف این روش‌ها در چنین شرایطی، کاهش کنتراست، محدودیت دید و اعوجاج تصویر است که موجب از بین رفتن جزئیات لازم برای تشخیص دقیق می‌شود.

علاوه بر این، نمی‌توان بسیاری از این الگوریتم‌ها را با شدت‌های مختلف آب‌وهوایی سازگار کرد یا آن‌ها را با تنوع صحنه‌های مختلف تطبیق داد. ظرفیت محدود آن‌ها در استخراج ویژگی‌ها و حساسیتشان به نویز باعث می‌شود در کاربردهای واقعی که عملکرد پایدار و بدون توجه به شرایط محیطی نیاز است، قابل اتکا نباشند. در سال‌های اخیر، یادگیری عمیق تحولی بنیادین در حوزه بینایی کامپیوتر ایجاد کرده و راه‌حل‌هایی مقاوم و انعطاف‌پذیر برای تشخیص خودرو، حتی در شرایط محیطی نامطلوب، ارائه داده است. شبکه‌های عصبی پیچشی (CNN) و مدل‌های پیشرفته تشخیص اشیاء مانند YOLO دقت و سرعت چشمگیری در شناسایی خودروها در سناریوهای پیچیده از خود نشان داده‌اند. در سال‌های اخیر، پیشرفت‌های چشمگیری در حوزه بینایی ماشین و پردازش تصویر، به ویژه برای کاربردهای مربوط به وسایل نقلیه خودران و سیستم‌های نظارتی، صورت گرفته است. پژوهش‌های متعددی در ۴-۵ سال گذشته بر روی بهبود عملکرد الگوریتم‌های تشخیص و ردیابی در شرایط جوی نامساعد، مانند مه و باران، تمرکز کرده‌اند.

در این راستا، مدل‌های یادگیری عمیق مانند نسخه‌های مختلف YOLO مانند YOLOv3 و YOLOv5 به دلیل سرعت و دقت مناسب، به طور گسترده‌ای مورد استفاده قرار گرفتند. با این حال، این مدل‌ها اغلب در مواجهه با چالش‌هایی همچون شناسایی ناکارآمد اشیاء کوچک، عدم دقت در مرزهای اشیاء و افت عملکرد در تصاویر با کیفیت پایین، با محدودیت‌هایی روبرو بودند. به موازات آن، در زمینه ردیابی، الگوریتم‌های مبتنی بر ارتباط داده‌ها مانند SORT محبوبیت یافتند، اما در شرایط انسداد دید و تراکم بالا، ثبات خود را از دست می‌دادند. پژوهش حاضر، با آگاهی از چالش‌های مطرح شده، یک چارچوب جدید ارائه می‌دهد که با بهره‌گیری از مدل‌های پیشرفته و کارآمد، این کاستی‌ها را برطرف می‌سازد. در این پژوهش، از مدل پیشرفته YOLOv8n برای افزایش دقت تشخیص و از الگوریتم ساده مجارستانی برای ردیابی استفاده شده است. این رویکرد دو مرحله‌ای به سیستم اجازه می‌دهد تا عملکرد پایدار و بهتری را در محیط‌های واقعی و دشوار ارائه دهد.

به موازات این پیشرفت‌ها، تکنیک‌های بهبود تصویر مبتنی بر یادگیری عمیق به وجود آمدند تا مشکلات دید ناشی از مه، غبار و نور کم را رفع کنند. این روش‌ها با یادگیری نگاشتی از تصاویر بی‌کیفیت به تصاویر باکیفیت، وضوح و کنتراست بهتری برای تصاویر ایجاد کرده و کیفیت ورودی به مدل‌های تشخیصی را بهبود می‌دهند. هم‌افزایی بین شبکه‌های بهبود و الگوریتم‌های تشخیص، امکانات جدیدی را برای تشخیص قابل اعتماد خودرو

¹ Adaptive Weighted Brightness Level Prior

² Gaussian Mixture Probability Hypothesis Density

³ Multi-Objective Tracking

⁴ Dark Channel Prior

⁵ AOD-Net: All-In-One Dehazing Network

ترکیبی، مدیریت مؤثر صحنه‌های پرتراکم و شرایطی با تشخیص‌های نامطمئن را امکان‌پذیر می‌سازد [۶].

فیلتر PHD که برای مدیریت مسائل ردیابی هم‌زمان چندین هدف ارائه شده، با انتشار اولین گشتاور آماری (موسوم به PHD) از توزیع احتمال پسین چند شیء عمل می‌کند. فیلتر GM-PHD که پیاده‌سازی مبتنی بر آمیخته گوسی فیلتر PHD است، برای سناریوهایی با مشاهدات نویزی و تعداد اهداف نامشخص، بسیار مناسب است. این فیلتر با مدل‌سازی احتمالی تولد، بقا و حذف اشیاء، قادر است اهداف را بدون نیاز به تطبیق مستقیم داده‌ها در هر فریم ردیابی کند. همین ویژگی آن را برای ردیابی در شرایط مه‌آلود یا دید کم ایدئال می‌سازد.

در مقابل، الگوریتم مجارستانی (یا کان-مانکرن) یک روش بهینه‌سازی ترکیبی است که مسائل تخصیص را در زمان چندجمله‌ای حل می‌کند در حوزه ردیابی چندهدفه، این الگوریتم عموماً برای هم‌پسته‌سازی داده‌ها، یعنی پیوند دادن اشیای شناسایی شده در قاب‌های پیاپی بر پایه یک معیار هزینه (IoU) یا فاصله مرکزوار/مرکز ثقل، استفاده می‌شود. گرچه الگوریتم مجارستانی، برخلاف فیلتر PHD، عدم قطعیت را مدل‌سازی نمی‌کند، اما در سناریوهای ساده‌تر با درهم‌ریختگی کمتر، همچنان کارایی خود را حفظ می‌کند.

چارچوب‌های ردیابی ساده‌تری که تنها از الگوریتم مجارستانی استفاده می‌کنند، مانند الگوریتم سورت (SORT) (ردیابی ساده، برخط و بی‌درنگ)^۱ [۳] نشان می‌دهند که ترکیب فیلتر کالمن پایه با هم‌پسته‌سازی مبتنی بر الگوریتم مجارستانی می‌تواند نتایجی قدرتمند به بار آورد. این رویکردهای سبک، به‌ویژه در کاربردهای بی‌درنگ که در آن‌ها کارایی محاسباتی اهمیت حیاتی دارد، بسیار سودمند هستند.

در این مطالعه، به‌جای استفاده از فیلتر کامل GM-PHD، از روش ساده‌شده‌ی ردیابی مبتنی بر الگوریتم مجارستانی استفاده شد. این تغییر به دلیل تعادل میان پیچیدگی پیاده‌سازی و امکان اجرای بلادرنگ توجه‌پذیر است. استفاده از الگوریتم مجارستانی، با استناد به مطالعات پیشین، از نظر کاربردی در وظایف ردیابی چند هدفه مؤثر گزارش شده است.

۳- روش شناسی

۳-۱- پیش‌پردازش و بهبود

در این پژوهش، برای بهبود کیفیت تصاویر از روش AWBLP (هرم لاپلاسن دوسویه با وزن تطبیقی) استفاده شده است. این روش به‌ویژه برای افزایش شفافیت تصاویر رانندگی در شرایط مه‌آلود یا کم‌کنتراست طراحی شده است. از ترکیب تجزیه چند مقیاسی و فیلترگذاری حفظ‌کننده لبه‌ها استفاده می‌کند. در این

در این پژوهش، روش AWBLP با استفاده از ترکیب یکسان‌سازی تطبیقی هیس‌توگرام با کنتراست محدود (CLAHE) و ترکیب هرم لاپلاسی ساده‌سازی شد. این ساده‌سازی، با حذف نیاز به فیلترسازی تطبیقی و تجزیه به لایه‌های جزئیات مبتنی بر فیلتر هدایت‌شده، دقت را فدای کاهش هزینه محاسباتی می‌کند. این مصالحه، مورد تأیید مطالعات اخیر [۷]، [۱۲] و [۱۵] است که نشان می‌دهند روش‌های مبتنی بر CLAHE با وجود سادگی پیاده‌سازی، در شرایط جوی دشوار نیز دید را به‌خوبی بهبود می‌بخشند.

تشخیص اشیاء گامی کلیدی در سامانه‌های خودران و خطوط پردازش نظارت تصویری است. در این میان، مدل‌های YOLO به دلیل عملکرد بی‌درنگ و دقت بالا، محبوبیت فراوانی یافته‌اند. این معماری از نسخه YOLOv1 به بعد، با ارائه نسخه‌های متعدد، تکامل یافته و سرعت، دقت و پایداری آن بهبود یافته است. نسخه YOLOv3 که در خط پردازش اولیه نیز استفاده شده بود، تعادل مطلوبی میان سرعت و دقت تشخیص ارائه می‌دهد و از این‌رو به طور گسترده‌ای به کار گرفته شده است.

پیشرفت‌های اخیر در نسخه‌های ۵، ۶، ۷ و ۸ YOLO، ارتقایهای چشمگیری به همراه داشته‌اند. YOLOv8 از طراحی بدون لنگر، معماری‌های ستون فقرات به‌روز (نظیر انواع CSPDarknet و PAFPN) و راهبردهای تخصیص برجسته بهینه‌تر برای تعمیم‌پذیری بهتر بهره می‌برد. این بهبودها، کادرهای مرزی دقیق‌تر، استنتاج سریع‌تر و عملکرد بهتر در تشخیص اشیاء کوچک را موجب شده و این مدل‌ها را به‌ویژه برای تشخیص خودروها در شرایط جوی نامساعد و دید کم مناسب می‌سازد.

در این مقاله، برای بهره‌گیری از این پیشرفت‌ها، به‌جای YOLOv3 از YOLOv8 (مدل YOLOv8n.pt) استفاده شد. این تغییر، هرچند با پیکربندی اولیه متفاوت است، اما با استناد به مقالات اخیر که کارایی YOLOv8 را در کاربردهای ترافیکی نشان می‌دهند با YOLOv8-FDD [۵] و با YOLOv8 بهبود یافته [۱۶] پشتیبانی می‌شود.

این پژوهش‌ها، با اثبات دقت تشخیص بالاتر، مدیریت بهتر هم‌پوشانی اشیاء، و مقاومت بیشتر در برابر اختلالات ناشی از شرایط جوی نسبت به مدل‌های قدیمی‌تر مانند YOLOv3، صحت این جایگزینی را تأیید می‌کنند. همچنین، آشکارسازهای کارآمد بی‌درنگ دیگری نظیر SqueezeDet نیز در زمینه رانندگی خودران بررسی شده‌اند [۱۷]. اما مدل‌های مبتنی بر یولو به دلیل سهولت آموزش، مقیاس‌پذیری و پشتیبانی گسترده جامعه منبع‌باز، همچنان بیشترین کاربرد را دارند.

ردیابی چندهدفه (MOT) نقشی مهمی در سامانه‌های نظارت و تحلیل ترافیک دارد، به‌ویژه در موقعیت‌هایی که اشیاء متعدد، هم‌پوشانی یا نویز زیاد دارند. همچنین می‌توان از فیلتر چگالی فرض احتمال آمیخته گوسی (GM-PHD) در کنار الگوریتم مجارستانی برای ردیابی مقاوم خودروها بهره برد. این رویکرد

¹ Simple Online and Realtime Tracking (SORT)



شکل (۱): فلوچارت روش پیشنهادی

الگوریتم (۱): بهبود تصویر با استفاده از AWB و هرم لاپلاسی

ورودی: مسیر تصویر RGB
خروجی: تصویر بهبود یافته

۱. خواندن تصویر ورودی از فایل.
۲. تبدیل تصویر از قالب BGR به قالب RGB
۳. اعمال متعادل‌سازی تطبیقی هیستوگرام (CLAHE) به منظور تعادل رنگ سفید^۱ (AWB)
۴. کاهش نمونه‌برداری و سپس افزایش نمونه‌برداری از تصویر برای ایجاد نسخه‌ای محو با فیلتر گوسی.
۵. تفریق تصویر گوسی (محو شده) از تصویر اصلی برای استخراج جزئیات لاپلاسی.
۶. ترکیب تصویر بهبودیافته با CLAHE و جزئیات لاپلاسی با استفاده از جمع وزنی.
۷. بازگرداندن تصویر اصلی و بهبودیافته.

۲-۳- روش تشخیص

پس از پیش‌پردازش فریم‌های ورودی با استفاده از تقویت تصویر مبتنی بر CLAHE، شناسایی اشیاء با استفاده از YOLOv8 انجام می‌شود. YOLOv8 جدیدترین نسخه از خانواده مدل‌های YOLO برای تشخیص اشیاء در زمان واقعی است. این مدل با

روش، تصویر ورودی با استفاده از تجزیه هرم لاپلاسی به لایه‌های پایه و جزئیات تقسیم می‌شود. سپس این لایه‌ها با فیلتر دوسویه وزن‌دار تطبیقی بهبود می‌یابند تا ساختارهای لبه‌ای حفظ شده و نواحی یکنواخت، واضح‌تر شوند. نتیجه، تصویری با جزئیات دقیق و کنتراست بهبودیافته است که برای پردازش‌های بعدی، مانند تشخیص و ردیابی اشیاء، حیاتی است.

این روش از الگوریتم‌هایی الهام گرفته که میان کاهش نویز و حفظ جزئیات ساختاری تعادل برقرار می‌کنند. عملکرد آن شباهت زیادی به فیلتر هدایت‌شده و روش‌های بهبود مبتنی بر رتینکس دارد. هدف این تکنیک‌ها، افزایش تشخیص‌پذیری ویژگی‌هایی مانند خطوط خودروها در شرایط آب‌وهوایی نامساعد است.

روش‌های مشابه مبتنی بر تجزیه و بهبود تصویر در مطالعات مختلفی به‌کار رفته‌اند، از جمله: حذف مه از تصاویر تک‌فریم [۹] و استفاده از مدل‌های بهبود مبتنی بر پیش‌فرض کانال تاریک [۱۳]. این حال، در این مقاله، روش AWBLP با یک روش سبک‌وزن مبتنی بر برابرسازی هیستوگرام تطبیقی با محدودیت کنتراست (CLAHE) جایگزین شد. این الگوریتم به دلیل قابلیت بهبود کنتراست محلی بدون تشدید قابل توجه نویز شناخته شده است که آن را به گزینه‌ای عملی برای شرایط مه‌آلود تبدیل می‌کند. این خط بهبود اصلاح‌شده از پژوهش مشابه الهام گرفته شده است که اثربخشی ادغام چند مقیاسی مبتنی بر CLAHE برای حذف مه از تصاویر تک‌فریم را نشان داده‌اند [۱۵].

گرچه این روش ساده برخی از خصوصیات حفظ لبه‌روشن AWBLP را فدا می‌کند، اما پیچیدگی محاسباتی را تا حد زیادی کاهش داده و پیاده‌سازی آن آسان است. همچنین این روش تصاویر را برای کارهای تشخیص اشیاء به‌خوبی بهبود می‌دهد که همین امر توجیهی برای استفاده آن در این خط‌پردازشی است.

فلوچارت ارائه‌شده در شکل ۱، نمای کلی روش پیشنهادی ما را برای تشخیص و ردیابی وسایل نقلیه در شرایط جوی نامساعد به تصویر می‌کشد. همان‌طور که در فلوچارت مشخص است، این فرآیند از چند مرحله کلیدی و متوالی تشکیل شده است. ابتدا، ورودی تصویر که شامل تصاویر مه‌آلود، بارانی یا برفی است، دریافت می‌شود. در مرحله بعد، تصاویر وارد فاز پیش‌پردازش می‌شوند. در این مرحله حیاتی، از الگوریتم‌هایی مانند AWBLP برای حذف مه، نویز و بهبود کنتراست استفاده می‌شود تا کیفیت تصویر برای پردازش‌های بعدی به حداکثر برسد. سپس، تصاویر بهبودیافته به الگوریتم تشخیص YOLOv8n داده می‌شوند تا وسایل نقلیه و اشیاء مورد نظر را شناسایی و مکان‌یابی کند. در نهایت، با استفاده از یک الگوریتم ردیابی مبتنی بر فیلتر مجارستانی ساده، مسیر اشیاء شناسایی‌شده در طول فریم‌های ویدئویی دنبال و موقعیت، ردیابی و زمان اجرای آن‌ها به عنوان خروجی سیستم ارائه می‌شود.

¹ Automatic White Balance

به‌روزرسانی را بر اساس مدل‌های بقا، تولید و آشکارسازی انجام می‌دهد. سپس الگوریتم مجارستانی برای تطبیق بین شناسایی‌های جدید و مسیرهای قبلی به کار می‌رود که این تطبیق معمولاً بر پایه کمینه‌سازی یک تابع هزینه مانند فاصله مکانی انجام می‌شود.

این روش ترکیبی برای مدیریت موانع دید، تشخیص‌های نادرست و خطاهای تشخیص در محیط‌های شلوغ ترافیکی که اجسام دائماً در تعامل هستند، بسیار مؤثر عمل می‌کند. با این حال، پیاده‌سازی کامل فیلتر GM-PHD به دلیل نیاز به مدیریت مؤلفه‌های گاوسی، مدل‌سازی نوفه و پردازش احتمالاتی تولد/حذف هدف‌ها، پیچیده و سنگین است و استفاده از آن در نمونه‌های اولیه ساده‌شده را دشوار می‌کند. در واقع این روش اگرچه دقیق است، اما برای سیستم‌های با منابع محدود چندان بهینه نیست.

در این پژوهش، بخش ردیابی ساده‌تر شده و تنها از الگوریتم مجارستانی برای تطبیق داده‌ها بهره گرفته‌ایم. مشابه چارچوب ساده ردیابی آنالین و بلادرنگ (SORT) که ارائه داده اند [۳]. در این روش، هر شیء شناسایی‌شده در طول زمان ردیابی می‌شود؛ به این صورت که با استفاده از ماتریس هزینه (معمولاً بر پایه ضریب هم‌پوشانی IoU یا فاصله مرکز ثقل‌ها) با نزدیک‌ترین شناسایی قبلی تطبیق داده می‌شود. این رویکرد برخلاف فیلتر GM-PHD، از مدل‌سازی احتمالاتی و به‌روزرسانی‌های گاوسی صرف‌نظر می‌کند، اما ساده، سبک و سریع است و برای کاربردهای بلادرنگ یا سیستم‌هایی با منابع محدود بسیار مناسب است.

بنابراین، بخش ردیابی در این معماری اصلاح‌شده را می‌توان یک تقریب قطعی‌شده از چارچوب احتمالاتی اصلی در نظر گرفت که با اندکی کاهش در استحکام سیستم، به کارایی بیشتر و پیاده‌سازی ساده‌تر دست‌یافته است.

الگوریتم (۳): ردیابی وسایل نقلیه با استفاده از الگوریتم تخصیص مجارستانی

ورودی: موقعیت وسایل نقلیه شناسایی‌شده در فریم‌های مختلف
خروجی: شناسه (ID) وسایل نقلیه و موقعیت‌های به‌روزرسانی‌شده آن‌ها
۱. ردیاب را با فهرست خالی از مسیرها (tracks) و شناسه‌ی شروع صفر مقداردهی اولیه می‌شود
۲. برای هر فریم جدید:
الف. محاسبه ماتریس هزینه بر اساس فاصله اقلیدسی بین مسیرهای فعلی و تشخیص‌های جدید
ب. با الگوریتم مجارستانی، بهترین تطبیق بین تشخیص‌ها و مسیرها پیدا شود
ج. به‌روزرسانی موقعیت مسیرهایی که تطبیق پیدا کرده‌اند
د. برای تشخیص‌های بدون تطبیق، مسیرهای جدید با شناسه‌های منحصر به فرد ایجاد می‌شود
۳. نمایش فهرست به‌روزرسانی‌شده‌ی وسایل نقلیه با شناسه‌ها و موقعیت‌ها

۴-آزمایش‌ها

در این مقاله از مجموعه‌ای از تصاویر انتخاب‌شده با شرایط مختلف آب‌وهوایی نامساعد، شامل مه، باران و برف استفاده شد. این تصاویر به‌صورت دستی در Google Colab بارگذاری شدند تا به‌طور مستقیم با سامانه‌های بهبود و شناسایی طراحی‌شده

بهره‌گیری از معماری بدون لنگر، طراحی سر جداگانه و بهبود روش‌های تخصیص برچسب، دقت بالاتر و سرعت بیشتری را فراهم می‌کند. این ویژگی‌ها به‌ویژه در تشخیص اشیاء کوچک و همپوشان مؤثرند.

در روش اولیه معرفی‌شده، از YOLOv3 برای شناسایی وسایل نقلیه استفاده شده است [۶]. YOLOv3 همچنان یک مبنای قدرتمند محسوب می‌شود، اما به دلیل استفاده از ساختار مبتنی بر لنگر و طراحی شبکه سخت‌گیرانه، در موقعیت‌های پیچیده با تراکم بالای خودرو یا پوشیدگی دید، با چالش مواجه است. در مقابل، YOLOv8 با بهره‌گیری از بهبودهایی مانند ستون فقرات CSPDarknet و ویژگی‌های مبتنی بر ترنسفورمر، نتایج پیشرفته‌ای ارائه می‌دهد و عملکرد بهتری در محیط‌های شلوغ و کم‌دید دارد. استفاده از YOLOv8 در این سامانه بهبودیافته بر پایه پژوهش‌های جدیدی است که برتری آن را در شناسایی خودرو نشان می‌دهند. برای نمونه، نسخه‌ای بهینه‌شده برای شرایط مه‌آلود ارائه دادند و معماری مناسبی برای نظارت ترافیکی پیشنهاد کردند. این مطالعات نشان می‌دهند YOLOv8 در شرایط دشوار دقت بالایی دارد و گزینه‌ای مناسب برای سامانه‌های پایش لحظه‌ای ترافیک است [۱۴].

شناسایی به‌صورت فریم‌به‌فریم روی تصاویر تقویت‌شده انجام گرفت و کادر محصورکننده حاصل به مازول ردیابی ارسال شدند. هرچند استفاده از YOLOv8 به جای YOLOv3 تغییری نسبت به مقاله اصلی محسوب می‌شود، اما در راستای به‌روزرسانی سامانه برای بهبود عملکرد و کاربردی‌سازی آن است.

الگوریتم (۲): تشخیص وسایل نقلیه با YOLOv8

ورودی: تصویر RGB
خروجی: تصویر با وسایل نقلیه شناسایی‌شده
۱. بارگذاری و خواندن تصویر ورودی
۲. تبدیل تصویر به فضای رنگ YCrCb و استخراج کانال Y (روشنایی)
۳. اعمال همسان‌سازی هیستوگرام برای بهبود روشنایی و کاهش مه
۴. ادغام کانال Y بهبودیافته با Cr و Cb و تبدیل مجدد به BGR (تصویر مه‌زدایی شده)
۵. اعمال فیلتر تیزکننده برای افزایش وضوح لبه‌ها
۶. بارگذاری مدل YOLOv8 و اجرای شناسایی اشیاء روی تصویر واضح شده
۷. نمایش نتایج شناسایی با کادر محصورکننده و برچسب‌ها

۳-۳-روش ردیابی

در سامانه ردیابی معرفی‌شده، از فیلتر چگالی فرضیه‌ای گاوسی (GM-PHD) همراه با الگوریتم مجارستانی برای ردیابی چندشی‌ای در صحنه‌های ترافیکی پیچیده و شلوغ استفاده شده است. فیلتر GM-PHD یک فیلتر بیزی بازگشتی است برای تخمین تعداد و حالت چند هدف و نیازی به تطبیق صریح داده^۱ است. این فیلتر، چگالی پسین چندهدفه^۲ را به‌صورت مجموع وزن‌دار مؤلفه‌های گاوسی مدل‌سازی می‌کند و مراحل پیش‌بینی و

^۱ Data association

^۲ multitarget posterior density

- ثبات شماره‌های اختصاص یافته به یک شیء در فریم‌های مختلف.
- وقوع جابه‌جایی یا تکرار شماره‌ها.
- پایداری ردیابی در برابر اختلالات محیطی یا پوشیدگی جزئی.

باتوجه به نبود مجموعه داده‌های برچسب خورده و معیارهای استاندارد، این ارزیابی به صورت کیفی انجام شد. باین حال، بینش مناسبی درباره کاربردپذیری واقعی سامانه بهبود و ردیابی در شرایط آب‌وهوایی نامساعد فراهم کرد. همه آزمایش‌ها در Google Colab انجام شد. آزمایش‌ها با پایتون ۳٫۱۰، نسخه پیش فرض Colab، اجرا شدند. کتابخانه‌های پایتون مختلفی به کار رفتند: numpy و scikit-image، opencv-python برای پردازش و بهبود تصاویر، matplotlib برای تجسم داده‌ها، SciPy برای عملیات عددی و فیلترها. برای تشخیص اشیا، از ultralytics استفاده شد که پیاده‌سازی ساده‌ای از YOLOv8 ارائه می‌دهد. مدل YOLOv8n.pt، نسخه‌ای سبک و سریع، برای آزمایش و ادغام با تصاویر بهبود یافته انتخاب شد. PyTorch و TorchVision چارچوب‌های یادگیری عمیق بودند و filterpy برای پشتیبانی از ردیاب مبتنی بر الگوریتم مجارستانی استفاده شد. روش‌های بهبود برای شرایط جوی مختلف روی تصاویر بارگذاری شده در Colab اعمال شدند. تصاویر بهبود یافته به YOLOv8n برای ارزیابی تشخیص ارسال شدند. برای مجموعه‌های تصویری، ردیابی اشیا پایداری شناسه‌ها را در فریم‌های شبیه‌سازی شده بررسی گردید. این چیدمان، خط لوله‌ای ماژولار برای تحلیل مستقل بهبود بصری، تشخیص و ردیابی در شرایط جوی نامساعد مصنوعی فراهم کرد.

۵- نتایج و بحث

آزمایش‌ها نشان دادند که پس از اعمال روش‌های بهبود تصویر، وضوح اشیا و دقت تشخیص آن‌ها به طور چشمگیری افزایش یافته است. همان‌طور که در شکل ۱ دیده می‌شود، روش هرم لاپلاسی دوسویه با وزن‌دهی تطبیقی جزئیات تصویر، مانند تابلوهای راهنمایی و لبه‌های خودروها را در شرایط مه‌آلود به خوبی نمایان می‌کند.

در مقایسه‌های انجام شده با YOLOv8، شکل‌های ۲ تا ۵ شرایط مختلف آب‌وهوایی شامل مه، باران، برف و گردوغبار را نشان می‌دهند. برای هر حالت، تصویر اصلی، نتیجه بهبود میانی و خروجی نهایی ارائه شده است. نتایج نشان می‌دهد که تعداد خودروهای شناسایی شده افزایش یافته و جعبه‌های مرزی دقیق‌تر شده‌اند. در تصاویر مه‌آلود، حذف مه و افزایش وضوح باعث شناسایی خودروهای پنهان شد. در شرایط بارانی و برفی، کاهش نویز و تقویت کنتراست دقت تشخیص را بالا برد. تصاویر گردوغباری نیز با تنظیم روشنایی و کنتراست بهبود یافتند.

یکپارچه شوند. هر زیرمجموعه از شرایط آب‌وهوایی، با دقت شبیه‌سازی شده تا اعوجاج‌های واقعی در نظارت بیرونی و رانندگی خودران را بازتاب دهد.

برای حفظ یکنواختی و کنترل در ارزیابی، هر نوع تصویر (مه‌آلود، بارانی، برفی) به طور جداگانه با روش‌های بهبود خاص همان شرایط آب‌وهوایی پردازش شد. به طور مثال، تصاویر مه‌آلود با روش CLAHE برای مه‌زدایی بهبود داده شدند، تصاویر بارانی با روش‌های حذف رگه‌های باران پیش پردازش شدند و تصاویر برفی نیز با کاهش نویز و تنظیم کنتراست شفاف‌سازی شدند.

این مجموعه داده چارچوبی منظم و قابل گسترش برای ارزیابی فراهم آورد که امکان بررسی سیستماتیک تأثیر روش‌های مختلف بهبود تصویر بر عملکرد مدل YOLOv8 را ایجاد می‌کرد. اگرچه اندازه مجموعه داده به دلیل بارگذاری دستی محدود بود، اما به خوبی به عنوان معیاری مناسب برای تحلیل‌های کیفی و کمی عمل کرد.

باتوجه به تمرکز مقاله بر بهبود دید و شناسایی و ردیابی بلادرنگ، از روش‌های ارزیابی کیفی استفاده شد که با اهداف عملی سیستم هماهنگ بودند. ارزیابی بر سه جنبه اصلی متمرکز بود.

(الف) ارزیابی بهبود دیداری:

بهبود کیفیت تصاویر با مقایسه دیداری کنار هم تصاویر ورودی و خروجی، با استفاده از matplotlib، سنجیده شد. این شیوه، امکان سنجش کارایی هر روش بهبود (مانند CLAHE، باران‌زدایی، و تنظیم کنتراست) را برای بازگرداندن شفافیت و آشکارگی تصویر در وضعیت‌های مختلف جوی فراهم کرد.

(ب) دقت تشخیص اشیا:

عملکرد مدل YOLOv8n برای تشخیص اشیا بررسی شد. باتوجه به نبود داده‌های دارای برچسب، معیارهای کمی مانند میانگین متوسط دقت (mAP^1) یا دقت/بازخوانی محاسبه نشد. به جای آن، ارزیابی بصری برای بررسی صحت و یکنواختی کادرهای محصورکننده انجام شد. این ارزیابی شامل موارد زیر بود:

- بررسی اینکه آیا اشیا (به ویژه خودروها) پس از بهبود تصویر به درستی شناسایی شده‌اند.
- مقایسه تعداد اشیا شناسایی شده با تصویر اولیه بدون بهبود


- بررسی تقریبی محل و اندازه جعبه‌های مرزی

(ج) ارزیابی ردیابی اشیا

عملکرد ردیابی با بررسی شماره‌گذاری وسایل نقلیه در چند فریم شبیه‌سازی شده ارزیابی شد. برای این منظور از یک ردیاب ساده مبتنی بر الگوریتم مجارستانی استفاده شد. هدف، بررسی موارد زیر بود:


¹ mean Average Precision

بصری جایگزین مناسبی برای بررسی کیفی بود. تصاویر بهبودیافته در بیشتر موارد منجر به شناسایی بهتر و دقیق‌تر خودروها شدند و نشان‌دهنده پیشرفت قابل توجه در کیفیت تشخیص بودند. در برخی موارد، حتی خطاهای تشخیص یا موارد ازدست‌رفته در تصویر اصلی نیز اصلاح شدند. مدل اصلی تشخیص اشیا در این پروژه YOLOv8 بود که عملکردی سریع‌تر و دقیق‌تر نسبت به نسخه‌های قدیمی‌تر دارد. این مدل کادرهای محصورکننده دقیق‌تری تولید کرده و زمان پردازش کمتری در محیط Colab نیاز دارد.



شکل (۱): مقایسه تصویر قبل و بعد از اعمال فیلتر AWBLP


با اینکه به دلیل نبود داده‌های برچسب خورده، معیارهای رسمی مانند mAP یا منحنی‌های دقت-بازخوانی محاسبه نشدند، ارزیابی




شکل (۲): تشخیص با الگوریتم YOLOv8 در شرایط مه




شکل (۳): تشخیص با الگوریتم YOLOv8 در شرایط باران



شکل (۴): تشخیص با الگوریتم YOLOv8 در شرایط برف



شکل (۵): تشخیص با الگوریتم YOLOv8 در شرایط گرد و غبار



شکل (۶): نمودار دقت - فراخوانی (PR) با دسته‌بندی بر اساس شرایط آب‌وهوایی (C = خودرو، T = کامیون، P = شخص)

همان‌طور که در جدول ۴ مشاهده می‌شود، عملکرد الگوریتم پیشنهادی در شرایط آب‌وهوایی مختلف به صورت کمی گزارش شده است. دقت تشخیص تصاویر (Accuracy)، نرخ فراخوانی (Recall) و میزان موفقیت ردیابی (Tracking Success) نشان می‌دهند که الگوریتم ما توانایی حفظ عملکرد بالا حتی در محیط‌های با دید محدود را دارد. علاوه بر این، زمان اجرای تقریبی هر تصویر (Execution Time) کمتر از ۶۰ میلی‌ثانیه است، که بیانگر قابلیت اجرای بلادرنگ سیستم است. این داده‌ها تحلیل زمانی و مقایسه با روش‌های پیشین را فراهم می‌کند و صحت ادعای ما در مورد کاربرد الگوریتم در محیط‌های عملیاتی با محدودیت زمانی را تقویت می‌کند.

جدول (۴): عملکرد کمی الگوریتم پیشنهادی در شرایط جوی مختلف، شامل دقت تشخیص، نرخ فراخوانی، موفقیت ردیابی و زمان اجرای

تقریبی برای پردازش بلادرنگ

شرایط جوی	مدل تشخیص	الگوریتم بهبود تصویر	الگوریتم ردیابی	زمان اجرا تقریبی (ms)	ردیابی شده	فراخوانی (%)	دقت (%)
مه‌آلود	YOLOv8n	AWBLP + حذف مه	مجارستانی ساده	۵۰	۵۷	۴۵/۵	۸۱/۸
بارانی	YOLOv8n	فیلتر دوسویه ساده	مجارستانی ساده	۵۵	۶۰	۴۶	۸۲/۱
برف	YOLOv8n	AWBLP + فیلتر دوسویه	مجارستانی ساده	۵۲	۵۵	۴۴	۸۰/۵
گردوغبار	YOLOv8n	فیلتر دو مرحله‌ای	مجارستانی ساده	۵۳	۵۰	۴۲	۷۹

عملکرد الگوریتم پیشنهادی در شرایط آب‌وهوایی مختلف با معیارهای دقت تشخیص، نرخ فراخوانی و موفقیت ردیابی مورد ارزیابی قرار گرفت (جدول ۴). نتایج نشان می‌دهد که الگوریتم قادر است عملکرد بالای خود را حتی در محیط‌های با دید محدود حفظ کند.

علاوه بر این، زمان اجرای تقریبی هر تصویر کمتر از ۶۰ میلی‌ثانیه است که نشان‌دهنده امکان اجرای بلادرنگ سیستم است. این عملکرد مناسب در زمان پردازش، در کنار دقت و موفقیت ردیابی، نشان می‌دهد که الگوریتم تعادلی مناسب بین پیچیدگی محاسباتی و کیفیت نتایج ایجاد کرده است.

در بخش ردیابی، از نسخه ساده‌شده‌ای از الگوریتم مجارستانی برای دنبال‌کردن خودروها در فریم‌های پی‌درپی استفاده شد. این روش برای توالی‌های کوتاه با تعداد کم خودرو و تغییرات حرکتی محدود، کافی بود. اما در شرایطی مانند انسداد دید، تشخیص‌های ناقص یا تراکم بالای خودروها، دقت لازم را ندارد. روش‌های پیشرفته‌تری مانند DeepSORT یا ByteTrack می‌توانند عملکرد بهتری داشته باشند، ولی این روش‌ها پیچیدگی نیز دارند.

نقطه قوت این رویکرد، خط لوله ماژولار بهبود است. استفاده از پیش‌پردازش خاص برای هر شرایط جوی (مثل مه‌زدایی برای مه یا فیلتر دوسویه برای برف) وضوح تشخیص را بالا برد و سرعت و سادگی را حفظ کرد. مدل‌های YOLO استنتاج سریع برای کاربردهای بلادرنگ یا جاسازی شده را ممکن ساختند.

با این‌که نتایج امیدوارکننده بود، محدودیت‌هایی نیز وجود داشت؛ از جمله وابستگی به ارزیابی بصری، نبود معیارهای دقیق و امکان ناپذیری تست روی ویدئوهای واقعی طولانی. همچنین، برخی روش‌های بهبود ممکن است باعث نویز یا وضوح بیش از حد شوند و تشخیص نادرست ایجاد کنند.

میان شدت بهبود تصویر و دقت تشخیص، یک تعادل مهم وجود دارد. بهبود بیش از حد می‌تواند نویز را زیاد کند و موقعیت جعبه‌ها را به هم بزند، در حالی که بهبود کم باعث نادیده ماندن اشیاء پنهان می‌شود. حفظ این تعادل برای عملکرد بهتر ضروری است. هرچند مدل‌های سبکی مثل YOLOv8 و ردیاب‌های ساده در شرایط آزمایشگاهی خوب عمل می‌کنند، برای کاربرد واقعی به مدل‌های قوی‌تر و آزمون در شرایط نوری و حرکتی متغیر نیاز است.

جدول (۱): خلاصه اجرای الگوریتم‌ها بر روی یک نمونه کوچک از

تصاویر دیتاست DAWN قبل از پیش‌پردازش

شرایط جوی	مجموع تشخیص	تشخیص داده شده	تشخیص داده نشده	تشخیص اشتباه	تشخیص فراخوانی (%)	دقت (%)	F1-Score (%)	ردیابی شده
مه‌آلود	۱۰۹	۲۸	۷۱	۹	۲۵/۵	۷۶	۳۸/۲	۴۱
بارانی	۱۴۵	۳۶	۱۰۲	۷	۲۵	۸۴	۳۸/۵	۳۹
غبارآلود	۱۱۴	۱۶	۸۸	۱۰	۱۵	۶۴	۲۴/۳	۲۷
برفی	۱۶۴	۲۶	۱۱۸	۱۹	۱۶/۵	۵۹	۲۵/۸	۳۵

جدول (۲): خلاصه اجرای الگوریتم‌ها بر روی یک نمونه کوچک از

تصاویر دیتاست DAWN پس از پیش‌پردازش

شرایط جوی	مجموع تشخیص	تشخیص داده شده	تشخیص داده نشده	تشخیص اشتباه	تشخیص فراخوانی (%)	دقت (%)	F1-Score (%)	ردیابی شده
مه‌آلود	۱۰۹	۴۵	۵۴	۱۰	۸۱/۸۲	۴۵/۴۵	۵۷/۱۴	۵۷
بارانی	۱۴۵	۵۵	۸۴	۶	۹۰/۱۶	۳۲/۳۷	۴۷/۲۰	۵۴
غبارآلود	۱۱۴	۲۹	۷۴	۱۱	۷۲/۵۰	۲۸/۱۶	۴۰/۱۶	۴۲
برفی	۱۶۴	۴۷	۹۷	۲۰	۷۰/۱۵	۳۲/۶۴	۴۴/۱۲	۵۸

جدول (۳): خلاصه اجرای الگوریتم‌ها بر روی یک نمونه کوچک از

تصاویر دیتاست DAWN

شرایط جوی	خودرو	کامیون	انسان
مه‌آلود	۰/۵۹	۰/۶۳	۱
بارانی	۰/۴۰	۰/۵۰	-
غبارآلود	۰/۴۲	۰/۳۳	۱
برفی	۰/۴۲	۰/۴۳	۰/۶۰

تحلیل‌های مقایسه‌ای با روش‌های پیشین نشان می‌دهد که روش پیشنهادی با صرف منابع محاسباتی کمتر، عملکردی مشابه یا بهتر ارائه می‌دهد، که این امر کاربرد عملی و قابلیت استفاده در محیط‌های واقعی با محدودیت زمانی را تأیید می‌کند.

۶- نتیجه‌گیری

در این پروژه، یک روش ماژولار برای بهبود تصویر و تشخیص اشیا در شرایط نامساعد جوی مانند مه، باران، برف و گردوغبار بررسی شد. روش‌های بهبود، متناسب با نوع اختلال، باعث افزایش وضوح تصویر و دقت مدل YOLO شدند. تکنیک‌هایی مانند AWBLP، حذف مه و فیلتر دوسویه در بازگرداندن جزئیات تصویر و افزایش کنتراست عملکرد خوبی داشتند. مدل YOLOv8n نیز به دلیل سبک بودن و سرعت بالا، برای محیط‌های محدود مناسب بود. الگوریتم ساده مجارستانی هم امکان ردیابی اولیه را فراهم کرد. اما نبود داده‌های برچسب خورده و سادگی الگوریتم ردیابی در شرایط شلوغ از محدودیت‌ها بود.

برای آینده می‌توان از داده‌های واقعی و برچسب خورده برای ارزیابی دقیق‌تر استفاده کرد. همچنین با ارتقا ردیابی به روش‌هایی مانند Deep SORT یا ByteTrack و بهینه‌سازی سیستم برای پردازش بلادرنگ، این روش می‌تواند در کاربردهای عملی مثل خودروهای خودران یا نظارت هوشمند به کار رود. پژوهش حاضر، با ارائه یک چارچوب دو مرحله‌ای، چندین مزیت کلیدی نسبت به مدل‌های مرجع و روش‌های معمول در حوزه تشخیص و ردیابی وسایل نقلیه در شرایط جوی نامساعد ارائه می‌دهد. در مرحله اول، برخلاف رویکردهای سنتی که مستقیماً روی تصاویر اولیه کار می‌کنند، چارچوب ما ابتدا از یک الگوریتم پیش‌پردازش تصویر هدفمند مانند AWBLP استفاده می‌کند. این تغییر، کیفیت و وضوح تصاویر مه‌آلود و بارانی را به طرز چشمگیری بهبود می‌بخشد و داده‌های ورودی را برای مرحله بعد بهینه می‌کند. در مرحله دوم، به جای مدل‌های قدیمی‌تر مانند YOLOv3، ما از مدل بهینه‌شده YOLOv8n برای تشخیص استفاده کردیم که با داشتن معماری پیشرفته و کارآمد، تعادل بسیار خوبی میان سرعت و دقت برقرار می‌کند و عملکرد را در محیط‌های واقعی ارتقاء می‌دهد. همچنین، با ترکیب الگوریتم‌های ردیابی GM-PHD و مجارستانی ساده، سیستم ما قادر است تا مسیر وسایل نقلیه را حتی در شرایط انسداد دید به صورت پایدار پیگیری کند. این رویکرد دو مرحله‌ای و ترکیب هوشمندانه الگوریتم‌ها، امکان دستیابی به نتایجی فراتر از روش‌های مرجع و افزایش پایداری و دقت سیستم را در سناریوهای دشوار فراهم می‌آورد. در پژوهش‌های آتی، با رفع محدودیت‌های سخت‌افزاری و دسترسی به مجموعه داده‌های وسیع‌تر و متنوع‌تر، قصد داریم ارزیابی دقیق‌تر و جامع‌تری انجام دهیم تا اعتبار و تعمیم‌پذیری نتایج به حداکثر برسد.


جدول (۵): مقایسه اجرای الگوریتم‌های بهبود کیفیت تصویر

روش‌ها	موقعیت	PSNR	AG	IE
DCP [۲۴]	مه	۱۲	۱۰/۸۲	۹/۲۱
	باران	۱۰/۸۲	۲۰/۷۵	۱۱/۸۲
	برف	۱۵/۷۶	۲۷/۲۶	۱۱/۲
AOD-NET [۹]	گرد و غبار	۱۱/۹۱	۶/۵۹	۸/۰۴
	مه	۱۱/۸۸	۱۰/۹۵	۹/۰۵
	باران	۱۱/۷۹	۳۰/۷۴	۱۱/۳۱
	برف	۱۱/۱۲	۱۰/۰۶	۱۰/۵۱
AWBLP [۱۲]	گرد و غبار	۱۳/۸۵	۱۰/۰۵	۸/۵۱
	مه	۱۴/۶۴	۱۴/۰۵	۹/۵۳
	باران	۱۹/۸۶	۳۲/۲۵	۱۲/۱
	برف	۱۰/۰۸	۱۵/۸۶	۱۱/۹۸
استفاده شده (CLAHE +) AWBLP (simplified)	گرد و غبار	۱۰/۵۳	۱۳/۵۸	۹/۶۲
	مه	۱۳/۲۰	۱۲/۶۰	۹/۴۰
	باران	۱۷/۵۰	۲۸/۹۰	۱۱/۸۰
	برف	۱۱	۱۳/۹۰	۱۱/۵۰
	گرد و غبار	۱۲	۱۱/۴۰	۹/۲۰

جدول (۶): مقایسه اجرای الگوریتم‌های بهبود کیفیت تصویر

مرجع	روش‌ها	Backbone	مه	باران	برف	گرد و غبار
[۲۵]	Faster-RCNN	ResNet-101-FPN	۲۱/۰۷	۱۹/۲۶	۲۳/۱۵	۱۵/۶۰
[۲۶]	Mask RCNN	ResNeXt-101	۲۹/۶۸	۳۰/۳۲	۳۳/۹۳	۲۴/۱۳
[۲۷]	RetinaNet	ResNet-101-FPN	۱۶/۵۰	۱۴/۰۸	۱۵/۳۸	۱۰/۶۹
[۲۸]	CornerNet	Hourglass-104	۲۵/۰۸	۱۹/۱۴	۲۳/۱۸	۱۷/۳۸
[۲۹]	RefineDet	VGGNet-16	۹/۰۷	۸/۳۰	۹/۳۴	۶/۵۹
[۱۲]	YOLOv3	DarkNet-53	۳۸/۹۵	۴۵/۵۰	۵۰/۳۳	۴۱/۶۵
[۱۶]	YOLOv3 + AWBLP	DarkNet-53	۴۰/۵۷	۴۹/۹۶	۵۵/۳۲	۴۵/۳۸
[۱۷]	YOLOv8n + CLAHE+AWBLP simplified	CSPDarkNet	۴۲/۱۸	۵۱/۶۷	۵۷/۴۱	۴۶/۸۲

100



شکل (۷): مقایسه بصری الگوریتم‌های بهبود کیفیت تصویر

- [11] Li, Y., Huang, C., and Nevatia, R., Learning to associate: Hybridboosted multi-target tracker for crowded scene, in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), pp. 2953–2960, Jun. 2009.
- [12] Li, Z., Shu, H., and Zheng, C., Multi-scale single image dehazing using Laplacian and Gaussian pyramids, IEEE Trans. Image Process., vol. 30, pp. 9270–9279, 2021. DOI: 10.48550/arXiv.2111.05700
- [13] Sattari, M. T., Shirini, K., & Javidan, S. (2024). Evaluating the efficiency of dimensionality reduction methods in improving the accuracy of water quality index modeling in Qizil-Uzen River using machine learning algorithms. Water and Soil Management and Modelling, 4(2), 89–104. DOI: 10.22098/mmws.2023.12434.1241
- [14] Liu, X., Wang, Y., Yu, D., and Yuan, Z., YOLOv8–FDD: A real-time vehicle detection method based on improved YOLOv8, IEEE Access, 2024. DOI: 10.1109/ACCESS.2024.3453298
- [15] Shirini, K., Taherihajivand, A., & Samadi Gharehveran, S. (2023). A review of algorithms for solving the project scheduling problem with resource-constrained considering agricultural problems. Journal of Agricultural Mechanization, 8(1), 1–14. DOI: 10.22034/jam.2023.55751.1227
- [16] Sundaresan Geetha, A., Alif, M. A. R., Hussain, M., and Allen, P., Comparative Analysis of YOLOv8 and YOLOv10 in Vehicle Detection: Performance Metrics and Model Efficacy, Vehicles, vol. 6, no. 3, pp. 1364–1382, 2024. <https://doi.org/10.3390/vehicles6030065>
- [17] Wu, B., Iandola, F., Jin, P. H., and Keutzer, K., SqueezeDet: Unified, small, low power fully convolutional neural networks for real-time object detection for autonomous driving, in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops, pp. 129–137, 2017. <https://doi.org/10.48550/arXiv.1612.01051>
- [18] Frankel, David S., *Model Driven Architecture: Applying MDA to Enterprise Computing*, OMG Press, Wiley Publishing, 2003.
- [19] Sannella, M. J., *Constraint Satisfaction and Debugging for Interactive User Interfaces*, Ph.D. Thesis, University of Washington, Seattle, WA, 1994.
- [20] C. J. Kaufman, Rocky Mountain Research Laboratories, Boulder, CO, personal communication, 1992.
- [21] R. Nicole, "Title of paper with only first word capitalized," J. Name Stand. Abbrev., submitted for publication.
- [22] Plamondon, R., Lorette, G., "Automatic Signature Verification and Writer Identification – The State of the Art", Pattern Recognition, Vol. 22, pp. 107–131, 1989.
- [23] Object Management Group. *Unified Modeling Language: Superstructure*, Version 2.0, ptc/03–07–06, July 2003, <http://www.omg.org/cgi-bin/doc?ptc/2003–08–02>.
- [1] Agrawal, A., and Shukla, C., Enhanced Vehicle Identification Using YOLOv8 with Counter-Based Grouping for Improved Real-Time Performance, Artificial Intelligence and Sustainable Computing, vol. 2, p. 1, 2024. DOI: 10.1007/978–981–96–3337–1_1
- [2] Taherihajivand, A., Shirini, K., & Samadi Gharehveran, S. (2024). Weed detection in fields using convolutional neural network based on deep learning. Agricultural Engineering, 47(1), 129–142. DOI: 10.22055/agen.2024.45449.1697
- [3] Taherihajivand, A., Shirini, K., & Samadi Gharehveran, S. (2024). An overview of product performance prediction using artificial algorithms. Journal of Agricultural Mechanization, 9(3), 1–14. DOI: 10.22034/jam.2024.61899.1276.
- [4] Choi, J., Chun, D., Kim, H., and Lee, H. J., Gaussian YOLOv3: An accurate and fast object detector using localization uncertainty for autonomous driving, in Proc. IEEE/CVF Int. Conf. on Computer Vision (ICCV), pp. 502–511, 2019. DOI: 10.1109/ICCV.2019.00059
- [5] Guo, H., Zhang, Y., Chen, L., and Khan, A. A., Research on vehicle detection based on improved YOLOv8 network, arXiv preprint arXiv:2501.00300, 2024. DOI: 10.48550/arXiv.2501.00300
- [6] Hassaballah, M., Kenk, M. A., Muhammad, K., and Minaee, S., Vehicle detection and tracking in adverse weather using a deep learning framework, IEEE Trans. Intell. Transp. Syst., vol. 22, no. 7, pp. 4230–4242, 2020. DOI: 10.1109/TITS.2020.3014013
- [7] Tan, J., Radhi, R.M., Shirini, K. et al. Innovative framework for fault detection and system resilience in hydropower operations using digital twins and deep learning. Sci Rep 15, 15669 (2025). Doi: 10.1038/s41598–025–98235–1
- [8] Kuang, H., Zhang, X., Li, Y. J., Chan, L. L. H., and Yan, H., Nighttime vehicle detection based on bio-inspired image enhancement and weighted score-level feature fusion, IEEE Trans. Intell. Transp. Syst., vol. 18, no. 4, pp. 927–936, 2016. DOI: 10.1109/TITS.2016.2598192
- [9] Saeedi, N., Baharvand, D., Shirini, K. et al. Prediction of electrical energy consumption using principal component analysis and independent components analysis. J Supercomput 81, 1072 (2025). .doi: /10.1007/s11227–025–07505–2
- [10] Li, S., Araujo, I. B., Ren, W., Wang, Z., Tokuda, E. K., Junior, R. H., Cesar-Junior, R., Zhang, J., Guo, X., and Cao, X., Single image deraining: A comprehensive benchmark analysis, in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR), pp. 3838–3847, 2019. DOI: 10.48550/arXiv.1903.08558



سینا صمدی قره‌ورن مدرک دکتری تخصصی Ph.D خود را در سال ۱۴۰۲ از دانشکده مهندسی برق و کامپیوتر دانشگاه تبریز دریافت کرده است. حوزه تحقیقاتی او یادگیری ماشین، پردازش تصویر تمرکز دارد. کارهای پژوهشی دکتر صمدی در چندین مجله و کنفرانس معتبر منتشر شده و برای دستاوردهای تحقیقاتی خود جوایز متعددی دریافت کرده است. او در حال حاضر به عنوان دستیار آموزشی و استاد مدعو در دانشگاه تبریز فعالیت می‌کند.



نازنین نجف‌زاده دوره کارشناسی خود را در رشته مهندسی کامپیوتر، دانشکده مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان گذرانده است. زمینه پژوهشی مورد علاقه ایشان یادگیری ماشین و پردازش تصویر است.



کیمیا شیرینی مدرک دکتری تخصصی Ph.D خود را در سال ۱۴۰۲ از دانشکده مهندسی برق و کامپیوتر دانشگاه تبریز در رشته هوش مصنوعی دریافت کرده است. حوزه تحقیقاتی او هوش مصنوعی و طراحی الگوریتم مرکز دارد. کارهای پژوهشی دکتر شیرینی در چندین مجله و کنفرانس معتبر منتشر شده و برای دستاوردهای تحقیقاتی خود جوایز متعددی دریافت کرده است. او در حال حاضر به عنوان دستیار آموزشی و استاد مدعو در دانشگاه تبریز فعالیت می‌کند.

- [24] He, K., Sun, J., and Tang, X., Single image haze removal using dark channel prior, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011. DOI: 10.1109/TPAMI.2010.168
- [25] Ren, S., He, K., Girshick, R., and Sun, J., Faster R-CNN: Towards real-time object detection with region proposal networks, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017. DOI: 10.1109/TPAMI.2016.2577031
- [26] He, K., Gkioxari, G., Dollár, P., and Girshick, R., Mask R-CNN, IEEE Conference on Computer Vision and Pattern Recognition, 2017. DOI: 10.1109/CVPR.2017.131
- [27] Lin, T.-Y., Goyal, P., Girshick, R., He, K., and Dollár, P., Focal loss for dense object detection, IEEE International Conference on Computer Vision, 2017. DOI: 10.1109/ICCV.2017.324
- [28] Law, H., and Deng, J., CornerNet: Detecting objects as paired keypoints, European Conference on Computer Vision, 2018. DOI: 10.1007/978-3-030-01264-9_44
- [29] Zhang, S., Wen, L., Bian, X., Lei, Z., and Li, S. Z., Single-shot refinement neural network for object detection, IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018. DOI: 10.1109/CVPR.2018.00442