



Performance Evaluation of the YOLOv8 Model in Traffic Sign Detection for Intelligent Transportation Systems

Sana Nazarinezhad^{1*} | Elham Farahani²

1. Corresponding Author, M.Sc. in Information Technology Engineering, Department of Information Technology, Faculty of Industrial Engineering, K.N.Toosi University of Technology, Tehran, Iran. Email: sana.nazari@email.kntu.ac.ir
2. Assistant Professor, Faculty of Computer Engineering, Iranian eUniversity, Tehran, Iran. Email: elham.farahani@iranian.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:
Received 18 March 2025
Revised 18 April 2025
Accepted 15 May 2025
Published Online 01 June 2025

Keywords:
Artificial Intelligence,
Computer Vision,
Deep Learning,
Smart Cities,
Traffic Management.

ABSTRACT

The increasing urbanization and vehicle growth strain traditional transportation systems, necessitating data-driven intelligent solutions. This article explores the application of artificial intelligence, specifically computer vision, in urban traffic management. We employed YOLOv8, the latest YOLO model, for traffic sign detection. Its improved architecture offers enhanced speed and accuracy for real-time object detection. Trained and evaluated on the Self-Driving Cars dataset, YOLOv8 demonstrated acceptable performance in traffic sign detection, suggesting its potential for intelligent urban traffic monitoring and improved road safety. However, the study identifies challenges in detecting certain traffic sign classes and proposes future directions, including multimodal models, increased training data diversity, and lightweight hardware implementation.

Cite this article: Nazarinezhad, S. & Farahani, E. (2025). Performance Evaluation of the YOLOv8 Model in Traffic Sign Detection for Intelligent Transportation Systems. *Urban Development Policy Making*, 2 (3), 277-296. DOI: <http://doi.org/10.22034/judpm.2025.514770.1029>



© Sana Nazarinezhad, Elham Farahani
DOI: <http://doi.org/10.22034/judpm.2025.514770.1029>

Introduction

Rapid urbanization and vehicle proliferation have overwhelmed traditional transportation systems, underscoring the need for innovative solutions in modern cities. Smart cities, integrating AI, IoT, and ICT, offer promising avenues to address these challenges. This research investigates the use of AI and computer vision to optimize traffic management within smart city environments, aiming to improve traffic flow, safety, and reduce environmental impact. Efficient traffic management is crucial for sustainable and livable urban spaces, and AI holds the potential to revolutionize transportation systems.

Methodology

This study utilized the YOLOv8 model, the latest evolution of the YOLO object detection framework, for traffic sign detection due to its enhanced speed and accuracy. The model was trained and evaluated using the Self-Driving Cars dataset, a comprehensive collection of 4969 traffic sign images representing diverse scenarios. The methodology involved data loading, preprocessing, model training

with hyperparameter optimization (batch size, learning rate, epochs), and performance evaluation using precision, recall, F1-score, and mean Average Precision (mAP). The dataset's characteristics, including class distribution and bounding box relationships, were analyzed.

Results

The YOLOv8 model showed promising results in traffic sign detection, achieving high accuracy in identifying various signs like speed limits, stop signs, and traffic lights. The confusion matrix detailed the model's performance across different classes, revealing strengths in detecting certain signs (e.g., speed limits) but challenges with others (e.g., traffic lights). Precision-confidence and recall-confidence curves illustrated the trade-off at different thresholds. Output examples demonstrated the model's ability to detect multiple signs in single images. Training results, including loss curves and mAP scores, indicated convergence and learning progress. Overall, YOLOv8 demonstrated effective potential for traffic sign detection in smart city applications.

Conclusion

This research highlights the transformative potential of AI and computer vision in smart city traffic management. YOLOv8 proved to be a valuable tool for traffic sign detection, contributing to intelligent transportation systems. Its accuracy can enhance driver assistance, autonomous vehicles, and traffic monitoring. However, limitations in detecting specific sign classes were noted. Future research should explore integrating multimodal models, enriching training data with diverse conditions, and deploying the model on edge devices for real-time processing. Combining traffic sign detection with traffic prediction and urban management systems is also suggested for comprehensive traffic management strategies. In conclusion, AI plays a significant role in advancing smart city initiatives and improving the safety, efficiency, and sustainability of urban transportation systems.



بررسی عملکرد مدل YOLOv8 در تشخیص علائم ترافیکی برای سامانه‌های حمل‌ونقل هوشمند

ثنا نظری نژاد^{۱*} | الهام فراهانی^۲

۱. نویسنده مسئول، کارشناسی ارشد مهندسی فناوری اطلاعات، گروه فناوری اطلاعات، دانشکده مهندسی صنایع، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران. رایانامه: sana.nazari@email.kntu.ac.ir
۲. استادیار، دانشکده مهندسی کامپیوتر، مؤسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران. رایانامه: elham.farahani@iranian.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:

پژوهشی

تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۳/۱۲/۲۸

تاریخ بازنگری: ۱۴۰۴/۰۱/۲۹

تاریخ پذیرش: ۱۴۰۴/۰۲/۲۵

تاریخ انتشار: ۱۴۰۴/۰۳/۱۱

کلیدواژه:

بینایی کامپیوتر،

شهرهای هوشمند،

مدیریت ترافیک،

هوش مصنوعی،

یادگیری عمیق.

با توجه به رشد روزافزون شهرنشینی و افزایش تعداد وسایل نقلیه، سیستم‌های حمل‌ونقل سنتی دیگر پاسخ‌گوی نیازهای جمعیتی نیستند و استفاده از راهکارهای هوشمند مبتنی بر داده، ضروری به نظر می‌رسد. در این راستا، مقاله حاضر به بررسی چگونگی بهره‌گیری از هوش مصنوعی، به‌ویژه بینایی کامپیوتری، در مدیریت ترافیک شهری می‌پردازد. در این پژوهش، از مدل YOLOv8، جدیدترین نسخه از مدل‌های YOLO، برای تشخیص علائم راهنمایی و رانندگی استفاده شده است. این مدل با استفاده از معماری بهبود می‌یابد، سرعت و دقت بیشتری نسبت به نسخه‌های قبلی ارائه می‌دهد و امکان تشخیص اشیا در زمان واقعی را فراهم می‌کند. برای آموزش و ارزیابی مدل، از دیتاست Self-Driving Cars استفاده شده است که شامل تصاویر علائم ترافیکی مختلف است. نتایج ارزیابی مدل نشان می‌دهد YOLOv8 عملکرد قابل قبولی در تشخیص علائم ترافیکی دارد. این مدل می‌تواند به عنوان یک راهکار مؤثر برای نظارت هوشمند بر ترافیک شهری و بهبود ایمنی جاده‌ها مورد استفاده قرار گیرد. با این حال، مقاله به چالش‌های موجود در تشخیص برخی از کلاس‌های علائم ترافیکی نیز اشاره دارد و پیشنهادهایی برای بهبود بیشتر مدل و توسعه روش‌های مؤثرتر در مدیریت هوشمند ترافیک ارائه می‌دهد. این پیشنهادها شامل استفاده از مدل‌های چندوجهی، افزایش تنوع داده‌های آموزشی و پیاده‌سازی مدل روی سخت‌افزارهای سبک است.

استناد: نظری نژاد، ثنا و فراهانی، الهام (۱۴۰۴). بررسی عملکرد مدل YOLOv8 در تشخیص علائم ترافیکی برای سامانه‌های حمل‌ونقل هوشمند. *سیاستگذاری پیشرفت شهری*، ۲ (۳) ۲۷۷-۲۹۶.

DOI: <http://doi.org/10.22034/judpm.2025.514770.1029>

© ثنا نظری نژاد، الهام فراهانی

DOI: <http://doi.org/10.22034/judpm.2025.514770.1029>



۱. مقدمه

شهرها و جوامع هوشمند^۱ (SCC) یک حوزه تحقیقاتی رو به رشد هستند که به دنبال ارائه راه‌حل‌های نوآورانه برای چالش‌های زیست‌محیطی، اقتصادی و حمل‌ونقل هستند. هوش مصنوعی، همراه با فناوری‌های پیشرفته‌ای مانند اینترنت اشیا^۲ (IoT) و سیستم‌های اطلاعات و ارتباطات^۳ (ICT)، امکان مدیریت کارآمدتر منابع شهری و بهینه‌سازی زیرساخت‌های حمل‌ونقل را فراهم کرده است [۱-۳]. با رشد سریع شهرنشینی و افزایش تعداد وسایل نقلیه در سطح شهرها، سیستم‌های حمل‌ونقل سنتی دیگر پاسخ‌گوی نیازهای جمعیتی نیستند و راه‌حل‌های هوشمند مبتنی بر داده، ضروری به نظر می‌رسند [۴ و ۵]. در این میان، سیستم‌های بینایی کامپیوتری و پردازش تصویر به عنوان ابزارهای کلیدی برای جمع‌آوری و تحلیل اطلاعات ترافیکی، نقش مهمی در بهینه‌سازی مدیریت حمل‌ونقل ایفا می‌کنند.

در دهه‌های اخیر، بهره‌گیری از هوش مصنوعی در مدیریت ترافیک شهری به کاهش ازدحام و افزایش ایمنی جاده‌ها منجر شده است. تحلیل داده‌های ترافیکی لحظه‌ای و پیش‌بینی الگوهای رفتاری وسایل نقلیه، از جمله کاربردهای کلیدی این فناوری است. مدل‌های یادگیری ماشین، با پردازش حجم عظیمی از داده‌های ترافیکی، قادر هستند مسیرهای جایگزین را پیشنهاد دهند و تنظیمات چراغ‌های راهنمایی را بهینه کنند [۶ و ۷]. این پیشرفت‌ها نه تنها باعث کاهش تأخیرهای ترافیکی شده، بلکه مصرف سوخت و انتشار گازهای گلخانه‌ای را نیز به حداقل رسانده است [۸ و ۹].

علاوه بر مدیریت ترافیک، هوش مصنوعی در بهبود ایمنی حمل‌ونقل نیز نقش بسزایی دارد. سیستم‌های پیشرفته کمک راننده^۴ (ADAS) و وسایل نقلیه خودران، مجهز به فناوری‌های بینایی کامپیوتری و یادگیری عمیق، می‌توانند خطرات احتمالی را تشخیص دهند و از وقوع تصادفات جلوگیری کنند. تحقیقات نشان داده‌اند استفاده از این سیستم‌ها می‌تواند میزان تصادفات جاده‌ای را تا حد قابل توجهی کاهش دهد [۱۰ و ۱۱]. اتحادیه اروپا و سایر نهادهای بین‌المللی نیز اهدافی را برای کاهش تصادفات و بهبود امنیت حمل‌ونقل تدوین کرده‌اند که بر اهمیت توسعه فناوری‌های هوش مصنوعی در این زمینه تأکید دارد [۱۲ و ۱۳].

یکی از کاربردهای مهم بینایی کامپیوتری در سامانه‌های حمل‌ونقل هوشمند، تشخیص علائم ترافیکی است. این فناوری نه تنها برای وسایل نقلیه خودران و سیستم‌های ADAS حیاتی است، بلکه در بهینه‌سازی مدیریت ترافیک و اجرای قوانین راهنمایی و رانندگی نیز نقش مهمی دارد. در این زمینه، مدل‌های یادگیری عمیق مانند YOLO (You Only Look Once) به دلیل سرعت و دقت زیاد خود در شناسایی اشیا، به‌ویژه در محیط‌های پویا و پیچیده شهری، مورد توجه قرار گرفته‌اند [۱۲ و ۱۳]. آخرین نسخه این مدل، یعنی YOLOv8، با بهبودهایی در دقت و کارایی، قابلیت‌های برجسته‌ای در تشخیص سریع و دقیق علائم ترافیکی ارائه می‌دهد. این ویژگی‌ها، YOLOv8 را به گزینه‌ای ایده‌آل برای پیاده‌سازی در سامانه‌های نظارت ترافیکی، مدیریت هوشمند چراغ‌های راهنمایی و بهبود ایمنی حمل‌ونقل تبدیل کرده‌اند [۱۴ و ۱۵].

در زمینه تشخیص علائم ترافیکی، علاوه بر مدل YOLOv8، از الگوریتم‌های دیگری مانند Faster R-CNN (Region-based Convolutional Neural Network)، Single Shot MultiBox Detector (SSD) و RetinaNet نیز استفاده می‌شود. هر یک از این الگوریتم‌ها به‌ویژه در مسائل مربوط به تشخیص اشیا و علائم ترافیکی عملکرد خوبی از خود نشان داده‌اند. Faster R-CNN یکی از مدل‌های پرکاربرد در تشخیص اشیا است که به دلیل دقت زیاد خود در شناسایی ویژگی‌ها و دقت در تعیین موقعیت اشیا، توجه زیادی را جلب کرده است. از سوی دیگر، SSD به دلیل سرعت زیاد در پردازش تصاویر و توانایی شناسایی اشیا در مقیاس‌های مختلف، در سیستم‌های زمان واقعی کاربرد دارد. همچنین RetinaNet با استفاده از Focal Loss به طور ویژه در شناسایی اشیا کوچک مانند علائم ترافیکی مؤثر است. اما مدل YOLOv8 به طور ویژه به دلیل ترکیب دقت زیاد و سرعت پردازش فوق‌العاده، نسبت به این الگوریتم‌ها مزیت‌های قابل توجهی دارد. از اصلی‌ترین برتری‌های YOLOv8 در مقایسه با الگوریتم‌های دیگر، سرعت پردازش بالای آن است که برای کاربردهای واقعی در محیط‌های شهری و ترافیکی ضروری است. این مدل می‌تواند در زمان‌های

1. Smart cities and communities (SCC)
 2. Internet of Things (IoT)
 3. Information and Communication Technologies (ICT)
 4. Advanced Driver Assistance Systems (ADAS)

بسیار کوتاه، تعداد زیادی از علائم ترافیکی را با دقت زیاد شناسایی کرده و به صورت هم‌زمان چندین شیء را در یک تصویر پردازش کند. علاوه بر این، توانایی YOLOv8 در تشخیص دقیق و سریع علائم ترافیکی در شرایط پیچیده شهری، مانند تغییرات نور، ازدحام ترافیکی و پیچیدگی‌های محیطی، آن را از مدل‌های دیگر متمایز می‌کند. این ویژگی‌ها، YOLOv8 را به گزینه‌ای ایده‌آل برای کاربردهای زمان واقعی در سامانه‌های حمل‌ونقل هوشمند تبدیل می‌کند [۱۴-۱۷].

برخی از شهرهای پیشرفته‌ای مانند سنگاپور، بارسلونا و آمستردام از مدل‌های بینایی کامپیوتری برای بهینه‌سازی مدیریت ترافیک و بهبود حمل‌ونقل عمومی بهره گرفته‌اند. این شهرها با اجرای سیستم‌های نظارتی پیشرفته، الگوریتم‌های یادگیری ماشین و تجزیه و تحلیل داده‌های ترافیکی، توانسته‌اند ازدحام ترافیک را کاهش داده و تجربه حمل‌ونقل بهتری برای شهروندان فراهم کنند [۱۴ و ۱۵]. توسعه این فناوری‌ها نشان داده است که هوش مصنوعی نه تنها به بهبود کارایی زیرساخت‌های شهری کمک می‌کند، بلکه تأثیرات مثبتی بر محیط زیست و کاهش آلودگی دارد [۱۶ و ۱۷]. در این مقاله، عملکرد مدل YOLOv8 در تشخیص علائم ترافیکی برای سامانه‌های حمل‌ونقل هوشمند مورد بررسی قرار می‌گیرد. هدف از این پژوهش، ارزیابی توانایی YOLOv8 در شناسایی علائم جاده‌ای و ارائه راهکارهایی برای بهبود دقت و کارایی این مدل در سیستم‌های حمل‌ونقل هوشمند است [۱۸ و ۱۹].

۲. کارهای گذشته

پیشرفت‌های مدل YOLOv8، آن را به عنوان یک جزء محوری در ارتقای سیستم‌های حمل‌ونقل هوشمند از طریق تشخیص مؤثر علائم راهنمایی و رانندگی قرار می‌دهد [۱]. در این بخش به بررسی مطالعات انجام شده در این زمینه پرداخته می‌شود.

۱- شهرهای هوشمند و مدیریت ترافیک

شهرها و جوامع هوشمند یک حوزه تحقیقاتی نوظهور است که توسط پیشرفت‌های عمده در فناوری، تغییرات در عملیات تجاری و چالش‌های زیست‌محیطی ترویج می‌شود. برخی از فناوری‌های توانمندساز برای شهرهای هوشمند، فناوری‌های اطلاعات و ارتباطات هستند که زیرساخت‌ها، منابع و خدمات را با سیستم‌های نظارت داده و مدیریت دارای مرتبط می‌کنند [۲ و ۳]. فناوری دیگر، اینترنت اشیا است که دستگاه‌ها را قادر می‌سازد به اینترنت متصل شوند و وضعیت عملیاتی خود را به اشتراک بگذارند [۴]. دیجیتالی شدن و پیشرفت‌های فناوری اطلاعات و ارتباطات، عامل اصلی تغییر در عملیات تجاری و اقتصادی محسوب می‌شوند. از هوش مصنوعی برای تحلیل داده‌ها و بهبود کارایی سیستم‌های مختلف از جمله مدیریت ترافیک شهری استفاده می‌شود [۵ و ۶]. روندهای اخیر نشان می‌دهد کسب‌وکارها به سمت ارائه خدمات مبتنی بر هوش مصنوعی حرکت کرده‌اند، که به بهبود بهره‌وری و کاهش هزینه‌ها منجر شده است [۷ و ۸].

۲- چالش‌های انرژی و ایمنی در حمل‌ونقل شهری

مصرف انرژی یکی دیگر از چالش‌های مهم در جوامع شهری است. در اروپا، انرژی مصرفی در حمل‌ونقل به میزان ۲۸ درصد از کل انرژی مصرفی را شامل می‌شود که نشان‌دهنده نیاز به بهینه‌سازی سیستم‌های حمل‌ونقل است [۱۱ و ۱۲]. سیستم‌های مدیریت ترافیک مبتنی بر هوش مصنوعی می‌توانند به کاهش مصرف انرژی و کاهش آلاینده‌های زیست‌محیطی کمک کنند [۱۳ و ۱۴].

ادغام هوش مصنوعی در سیستم‌های مدیریت ترافیک باعث بهبود بهره‌وری حمل‌ونقل و کاهش تصادفات شده است. در اتحادیه اروپا، مصرف انرژی در حمل‌ونقل از سال ۱۹۹۰ تا ۲۰۱۷ به میزان ۳۲ درصد افزایش یافته و این روند نیازمند راهکارهای هوشمند برای بهینه‌سازی جریان ترافیک است [۱۵ و ۱۶].

ایمنی ترافیک یکی از چالش‌های مهم جهانی است. گزارش‌ها نشان می‌دهد در سال ۲۰۱۹، حدود ۲۲۷۰۰ نفر در اروپا بر اثر تصادفات رانندگی جان خود را از دست دادند و بیش از ۱/۴ میلیون نفر مجروح شدند [۱۷ و ۱۸]. استفاده از سیستم‌های مبتنی بر هوش مصنوعی مانند ADAS می‌تواند خطر تصادفات را کاهش دهد و ایمنی کاربران جاده‌ای را افزایش دهد [۱۹ و ۲۰].

۳- هوش مصنوعی و مدیریت هوشمند ترافیک

با توجه به افزایش روند خودکارسازی وسایل نقلیه، پتانسیل زیادی برای کاهش اثرات تصادفات یا حتی جلوگیری از وقوع آن‌ها وجود دارد. فناوری اینترنت اشیا می‌تواند به توسعه سیستم‌های ایمنی کمک کند که بتوانند کاربران آسیب‌پذیر جاده را شناسایی کنند و به آن‌ها هشدار دهند [۲۱ و ۲۲].

در سطح جهانی، هوش مصنوعی برای پیش‌بینی الگوهای ترافیکی و کاهش ازدحام در محیط‌های شهری به کار گرفته شده است. سیستم‌های مدیریت هوشمند ترافیک می‌توانند با پردازش داده‌های لحظه‌ای، زمان‌بندی چراغ‌های راهنمایی را تنظیم کنند و جریان ترافیک را بهینه سازند [۲۳ و ۲۴].

یکی از ابتکارات مهم در این زمینه، شبکه اروپایی CIVITAS است که با هدف کاهش آلاینده‌های زیست‌محیطی و بهبود تحرک شهری فعالیت می‌کند. این پروژه بیش از ۸۵ شهر را در بر گرفته و اقداماتی مانند برنامه‌ریزی حمل‌ونقل یکپارچه و مدیریت هوشمند ترافیک را توسعه داده است [۲۵ و ۲۶]. در سوئد، برنامه Drive Sweden توسعه راه‌حل‌های حمل‌ونقل پایدار را دنبال می‌کند. این پروژه از هوش مصنوعی برای هماهنگ‌سازی حمل‌ونقل عمومی و بهینه‌سازی زیرساخت‌های شهری استفاده می‌کند [۲۷ و ۲۸]. در سنگاپور، سیستم‌های حمل‌ونقل هوشمند با بهره‌گیری از الگوریتم‌های یادگیری ماشین توانسته‌اند تأخیرهای ناشی از ترافیک را کاهش دهند و بهره‌وری شبکه حمل‌ونقل را افزایش دهند [۲۹ - ۳۲]. همچنین، سیستم‌های مدیریت هوشمند ترافیک در بارسلونا به کاهش قابل توجه ازدحام و افزایش کارایی شهری منجر شده‌اند. این سیستم‌ها با استفاده از داده‌های بلادرنگ و الگوریتم‌های هوش مصنوعی، زمان‌بندی چراغ‌های راهنمایی را بهینه‌سازی می‌کنند [۳۳ - ۳۶].

۴- بررسی عملکرد YOLOv8 در تشخیص علائم راهنمایی و رانندگی

مدل YOLOv8 به عنوان ابزاری پیشرو برای تشخیص علائم راهنمایی و رانندگی در سیستم‌های حمل‌ونقل هوشمند (ITS) مطرح شده است. این مدل به دلیل دقت و کارایی زیاد خود در تشخیص انواع علائم راهنمایی و رانندگی، که برای افزایش ایمنی جاده و مدیریت مؤثر ترافیک حیاتی است، قابل توجه است [۳۷ و ۳۸].

۵- ارزیابی عملکرد YOLOv8

تحقیقات نشان داده است YOLOv8 از نظر دقت و قابلیت اطمینان، به طور قابل توجهی از مدل‌های قبلی مانند ResNet50 عملکرد بهتری دارد. به عنوان مثال، YOLOv8 به مقادیر دقت، بازیابی و امتیاز F1 به ترتیب ۰/۹۳۴۵، ۰/۹۴۲۸، ۰/۹۴۲۸ و ۰/۹۳۲۲ درصد که نشان‌دهنده قابلیت قوی آن در کاربردهای دنیای واقعی است، دست یافت [۳۸]. در مقابل، ResNet50 دقت پایین‌تری معادل ۸۴/۳۲ درصد را ثبت کرد، که عملکرد برتر YOLOv8 را در وظایف تشخیص علائم راهنمایی و رانندگی برجسته می‌کند [۳۸].

۶- سازگاری با شرایط چالش برانگیز

یکی از پیشرفت‌های کلیدی YOLOv8، سازگاری آن با شرایط محیطی چالش برانگیز مانند مه و انسداد است. یک مطالعه اخیر، اصلاحاتی را در معماری YOLOv8 برای بهبود عملکرد آن در این شرایط معرفی کرد. با ادغام یک ماژول چندشاخه‌ای CSP^۲ و یک شبکه همجوشی ویژگی مسیر دوگانه، YOLOv8 اصلاح شده، معیارهای تشخیص بهبودیافته‌ای را نشان داد و به افزایش میانگین دقت متوسط (mAP) به میزان ۲/۱ و ۲/۲ درصد در شرایط نامساعد دست یافت [۳۹]. این سازگاری برای حفظ دقت تشخیص در سناریوهای رانندگی دنیای واقعی بسیار مهم است.

۷- استفاده از مجموعه داده‌های جامع

اثر بخشی YOLOv8 با استفاده از مجموعه داده‌های گسترده برای آموزش و ارزیابی بیشتر پشتیبانی می‌شود. محققان از مجموعه داده‌هایی استفاده کرده‌اند که شامل تصاویر متنوع علائم راهنمایی و رانندگی در شرایط محیطی مختلف است و اطمینان

1. Intelligent Transportation System
2. Cross Stage Partial

می‌دهد که مدل به خوبی برای مقابله با چالش‌های دنیای واقعی مجهز شده است [۴۰]. توانایی پردازش شرایط نور پیچیده و انسداد، YOLOv8 را به گزینه‌ای ترجیحی برای تشخیص علائم راهنمایی و رانندگی تبدیل می‌کند [۴۰].

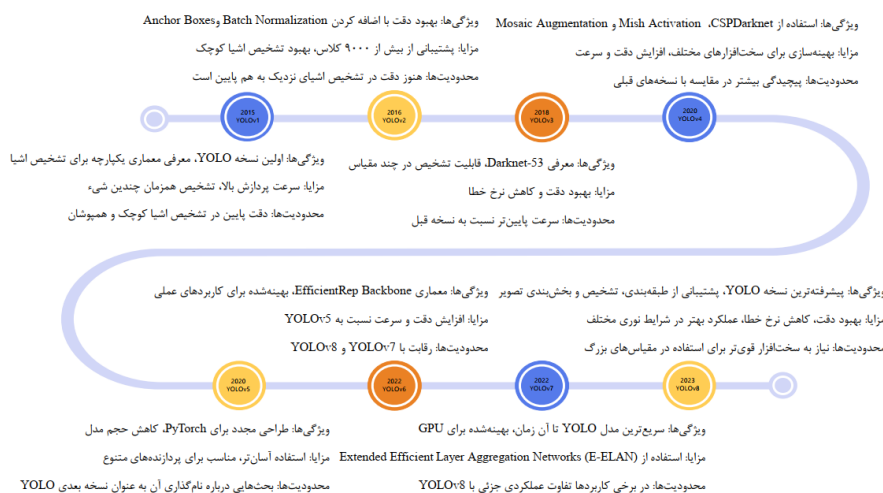
۳. مدل پیشنهادی

۳-۱. YOLOv8

YOLOv8 جدیدترین نسخه از مدل‌های YOLO است که توسط Ultralytics توسعه یافته و برای تشخیص اشیاء، طبقه‌بندی تصاویر و بخش‌بندی تصاویر بهینه‌سازی شده است. این مدل با استفاده از معماری بهبودیافته، سرعت و دقت بیشتری نسبت به نسخه‌های قبلی ارائه می‌دهد و آن را به یکی از پیشرفته‌ترین مدل‌های بینایی کامپیوتر تبدیل کرده است. YOLOv8 بر اساس شبکه‌های عصبی کانولوشنال (CNNs) طراحی شده و به گونه‌ای بهینه‌سازی شده که بتواند در زمان واقعی (Real-Time) اشیاء را با دقت زیاد تشخیص دهد. یکی از ویژگی‌های کلیدی YOLOv8 بهینه‌سازی در پردازش تصاویر و کاهش میزان محاسبات است که باعث شده در سخت‌افزارهای سبک مانند پردازنده‌های کم‌توان (Edge Devices) و موبایل‌ها نیز قابل اجرا باشد. این مدل علاوه بر دقت زیاد در تشخیص، قابلیت‌های پیشرفته‌ای مانند کاهش نرخ خطا، بهبود پردازش تصاویر در شرایط نوری مختلف، و عملکرد بهینه در محیط‌های چالش‌برانگیز را فراهم کرده است. همچنین، YOLOv8 دارای مدل‌های از پیش آموزش دیده (Pre-trained Models) است که روی مجموعه داده‌های معروفی مانند COCO آموزش دیده‌اند و می‌توانند برای بهبود عملکرد روی داده‌های خاص، یادگیری انتقالی (Transfer Learning) را به کار بگیرند. علاوه بر این، این مدل از تکنیک‌های افزایش داده (Data Augmentation) بهره می‌برد که موجب بهبود توانایی تعمیم‌دهی مدل در شرایط متنوع می‌شود [۴۱ و ۴۲].

۳-۱-۱. نقشه راه توسعه YOLO تا YOLOv8

نقشه راه توسعه YOLO از اولین نسخه تا YOLOv8، که در شکل ۱ نمایش داده شده است، روند تکامل این مدل را از نظر دقت، سرعت و بهینه‌سازی برای کاربردهای عملی نشان می‌دهد. در هر نسخه، معماری بهبود یافته و قابلیت‌های جدیدی مانند افزایش دقت تشخیص، کاهش نرخ خطا و بهینه‌سازی پردازشی اضافه شده است. این پیشرفت‌ها باعث شده تا YOLO به یکی از محبوب‌ترین مدل‌های تشخیص اشیاء در بینایی کامپیوتر تبدیل شود.



شکل ۱. نقشه راه توسعه YOLO

۳-۱-۲. ویژگی‌های کلیدی YOLOv8

۱. بهبود دقت و سرعت: در مقایسه با نسخه‌های پیشین، YOLOv8 بهینه‌سازی‌های مهمی در زمینه پردازش تصاویر و شناسایی اشیاء داشته که باعث افزایش دقت و کاهش زمان اجرا شده است [۴۱ و ۴۲].

۲. قابلیت اجرا روی سخت‌افزارهای مختلف: این مدل می‌تواند روی CPU، GPU و حتی سخت‌افزارهای تعبیه‌شده اجرا شود و برای سیستم‌های بلادرنگ مناسب است [۴۱ و ۴۲].
۳. بهینه‌سازی برای مجموعه داده‌های متنوع: مدل YOLOv8 می‌تواند روی مجموعه داده‌های مختلف مانند COCO، Open Images و سایر دیتاست‌های سفارشی آموزش ببیند و برای کاربردهای گوناگون تنظیم شود [۴۱ و ۴۲].
۴. پشتیبانی از چندین وظیفه بصری: این مدل علاوه بر تشخیص اشیا، قابلیت‌های دیگری مانند بخش‌بندی تصویر و تشخیص نقاط کلیدی را نیز ارائه می‌دهد [۴۱ و ۴۲].
۵. استفاده از تکنیک‌های یادگیری انتقالی (Transfer Learning): امکان آموزش مدل با استفاده از وزن‌های از پیش آموزش‌دیده روی مجموعه داده‌های بزرگ مانند COCO وجود دارد که به بهبود عملکرد روی داده‌های جدید کمک می‌کند [۴۱ و ۴۲].

۲-۳. مجموعه داده

برای آموزش و ارزیابی مدل YOLOv8 در این پژوهش، از دیتاست Self-Driving Cars استفاده شده است که در Roboflow Universe در دسترس قرار دارد. این دیتاست شامل ۴۹۶۹ تصویر از علائم ترافیکی مختلف است که برای توسعه و آزمایش سیستم‌های بینایی کامپیوتر در خودروهای خودران و مدیریت ترافیک مورد استفاده قرار می‌گیرد. جدول ۱ تحلیل مختصری از این مجموعه داده ارائه می‌دهد.

جدول ۱. مجموعه داده Self-Driving Cars

ویژگی	توضیحات
تعداد تصاویر	۴۰۹۶۹ تصویر
نوع تصاویر	تصاویر علائم راهنمایی و رانندگی
فرمت تصاویر	JPEG
ابعاد تصاویر	۶۴۰x۶۴۰ پیکسل (نسخه ۴) و ۴۱۶x۴۱۶ پیکسل (نسخه ۶)
فرمت برچسب‌ها	JSON (COCO)، XML (Pascal VOC)، TXT (YOLO)
تعداد کلاس‌ها	۱۵ کلاس: چراغ سبز، چراغ قرمز، محدودیت سرعت ۱۰، محدودیت سرعت ۱۰۰، محدودیت سرعت ۱۱۰، محدودیت سرعت ۱۲۰، محدودیت سرعت ۲۰، محدودیت سرعت ۳۰، محدودیت سرعت ۴۰، محدودیت سرعت ۵۰، محدودیت سرعت ۶۰، محدودیت سرعت ۷۰، حداکثر سرعت ۸۰، حداکثر سرعت ۹۰، توقف.

۱-۲-۳. ویژگی‌های کلیدی YOLOv8

تنوع در کلاس‌های علائم ترافیکی: این دیتاست شامل ۱۵ کلاس مختلف از علائم ترافیکی است، از جمله:

- چراغ سبز، چراغ قرمز
- محدودیت سرعت (۱۰، ۲۰، ۳۰، ...، ۱۲۰ کیلومتر بر ساعت)
- علامت توقف

اندازه‌گیری دقیق داده‌ها: تمام تصاویر دارای برچسب‌های دقیق و مختصات جعبه‌های محدودکننده (Bounding Boxes) هستند که به مدل کمک می‌کند مکان دقیق اشیا را در تصویر تشخیص دهد.

تقسیم‌بندی داده‌ها: داده‌های این مجموعه به سه بخش آموزش (Train)، اعتبارسنجی (Valid)، و آزمون (Test) تقسیم شده‌اند تا عملکرد مدل در شرایط مختلف مورد بررسی قرار گیرد.


قابلیت استفاده در کاربردهای مختلف: این دیتاست برای پروژه‌های تشخیص علائم راهنمایی و رانندگی، بهینه‌سازی سیستم‌های کمک‌راننده (ADAS)، و مدیریت هوشمند ترافیک مناسب است. در شکل ۲ تعدادی از تصاویر اصلی را قبل از تشخیص می‌توان مشاهده کرد.



شکل ۲. تصاویر مجموعه داده

۳-۲-۲. تجزیه و تحلیل مجموعه داده

شکل ۳ کورلوگرام مربوط به برچسب‌های علائم ترافیکی را نشان می‌دهد. این نمودار، رابطه بین مختصات x ، y ، عرض و ارتفاع جعبه‌های محدودکننده علائم ترافیکی را به صورت گرافیکی نمایش می‌دهد.



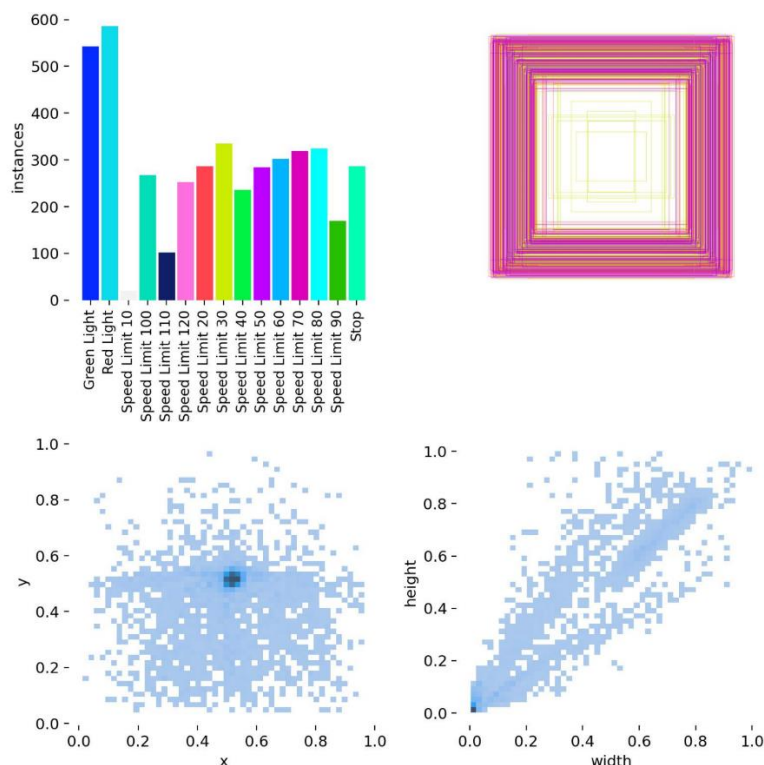
شکل ۳. کورلوگرام مربوط به برچسب‌های علائم ترافیکی

همان‌طور که مشاهده می‌شود، نمودار در امتداد قطر اصلی، هیستوگرام‌های مربوط به هر متغیر را نشان می‌دهد. این هیستوگرام‌ها توزیع داده‌های مربوط به هر متغیر را نمایش می‌دهند. برای مثال، هیستوگرام مربوط به مختصات y نشان می‌دهد بیشتر علائم ترافیکی در قسمت‌های پایین‌تر تصویر قرار دارند.

در قسمت‌های دیگر نمودار، نمودارهای پراکنش رابطه بین هر دو متغیر را نشان می‌دهند. برای مثال، نمودار پراکنش بین عرض و ارتفاع جعبه‌های محدودکننده نشان می‌دهد بین این دو متغیر رابطه مثبتی وجود دارد؛ به این معنا که علائم ترافیکی با عرض بیشتر، معمولاً ارتفاع بیشتری نیز دارند.

این نمودار می‌تواند اطلاعات مفیدی در مورد ویژگی‌های هندسی علائم ترافیکی ارائه دهد و به ما کمک کند تا الگوهای موجود در داده‌ها را شناسایی کنیم. این اطلاعات می‌تواند در طراحی مدل‌های تشخیص علائم ترافیکی و بهبود عملکرد آن‌ها مفید باشد.

شکل ۴ اطلاعات مختلفی را در مورد برچسب‌های علائم ترافیکی در مجموعه داده نشان می‌دهد. این تصویر شامل سه نمودار جداگانه است که هر یک اطلاعات خاصی را ارائه می‌دهند.



شکل ۴. توزیع تعداد نمونه‌ها برای هر کلاس، رابطه بین مختصات X و Y جعبه‌های محدودکننده و رابطه بین عرض و ارتفاع جعبه‌های محدودکننده

نمودار اول (بالا سمت چپ): این نمودار، توزیع تعداد نمونه‌ها برای هر کلاس از علائم ترافیکی را نشان می‌دهد. همان‌طور که مشاهده می‌شود، کلاس 'Green Light' بیشترین تعداد نمونه را دارد، در حالی که کلاس 'Speed Limit 10' کمترین تعداد نمونه را دارد. این موضوع نشان می‌دهد مجموعه داده ممکن است ناهمگن باشد و برخی از کلاس‌ها تعداد نمونه‌های بیشتری نسبت به سایر کلاس‌ها داشته باشند.

نمودار دوم (پایین سمت چپ): این نمودار، رابطه بین مختصات X و Y جعبه‌های محدودکننده علائم ترافیکی را نشان می‌دهد. همان‌طور که مشاهده می‌شود، بیشتر علائم ترافیکی در قسمت‌های پایین‌تر تصویر قرار دارند. این موضوع می‌تواند ناشی از نحوه جمع‌آوری داده‌ها یا ویژگی‌های خاص تصاویر مجموعه داده باشد.

نمودار سوم (پایین سمت راست): این نمودار، رابطه بین عرض و ارتفاع جعبه‌های محدودکننده علائم ترافیکی را نشان می‌دهد. همان‌طور که مشاهده می‌شود، بین این دو متغیر رابطه مثبتی وجود دارد؛ به این معنا که علائم ترافیکی با عرض بیشتر، معمولاً ارتفاع بیشتری نیز دارند.

به طور کلی، این تصویر اطلاعات مفیدی در مورد ویژگی‌های هندسی علائم ترافیکی و توزیع کلاس‌ها در مجموعه داده ارائه می‌دهد. این اطلاعات می‌تواند در طراحی مدل‌های تشخیص علائم ترافیکی و بهبود عملکرد آن‌ها مفید باشد.

۳-۲-۳. تجزیه و تحلیل مجموعه داده

- رعایت قوانین راهنمایی و رانندگی: مدل آموزش‌دیده با این دیتاست می‌تواند در سیستم‌های کمک‌راننده و خودروهای خودران برای تشخیص علائم و اخطار به رانندگان استفاده شوند.
- زیرساخت شهر هوشمند: مقامات شهری می‌توانند از این مدل برای نظارت بر رعایت قوانین راهنمایی و رانندگی و بهبود مدیریت ترافیک بهره ببرند.
- بهبود ایمنی جاده‌ای: این مدل می‌تواند به کاهش تصادفات و تخلفات جاده‌ای کمک کند.

استفاده از این دیتاست در ترکیب با مدل YOLOv8، امکان بهینه‌سازی مدیریت ترافیک در شهرهای هوشمند را فراهم می‌کند. با تحلیل دقیق نتایج خروجی مدل، می‌توان سیاست‌های بهتری برای کنترل جریان ترافیک، کاهش حوادث رانندگی و بهبود زیرساخت‌های شهری اتخاذ کرد.

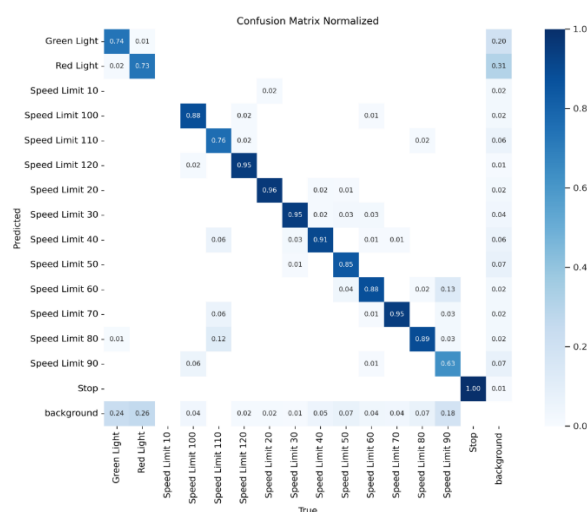
۳-۳. فرایند آموزش و استفاده از YOLOv8

در این پژوهش، از YOLOv8 برای تشخیص علائم راهنمایی و رانندگی استفاده شده است. مراحل پیاده‌سازی مدل شامل بارگذاری داده‌ها، انجام پیش‌پردازش، آموزش مدل و ارزیابی عملکرد آن است.

- بارگذاری و پیش‌پردازش داده‌ها: ابتدا تصاویر و برچسب‌های مربوط به علائم ترافیکی از دیتاست Self-Driving Cars دریافت شد. تصاویر به فرمت مورد نیاز YOLOv8 تبدیل شدند و نرمال‌سازی داده‌ها برای بهبود کیفیت آموزش انجام شد.
- آموزش مدل: مدل YOLOv8 با مجموعه داده Train آموزش داده شد. از معیارهای Mean و Loss Function Average Precision (mAP) برای نظارت بر عملکرد مدل استفاده شد.
- تنظیم هایپرپارامترها: برای دستیابی به بهترین عملکرد، پارامترهای مدل مانند اندازه دسته داده‌ها (batch size)، نرخ یادگیری (learning rate) و تعداد تکرارها (epochs) تنظیم شدند.
- ارزیابی مدل: عملکرد مدل با استفاده از داده‌های Valid و Test ارزیابی شد و معیارهای دقت و نرخ بازیابی برای تعیین کارایی مدل محاسبه شدند.
- استنتاج و پیش‌بینی: پس از آموزش، مدل برای تشخیص علائم در تصاویر جدید به کار گرفته شد.

۴. نتایج

این بخش به بررسی و ارزیابی مدل پیشنهادی می‌پردازد. شکل ۵ ماتریس درهم‌ریختگی نرمال‌شده را برای مدل طبقه‌بندی علائم ترافیکی نشان می‌دهد. این ماتریس به ما امکان می‌دهد تا عملکرد مدل را در تشخیص هر کلاس به طور جداگانه ارزیابی کنیم و قوت‌ها و ضعف‌های آن را شناسایی کنیم.



شکل ۵. ماتریس درهم‌ریختگی نرمال‌شده

همان‌طور که مشاهده می‌شود، مدل در تشخیص برخی از کلاس‌ها عملکرد بسیار خوبی دارد. برای مثال، دقت تشخیص علائم 'Speed Limit 20' و 'Speed Limit 120' به ترتیب ۹۵ و ۹۶ درصد است. همچنین، مدل در تشخیص علائم 'Stop' نیز عملکرد قابل قبولی دارد و دقت تشخیص آن ۱۰۰ درصد است.

با این حال، مدل در تشخیص برخی از کلاس‌های دیگر با مشکلاتی مواجه است. برای مثال، دقت تشخیص علامت 'Green Light' تنها ۷۴ درصد است و ۲۰ درصد از نمونه‌های این کلاس به اشتباه به عنوان 'background' طبقه‌بندی شده‌اند. همچنین، دقت تشخیص علامت 'Speed Limit 90' نیز نسبتاً پایین است و تنها ۶۳ درصد است.

این ماتریس نشان می‌دهد مدل در تشخیص علائم مربوط به محدودیت سرعت عملکرد بهتری نسبت به تشخیص علائم مربوط به چراغ راهنمایی دارد. این موضوع می‌تواند ناشی از تفاوت در ویژگی‌های بصری این علائم باشد. علائم مربوط به محدودیت سرعت معمولاً دارای شکل و رنگ‌های متمایزتری هستند، در حالی که علائم مربوط به چراغ راهنمایی ممکن است در شرایط نوری مختلف یا به دلیل انسداد جزئی، تشخیص آن‌ها دشوارتر باشد.

شکل ۶ نمونه‌هایی از خروجی مدل طبقه‌بندی علائم ترافیکی را در مجموعه داده نشان می‌دهد. در این تصویر، هر سطر شامل چهار نمونه از علائم ترافیکی است که توسط مدل شناسایی شده‌اند.



شکل ۶. نمونه‌هایی از خروجی مدل طبقه‌بندی علائم ترافیکی


همان‌طور که مشاهده می‌شود، مدل در تشخیص علامت 'Speed Limit 100' عملکرد بسیار خوبی دارد و در بیشتر موارد، این علامت را با اطمینان بالا (۰/۹) شناسایی می‌کند.

شکل ۷ نمونه‌هایی از خروجی مدل طبقه‌بندی علائم ترافیکی را در مجموعه داده نشان می‌دهد. همان‌طور که مشاهده می‌شود، مدل در این تصویر علائم مختلفی از ۱۵ کلاس تعریف‌شده را شناسایی کرده است. هر علامت با یک کادر مشخص و برچسب مربوط به کلاس آن مشخص شده است.




شکل ۷. نمونه‌هایی از خروجی مدل در تشخیص کلاس‌های مختلف

این تصویر نشان می‌دهد مدل توانایی شناسایی و تمایز بین ۱۵ کلاس مختلف علائم ترافیکی را دارد. این موضوع نشان‌دهنده عملکرد مناسب مدل در یادگیری ویژگی‌های متمایز هر کلاس است. شکل‌های ۸ تا ۱۱ عملکرد مدل طبقه‌بندی علائم ترافیکی را از جنبه‌های مختلف بررسی می‌کنند. شکل ۸ منحنی دقت - اطمینان مدل را نمایش می‌دهد و نشان می‌دهد دقت مدل با افزایش اطمینان آن افزایش می‌یابد. با این حال، در سطوح اطمینان پایین‌تر، دقت کاهش می‌یابد، به‌ویژه در کلاس‌هایی مانند 'Green Light' و 'Red Light' که دقت کمتری نسبت به کلاس‌هایی مانند 'Speed Limit 100' و 'Speed Limit 120' دارند.



شکل ۸. منحنی دقت - اطمینان


شکل ۹ به بررسی منحنی F1- اطمینان می‌پردازد که نشان‌دهنده رابطه بین امتیاز F1 و میزان اطمینان مدل است. این نمودار تأیید می‌کند که امتیاز F1 با افزایش اطمینان افزایش یافته و در سطوح پایین‌تر، به دلیل افزایش خطاها، کاهش می‌یابد.



شکل ۹. منحنی F1- اطمینان

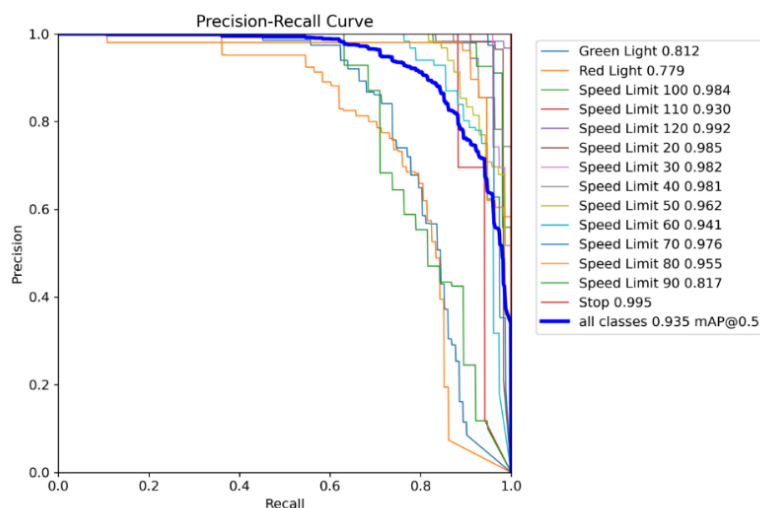
شکل ۱۰ منحنی بازخوانی - اطمینان را نمایش می‌دهد که نشان می‌دهد بازخوانی مدل با افزایش اطمینان کاهش می‌یابد؛ به این معنا که مدل در تشخیص نمونه‌های دارای اطمینان زیاد دقت بیشتری دارد، اما ممکن است برخی از نمونه‌های مثبت را از

دست بدهد. در مقابل، در سطوح پایین تر اطمینان، بازخوانی افزایش می‌یابد؛ به این معنا که مدل در تشخیص نمونه‌های مثبت عملکرد بهتری دارد.



شکل ۱۰. منحنی بازخوانی - اطمینان

در شکل ۱۱، منحنی دقت - بازخوانی ارائه شده است که رابطه بین دقت و بازخوانی مدل را در سطوح مختلف آستانه طبقه‌بندی نشان می‌دهد. مدل در تشخیص برخی کلاس‌ها مانند 'Stop' و 'Speed Limit 120' عملکرد بهتری دارد، در حالی که در تشخیص کلاس‌هایی مانند 'Green Light' با چالش‌هایی روبه‌روست. این نتایج نشان می‌دهد مدل عملکرد کلی قابل قبولی در طبقه‌بندی علائم ترافیکی دارد.



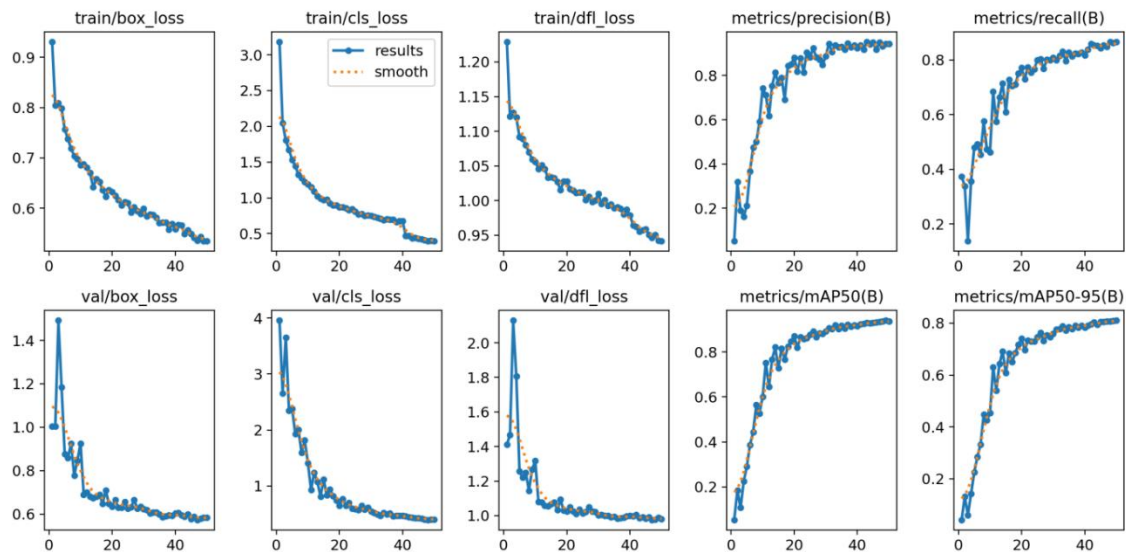
شکل ۱۱. منحنی دقت - بازخوانی

شکل ۱۲ نمونه‌هایی از خروجی مدل طبقه‌بندی علائم ترافیکی را در مجموعه داده نشان می‌دهد. در این تصویر، مدل توانسته است همه علائم را به درستی تشخیص دهد. این موضوع نشان می‌دهد مدل در تشخیص علائم مختلفی از جمله 'Stop'، 'Speed Limit 40'، 'Speed Limit 60'، 'Speed Limit 80'، 'Green Light' و 'Red Light' عملکرد قابل قبولی دارد.



شکل ۱۲. نمونه‌هایی از خروجی مدل

شکل ۱۲ نشان می‌دهد مدل در تشخیص علائم ترافیکی در شرایط مختلف، توانایی خوبی از خود نشان می‌دهد. شکل ۱۳ نمودارهای مربوط به نتایج آموزش مدل طبقه‌بندی علائم ترافیکی را نشان می‌دهد. این نمودارها، اطلاعات مفیدی را در مورد عملکرد مدل طی فرایند آموزش و ارزیابی ارائه می‌دهند.



شکل ۱۳. نمودارهای مربوط به نتایج آموزش مدل طبقه‌بندی علائم ترافیکی

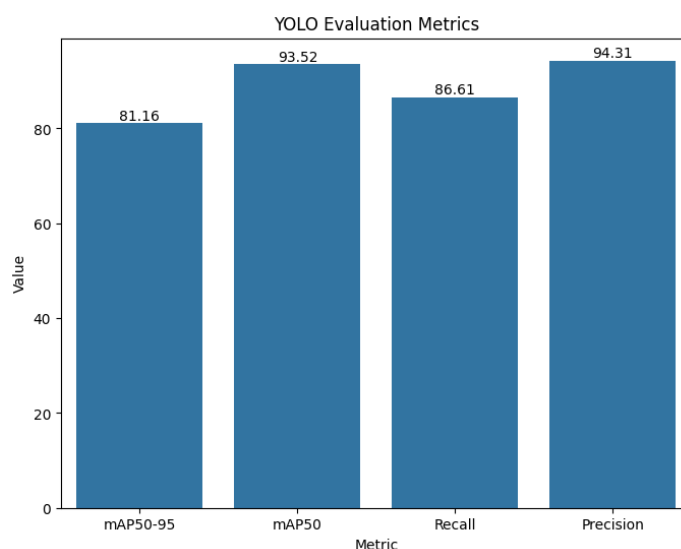
نمودارهای ردیف اول (train): این نمودارها، عملکرد مدل را در مجموعه داده آموزش نشان می‌دهند. نمودار 'train/box_loss' نشان می‌دهد میزان خطای جعبه‌های محدودکننده طی آموزش به تدریج کاهش می‌یابد. نمودار 'train/cls_loss' نشان می‌دهد میزان خطای طبقه‌بندی نیز طی آموزش به تدریج کاهش می‌یابد. نمودار 'train/df_l_loss' نیز نشان‌دهنده کاهش خطای مربوط به تابع فاصله توزیع است. نمودارهای 'metrics/precision(B)' و 'metrics/recall(B)' به ترتیب دقت و بازخوانی مدل را در مجموعه داده آموزش نشان می‌دهند. همان‌طور که مشاهده می‌شود، هر دو معیار طی آموزش به تدریج افزایش می‌یابند.

نمودارهای ردیف دوم (val): این نمودارها، عملکرد مدل را در مجموعه داده اعتبارسنجی نشان می‌دهند. نمودارهای 'val/box_loss'، 'val/cls_loss' و 'val/df_l_loss' به ترتیب میزان خطای جعبه‌های محدودکننده، طبقه‌بندی و تابع فاصله توزیع را

در مجموعه داده اعتبارسنجی نشان می‌دهند. نمودارهای 'metrics/mAP50(B)' و 'metrics/mAP50-95(B)' به ترتیب میانگین دقت میانگین را در آستانه ۵۰ درصد و ۹۵-۵۰ درصد در مجموعه داده اعتبارسنجی نشان می‌دهند. همان‌طور که مشاهده می‌شود، هر دو معیار طی آموزش به تدریج افزایش می‌یابند.

به طور کلی، این نمودارها نشان می‌دهند مدل طی فرایند آموزش عملکرد خوبی داشته و توانسته است به دقت و بازخوانی قابل قبولی در مجموعه داده‌های آموزش و اعتبارسنجی دست یابد.

شکل ۱۴ نتایج ارزیابی مدل YOLO را با استفاده از چهار معیار مختلف نشان می‌دهد. این معیارها شامل میانگین دقت میانگین (mAP) در آستانه ۵۰ درصد (mAP50)، میانگین دقت میانگین در آستانه ۹۵-۵۰ درصد (mAP50-95)، بازخوانی و دقت هستند.



شکل ۱۴. نتایج ارزیابی مدل YOLO

همان‌طور که مشاهده می‌شود، مدل عملکرد بسیار خوبی در تشخیص علائم ترافیکی دارد. میانگین دقت میانگین مدل در آستانه ۵۰ درصد برابر با ۹۳/۵۲ درصد است. این موضوع نشان می‌دهد مدل به طور کلی دقت زیادی در تشخیص علائم ترافیکی دارد. همچنین، میانگین دقت میانگین مدل در آستانه ۹۵-۵۰ درصد برابر با ۸۱/۱۶ درصد است. این موضوع نشان می‌دهد مدل در تشخیص علائم ترافیکی در سطوح مختلف آستانه طبقه‌بندی نیز عملکرد خوبی دارد.

بازخوانی مدل برابر با ۸۶/۶۱ درصد است. این موضوع نشان می‌دهد مدل توانایی بالایی در تشخیص همه نمونه‌های مثبت علائم ترافیکی دارد. دقت مدل نیز برابر با ۹۴/۳۱ درصد است. این موضوع نشان می‌دهد مدل تعداد کمی از نمونه‌های منفی را به اشتباه به عنوان نمونه‌های مثبت طبقه‌بندی می‌کند.

نتایج به دست آمده از این پژوهش نشان می‌دهند استفاده از هوش مصنوعی و بینایی کامپیوتر می‌تواند تأثیر بسزایی در بهینه‌سازی سیاست‌های مدیریت ترافیک داشته باشد. مدل پیشنهادی می‌تواند به عنوان یک راهکار مؤثر برای نظارت هوشمند بر ترافیک شهری مورد استفاده قرار گیرد.

۵. نتیجه‌گیری

در این مقاله، تأثیر استفاده از هوش مصنوعی و بینایی کامپیوتر در بهینه‌سازی سیاست‌های مدیریت ترافیک در شهرهای هوشمند مورد بررسی قرار گرفت. مدل YOLOv8 به عنوان یک راهکار مؤثر برای تشخیص علائم راهنمایی و رانندگی معرفی شد و عملکرد آن در این زمینه ارزیابی شد. نتایج نشان داد این مدل توانایی تشخیص علائم ترافیکی را با دقت قابل قبولی دارد و می‌تواند در سیستم‌های مدیریت هوشمند ترافیک مورد استفاده قرار گیرد. این توانایی امکان بهبود نظارت بر جریان ترافیک،

شناسایی تخلفات و ارائه هشدارهای به‌موقع به رانندگان را فراهم می‌آورد. علاوه بر این، استفاده از YOLOv8 می‌تواند به توسعه سیستم‌های کمک‌راننده پیشرفته‌تر و افزایش ایمنی جاده‌ها کمک کند. با این حال، مقاله چالش‌هایی را نیز در تشخیص دقیق برخی از کلاس‌های علائم ترافیکی نشان داد نیازمند توجه بیشتر در تحقیقات آینده است.

با این حال، برای بهبود عملکرد مدل و توسعه روش‌های مؤثرتر در مدیریت ترافیک، پیشنهاد می‌شود که در تحقیقات آینده استفاده از مدل‌های یادگیری عمیق پیشرفته‌تر، مد نظر قرار گیرد. همچنین، افزایش تنوع داده‌های آموزشی با در نظر گرفتن شرایط مختلف آب‌وهوایی، نورپردازی و انسداد، می‌تواند به افزایش استحکام و تعمیم‌پذیری مدل کمک کند. علاوه بر این، پیاده‌سازی مدل روی سخت‌افزارهای سبک و کم‌مصرف، امکان استفاده گسترده‌تر آن در سیستم‌های جاسازی شده و خودروهای خودران را فراهم می‌سازد.

در نهایت، این پژوهش نشان داد هوش مصنوعی و بینایی کامپیوتر نقش مهمی در توسعه شهرهای هوشمند و بهبود سیستم‌های حمل‌ونقل ایفا می‌کنند. با ادامه تحقیقات و توسعه فناوری‌های مرتبط، انتظار می‌رود که شاهد بهبود قابل توجهی در کارایی، ایمنی و پایداری سیستم‌های حمل‌ونقل شهری باشیم.

منابع

1. Thapliyal N, Aeri M, Namdev D, Kukreja V, Sharma R. YOLOv8 Enhanced: Pioneering Accuracy in Traffic Sign Detection and Classification. In: 2024 IEEE 9th International Conference for Convergence in Technology (I2CT). IEEE; 2024. p. 1–4. Available from: <https://doi.org/10.1109/i2ct61223.2024.10543354>
2. Belli L, Cilfone A, Davoli L, Ferrari G, Adorni P, Di Nocera F, et al. IoT-enabled smart sustainable cities: Challenges and approaches. *Smart Cities*. 2020;3(3):1039-71.
3. Scuotto V, Ferraris A, Bresciani S. Internet of Things: Applications and challenges in smart cities: a case study of IBM smart city projects. *Bus Process Manag J*. 2016;22(2):357-67.
4. Arasteh H, Hosseinezhad V, Loia V, Tommasetti A, Troisi O, Shafie-Khah M, et al. IoT-based smart cities: A survey. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC). IEEE; 2016. p. 1-6.
5. Tukker A. Product services for a resource-efficient and circular economy—a review. *J Clean Prod*. 2015;97:76-91.
6. Gärling T, Schuitema G. Travel demand management targeting reduced private car use: effectiveness, public acceptability and political feasibility. *J Soc Issues*. 2007;63(1):139-53.
7. Byttner S, Rögvaldsson T, Svensson M. Consensus self-organized models for fault detection (COSMO). *Eng Appl Artif Intell*. 2011;24(5):833-9.
8. Pillai AS. Traffic management: Implementing AI to optimize traffic flow and reduce congestion. *J Emerg Technol Innov Res*. 2024;11(7).
9. Ban X, Wang H, Chen T, Wang Y, Xiao Y. Monocular visual odometry based on depth and optical flow using deep learning. *IEEE Trans Instrum Meas*. 2020;70:1-19.
10. Wei L, Guo D, Chen Z, Yang J, Feng T. Forecasting short-term passenger flow of subway stations based on the temporal pattern attention mechanism and the long short-term memory network. *ISPRS Int J Geo-Inf*. 2023;12(1):25.
11. Eurostat. Shedding Light on Energy in the EU-A Guided Tour of Energy Statistics; Technical Report; Eurostat: Luxembourg, 2020.
12. Rahman R, Bin Azad Z, Bakhtiar Hasan M. Densely-populated traffic detection using YOLOv5 and non-maximum suppression ensembling. In: Proceedings of the International Conference on Big Data, IoT, and Machine Learning: BIM 2021. Singapore: Springer Singapore; 2021. p. 567-78.
13. Chen L, Englund C. Cooperative intersection management: A survey. *IEEE Trans Intell Transp Syst*. 2015;17(2):570-86.
14. Englund C, Chen L, Voronov A. Cooperative speed harmonization for efficient road utilization. In: 2014 7th International Workshop on Communication Technologies for Vehicles (Nets4Cars-Fall). IEEE; 2014. p. 19-23.
15. European Environment Agency. Final Energy Consumption in Europe by Mode of Transport; Technical Report; Copenhagen, Denmark, 2019.
16. Arora A, Jain A, Yadav D, Hassija V, Chamola V, Sikdar B. Next generation of multi-agent driven smart city applications and research paradigms. *IEEE Open J Commun Soc*. 2023;4:2104-21.
17. Badidi E, Moumane K, El Ghazi F. Opportunities, applications, and challenges of edge-AI enabled video analytics in smart cities: a systematic review. *IEEE Access*. 2023;11:80543-72.
18. Rizwan P, Suresh K, Babu MR. Real-time smart traffic management system for smart cities by using Internet of Things and big data. In: 2016 International Conference on Emerging Technological Trends (ICETT). IEEE; 2016. p. 1-7.
19. Adewopo V, Elsayed N, ElSayed Z, Ozer M, Wangia-Anderson V, Abdelgawad A. AI on the Road: A Comprehensive Analysis of Traffic Accidents and Autonomous Accident Detection System in Smart Cities. In: 2023 IEEE 35th International Conference on Tools with Artificial Intelligence (ICTAI). IEEE; 2023. p. 501-6.
20. Apolo-Apolo OE, Martínez-Guanter J, Egea G, Raja P, Pérez-Ruiz M. Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *Eur J Agron*. 2020;115:126030.
21. World Health Organization. Global status report on road safety 2018. World Health Organization; 2019.
22. European Commission. State of the Union: Commission raises climate ambition; 2020.

23. Zhao C, Wang X, Lv Y, Tian Y, Lin Y, Wang FY. Parallel transportation in TransVerse: From foundation models to DeCAST. *IEEE Trans Intell Transp Syst.* 2023;24(12):15310-27.
24. Barrachina J, Garrido P, Fogue M, Martinez FJ, Cano JC, Calafate CT, et al. Reducing emergency services arrival time by using vehicular communications and Evolution Strategies. *Expert Syst Appl.* 2014;41(4):1206-17.
25. Englund C, Chen L, Ploeg J, Semsar-Kazerooni E, Voronov A, Bengtsson HH, et al. The grand cooperative driving challenge 2016: boosting the introduction of cooperative automated vehicles. *IEEE Wirel Commun.* 2016;23(4):146-52.
26. European Commission. EU Road Safety Policy Framework 2021–2030—Next Steps towards “Vision Zero”. 2019.
27. Manika S. Mechanisms for Innovative-Driven Solutions in European Smart Cities. *Smart cities.* 2020, 3, 527–540
28. Bešinović N, De Donato L, Flammini F, Goverde RM, Lin Z, Liu R, et al. Artificial intelligence in railway transport: Taxonomy, regulations, and applications. *IEEE Trans Intell Transp Syst.* 2021;23(9):14011-24.
29. Cui Q, Wang Y, Chen KC, Ni W, Lin IC, Tao X, et al. Big data analytics and network calculus enabling intelligent management of autonomous vehicles in a smart city. *IEEE Internet Things J.* 2018;6(2):2021-34.
30. Koshniharova D, Mihovska A, Koleva P, Poulkov V. Data-driven interactive crowd management systems for Metaverse scenarios. In: 2022 25th International Symposium on Wireless Personal Multimedia Communications (WPMC). IEEE; 2022. p. 549-54.
31. Englund C, Aksoy EE, Alonso-Fernandez F, Cooney MD, Pashami S, Åstrand B. AI perspectives in Smart Cities and Communities to enable road vehicle automation and smart traffic control. *Smart Cities.* 2021;4(2):783-802.
32. Humayun M, Afsar S, Almufareh MF, Jhanjhi NZ, AlSuwailem M. Smart traffic management system for metropolitan cities of kingdom using cutting edge technologies. *J Adv Transp.* 2022;2022(1):4687319.
33. Gharrawi HA, Yaghoub MB. Traffic Management in Smart Cities Using the Weighted Least Squares Method. *arXiv preprint.* 2022. Available from: <https://arxiv.org/abs/2205.00346>
34. van der Meulen J, Mukhtar-Landgren D, Koglin T. Modernity, mobility, and acceleration: cycling as the blind spot in Swedish transport innovation. *Urban, Planning and Transport Research.* 2023;11(1):2261534.
35. Singh S, Singh J, Goyal SB, Sehra SS, Ali F, Alkhafaji MA, et al. A novel framework to avoid traffic congestion and air pollution for sustainable development of smart cities. *Sustainable Energy Technologies and Assessments.* 2023;56:103125.
36. Aramrattana M, Larsson T, Jansson J, Englund C. Dimensions of cooperative driving, ITS and automation. In: 2015 IEEE Intelligent Vehicles Symposium (IV). IEEE; 2015. p. 144-9.
37. Gupta R, Verma A, Kukreja V, Sharma R. Enhancing Road Safety and ITS Efficiency: A Comprehensive Evaluation of Traffic Sign Detection using YOLOv8. In: 2024 International Conference on Emerging Technologies in Computer Science for Interdisciplinary Applications (ICETCS). IEEE; 2024. Available from: <https://doi.org/10.1109/icetcs61022.2024.10543721>
38. Kaur A, Kukreja V, Thapliyal N, Aeri M, Sharma R, Hariharan S. An Improved YOLOv8 Model for Traffic Sign Detection and Classification. In: 2024 3rd International Conference for Innovation in Technology (INOCON). IEEE; 2024. Available from: <https://doi.org/10.1109/inocon60754.2024.10511576>
39. Zhang Y, Liu H, Dong D, Duan X, Lin F, Liu Z. DPF-YOLOv8: Dual Path Feature Fusion Network for Traffic Sign Detection in Hazy Weather. *Electronics.* 2024;13:4016. Available from: <https://doi.org/10.3390/electronics13204016>
40. Choudhary N, Sharma R, Upadhyay D, Verma A, Jain V. Enhanced Traffic Sign Recognition Using Advanced YOLOv8 Model. In: 2023 4th International Conference on Intelligent Technologies (CONIT). IEEE; 2024. Available from: <https://doi.org/10.1109/conit61985.2024.10626450>

41. Sohan M, Sai Ram T, Rami Reddy CV. A review on YOLOv8 and its advancements. In: International Conference on Data Intelligence and Cognitive Informatics. Singapore: Springer Singapore; 2024. p. 529-45.
42. Yang G, Wang J, Nie Z, Yang H, Yu S. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention. *Agronomy*. 2023;13(7):1824.