

بهبود دقت شناساگرهای خرابی‌های جاده با استفاده از داده افزایی‌های سنتی و داده افزایی جعبه مرزی اشیاء

نیما آقایان مشهدی^۱ عبدالله امیرخانی^۲

۱- دانش آموخته کارشناسی ارشد- دانشکده مهندسی خودرو- گروه برق و الکترونیک- دانشگاه علم و صنعت ایران- تهران- ایران

Nima_aghayan@auto.iust.ac.ir

۲- استادیار- دانشکده مهندسی خودرو- گروه برق و الکترونیک- دانشگاه علم و صنعت ایران - تهران- ایران

Amirkhani@iust.ac.ir

چکیده: تشخیص خودکار خرابی‌های جاده‌ها به فرایند تعمیر و نگهداری از آن‌ها سرعت می‌بخشد و از تصادفات رانندگی بسیاری جلوگیری می‌نماید. در این مقاله برای بررسی عملکرد شناساگرهای خرابی جاده با استفاده از YOLOv5، ده شناساگر در پایگاه داده RDD2020 توسعه داده شد. با شبیه‌سازی شرایط محیطی مانند تابش شدید نور خورشید و سایه بر سطح جاده مشخص گردید شناساگرهای خرابی جاده در این شرایط عملکرد خوبی ندارند. در ادامه با استفاده از تکنیک‌های داده افزایی سنتی، استحکام شناساگرهای خرابی جاده در شرایط محیطی مختلف بهبود داده شد. با استفاده از این تکنیک‌ها یک پایگاه صحت سنجی برای بررسی عملکرد شناساگرها در شرایط محیطی مختلف در پایگاه داده RDD2020 ایجاد شد. به منظور حل چالش کمبود داده در این پایگاه از تکنیک داده افزایی جعبه مرزی و ترکیب آن با تلفیق پوآسن اصلاح شده استفاده شد. در این روش تعداد نمونه‌های کلاس پایگاه داده مرجع در کلاس چاله و ترک افقی افزایش یافت. نتایج این پژوهش نشان می‌دهد که آموزش شناساگرها با داده‌های جدید، موجب بهبود عملکرد آن‌ها در معیار F1-Score و mAP به ترتیب به میزان ۳۳ و ۵۰ درصد شده است.

واژه‌های کلیدی: شناساگر اشیاء، خرابی‌های جاده، داده افزایی، پایگاه داده

نوع مقاله: پژوهشی

DOI: 10.61186/jiaeee.21.3. 139

تاریخ ارسال مقاله: ۱۴۰۱/۱۱/۰۴

تاریخ پذیرش مشروط: ۱۴۰۲/۰۶/۰۴

تاریخ پذیرش مقاله: ۱۴۰۲/۰۷/۰۹

نام نویسنده‌ی مسئول: دکتر عبدالله امیرخانی

نشانی نویسنده‌ی مسئول: ایران - تهران - میدان رسالت - خیابان فرجام - دانشگاه علم و صنعت ایران - دانشکده‌ی مهندسی خودرو

۱- مقدمه

سیستم حمل‌ونقل یکی از ارکان اساسی اقتصاد یک کشور است [۱]. مسیرها تحت تأثیر شرایط آب و هوایی و حجم ترافیک عبوری آسیب می‌بینند. این آسیب‌ها در جاده‌ها به صورت ترک و چاله‌ها آشکار می‌شوند [۲]. کیفیت پایین جاده‌ها، موجب تصادفات رانندگی و کاهش سرعت سیستم حمل‌ونقل جاده‌ای می‌شود. هزینه نگهداری از جاده‌ها، با تعمیرات به موقع کاهش می‌یابد [۳]. جاده‌های آسفالت به صورت دوره‌ای بازرسی می‌شوند و با توجه به سطح خرابی‌های جاده، عملیات تعمیر انجام می‌شود. این بازرسی‌ها، زمان‌بر و پرهزینه هستند [۴]. در برخی کشورها مانند کانادا و نیوزیلند، بررسی کیفیت جاده‌ها توسط دستگاه‌های خودکار انجام می‌شود. روش‌های خودکار، خطا و هزینه شناسایی را کاهش و سرعت بازرسی و تعمیر خرابی‌ها را افزایش می‌دهند. این روش‌ها از حسگرهای لرزشی، لیزری و تکنیک‌های پردازش تصویر استفاده می‌کنند. حسگرهای لیزری قیمت بالایی دارند و با توجه به پوشش محدود و سرعت پایین نمونه‌برداری موجب ترافیک می‌شوند [۵]. حسگرهای لرزشی مانند ژيروسکوپ‌ها و شتاب سنسورها می‌توانند چاله‌ها را با سنجش تغییرات لرزشی خودرو شناسایی کنند [۶]. دقت حسگرهای لرزشی با توجه به شرایط فیزیکی خودرو در سرعت‌ها و مسیر مختلف پایین است. همچنین یک خودرو جهت تشخیص چاله باید درون چاله قرار گیرد. این مورد موجب افزایش خرابی سیستم تعلیق خودروی بازرسی جاده‌ای می‌شود و محدوده بررسی آسیب‌های جاده‌ای را کوچک می‌نماید [۷]. سازمان‌های نگهداری جاده‌ها، نیازمند رویکردهای خودکار، با قیمت پایین و دقت مناسب هستند [۴].

تصاویر یکی از منابع اصلی اطلاعات جاده‌ای هستند [۳]. با جمع‌آوری تصاویر جاده می‌توان کیفیت سطوح جاده را با استفاده از تکنیک‌های پردازش تصاویر سنجید [۷]. بینایی ماشین امروزه در بسیاری از کاربردهای تشخیص و طبقه‌بندی اشیاء استفاده می‌شود [۸]. با توجه به پیشرفت تکنیک‌های پردازش تصویر، ویژگی‌هایی همچون وجود ترک‌ها و موقعیت آن‌ها، در تصاویر قابل‌شناسایی است [۹]. اعمال رویکردهایی آستانه‌گذاری و تبدیل‌هایی همچون تبدیل موجک چند مقیاسی امکان شناسایی ترک‌ها و چاله‌ها در شرایط مناسب فراهم می‌سازد [۱۰، ۱۱]. الگوریتم‌های تشخیص لبه مانند سوبل^۱ [۱۲] و پرویت^۲ [۱۳] ... می‌توانند ترک‌ها را در شرایط روشنائی مناسب شناسایی کنند اما اختلالاتی همچون نویز، شرایط نوری متفاوت و محوشدگی تصاویر، دقت این الگوریتم‌ها را کاهش می‌دهند.

امروزه پردازش تصویر با استفاده از یادگیری عمیق و شبکه‌های عصبی پیچشی (CNN^۳) بهترین عملکرد را در شناسایی آسیب‌های جاده‌ای دارد [۱۴]. این الگوریتم‌ها پس از آموزش با داده‌های مختلف

می‌توانند عملیات تشخیص را به صورت خودکار انجام دهند. با ترکیب روش‌های پردازش تصویر و یادگیری عمیق می‌توان رویکردی مناسب جهت تشخیص خرابی‌های جاده‌ای توسعه داد. این روش‌ها نیازمند حجم بالایی از داده‌ی تصویری هستند. در سال‌های اخیر استفاده از دوربین‌های ارزان قیمت همچون دوربین‌های تلفن همراه، جهت تشخیص آسیب‌های جاده‌ای مورد توجه قرار گرفته است. در سال ۲۰۱۸ مائدا و همکاران [۱۴] با ایجاد یک پایگاه داده از آسیب‌های جاده‌ای ژاپن، داده‌های مورد نیاز برای ایجاد مدل‌های شناساگر اولیه در این زمینه را فراهم کردند. این پایگاه داده توسط یک دوربین تلفن همراه نصب شده بر داشبورد خودرو، جمع‌آوری شده است. تعداد تصاویر این پایگاه داده در کلاس چاله بسیار محدود است. همچنین بررسی‌ها مشخص نمود، شناساگرهای این پایگاه، در شرایط واقعی دقت پایینی دارند. همچنین تفاوت تصاویر بین ژاپن و دیگر کشورها موجب عملکرد ضعیف مدل در دیگر کشورها می‌شود [۴]. با توجه به این مسائل پایگاه داده RDD2020 در [۱۵] ارائه شد. داده‌های این پایگاه از سه کشور ژاپن، هند و چک ایجاد شده‌اند. این داده‌ها به صورت کلی از تناسب بهتری برخوردار هستند. در پایگاه داده

RDD2020 زاویه دید دوربین رو به جاده است. در این زاویه دید، شناساگر می‌تواند ترک‌ها و چاله‌ها را در قسمت‌های مختلف جاده شناسایی نماید. این خرابی‌ها اندازه بسیاری کوچکی نسبت به دیگر عوامل در تصویر دارند. همچنین تعداد نمونه‌های برخی کلاس‌ها نسبت به دیگر کلاس‌ها کمتر است. ایجاد یک شناساگر قدرتمند با توجه به این شرایط دشوار است. یک شناساگر جامع، دقیق و مبتنی بر الگوریتم‌های یادگیری عمیق نیازمند داده‌هایی با تنوع بالا و شرایط نوری متفاوت است. برخی از شرایط واقعی مانند سایه‌های مختلف، بازتاب نور خورشید و سطوح روشنائی مختلف در پایگاه داده RDD2020 به تعداد کافی وجود ندارند. این شرایط می‌توانند عملکرد مدل‌های شناساگر را به شدت تحت تأثیر قرار دهند.

رویکردهای ارائه شده در اکثر متون، عمدتاً بر افزایش دقت شناساگرهای خرابی جاده‌ای در شرایط معمولی تمرکز داشته‌اند. این شناساگرها در شرایط محیطی و میدانی مختلف آزمایش نشده‌اند و چنین عواملی می‌تواند دقت آن‌ها را در شرایط واقعی کاهش دهند. برای مثال، جهت بررسی تأثیر سایه‌ها بر تصاویر جاده‌ای باید شرایط نوری مختلف در زمان‌های مختلف ایجاد شود. این تصاویر باید در بازه زمانی محدود جمع‌آوری شود و توسط نیروی انسانی، نشان‌گذاری شوند. ایجاد یک پایگاه داده مقاوم نیازمند جمع‌آوری داده‌ها در تمامی شرایط عملیاتی شناساگر است. آموزش مدل با استفاده از پایگاه مقاوم، مدلی مقاوم در برابر تغییرات محیطی ایجاد می‌کند. ایجاد یک پایگاه داده مقاوم به صورت طبیعی امری زمان‌بر و بسیار پرهزینه است. یکی از رهیافت‌های ایجاد پایگاه داده‌ی مقاوم، استفاده از تکنیک‌های داده‌افزایی است. این تکنیک‌ها تعمیم‌پذیری شناساگرها را در شرایط

می‌شود [۱۹]. معماری‌های این شبکه‌ها در حالت کلی به دو دسته R-CNN [۱۹] و YOLO [۲۰] دسته‌بندی می‌شود. معماری‌های R-CNN در طول زمان بهبود یافت و نسخه‌های سریع‌تر آن همچون Fast R-CNN و Faster R-CNN [۲۱، ۲۲] ایجاد شده است. این معماری‌ها گرچه از نظر سرعت بهبودهایی داشته‌اند اما مناسب دستگاه‌های متحرک و با توان پردازشی پایین نیستند. YOLO خانواده‌ی دیگری از شناساگرهای اشیاء است. نسخه‌های مختلفی همچون (YOLOv3, YOLOv4, YOLOv5, ...) [۲۳-۲۵] با معماری‌ها و تکنیک‌های مختلفی ایجاد شده‌اند. در این معماری تصویر به سلول‌هایی بخش‌بندی می‌شود. ویژگی‌های تصویر از این بخش‌ها استخراج شده و نتایج تشخیص بر اساس این ویژگی‌ها ایجاد می‌گردد [۲۶، ۲۷]. شناساگرهای مبتنی بر YOLO نسبت به شناساگرهای R-CNN از سرعت بالاتری برخوردار هستند و می‌توان از آن‌ها در سیستم‌هایی با توان پردازشی پایین استفاده کرد.

پژوهش‌های بسیاری از شناساگرهای مبتنی بر یادگیری عمیق برای تشخیص خرابی‌های جاده استفاده کرده‌اند. بر اساس پایگاه داده RDD2018 یانبو وانگ و همکاران [۲۸] از Faster R-CNN و SSD [۲۹] بر مبنای مدل‌های ResNet [۳۰] و VGG [۳۱] برای تشخیص خرابی‌های جاده استفاده کرده‌اند. آن‌ها همچنین با تجمیع نتایج مدل‌ها دقت تشخیص خرابی‌های جاده را افزایش دادند. نویسندگان در [۳۲] با استفاده از Faster R-CNN و داده‌کاوی، نتایج تشخیص آسیب‌های جاده را بهبود دادند. در مرجع [۳۳] با ترکیب Faster R-CNN و تکنیک جنگل تصادفی^۶ دقت شناساگر خرابی‌های جاده بهبود داده شده است. در [۳۴] از شبکه‌های مولد متخاصم (GANs^۷) برای ایجاد چاله‌های مصنوعی استفاده کردند. آن‌ها با استفاده از PG-GAN [۳۶] چاله‌ها را ایجاد و با تلفیق پواسن^۸ [۳۷] آن‌ها را با تصاویر اصلی ترکیب کردند. نویسندگان مرجع [۳۸] با بررسی انواع مدل‌های SSD Inception و Faster R-CNN در یافتند که V2 [۳۹] بهترین عملکرد را در زمینه تشخیص خرابی‌های جاده دارند. در [۴۰] از YOLOv3 جهت تشخیص آسیب‌های جاده استفاده شده است.

در زمینه‌ی تشخیص آسیب‌های جاده علاوه بر مدل‌های مبتنی بر یادگیری عمیق، از روش مبتنی بر یادگیری ماشین و پردازش تصویر نیز استفاده می‌شود. به عنوان نمونه چون و همکاران [۴۱] جهت طبقه‌بندی آسیب‌های جاده از یک طبقه‌بند بیز^۹ استفاده کرده‌اند. در [۴۲] با استفاده از فیلترهای گبور^{۱۰} ترک‌های جاده را شناسایی کردند. نویسندگان [۴۳] یک مدل مبتنی بر یادگیری ماشین را برای تشخیص ترک‌های سطوح بتنی توسعه داده است.

۲-۱- پایگاه‌های داده

پایگاه داده RDD2018 [۱۴]، زمینه تشخیص خرابی‌های جاده را با استفاده از دوربین‌های تلفن همراه ایجاد نمود. آن‌ها در این پایگاه،

محیطی مختلف بهبود می‌دهند. همچنین در شرایطی که داده‌ها محدود است از بیش برآزش مدل‌های شناساگر جلوگیری می‌کنند. در این پژوهش از داده‌افزایی سنتی به منظور ایجاد داده‌های آموزشی مقاوم استفاده شده است. این داده‌ها شرایط محیطی همچون وجود سایه اشیاء بر سطح جاده، تابش شدید خورشید و تغییرات روشنایی را شامل می‌شوند. این شرایط در پژوهش‌های مشابه جهت بهبود دقت شناساگرها در نظر گرفته نشده‌اند.

در این پژوهش جهت بررسی عملکرد شناساگرهای خرابی جاده در شرایط محیطی مختلف، انواع تبدیل‌ها بر تصاویر پایگاه داده RDD2020 اعمال شده است. این تبدیل‌ها تصاویری با سایه‌ها و شرایط نوری مختلف ایجاد می‌کنند. استفاده از رویکردهای داده‌افزایی موجب بهبود مقاومت شناساگرها با داده‌های محدود می‌شود. همچنین این پژوهش نشان می‌دهد رویکرد داده‌افزایی جعبه مرزی (BBA^{۱۱})، دقت شناساگر خرابی‌های جاده را در کلاس‌ها خرابی جاده با نمونه‌های محدود افزایش می‌دهد. تا آنجایی که در مقالات مشخص است این اولین پژوهشی است که عملکرد مدل‌های شناساگر خرابی جاده را در شرایط محیطی مختلف بررسی و بهبود می‌دهد.

- با استفاده از انواع روش‌های داده‌افزایی سنتی استحکام شناساگرهای خرابی جاده در شرایط محیطی مختلف بهبود داده شده است.
- دقت شناساگر خرابی‌های جاده در کلاس‌های ترک افقی و چاله با رویکرد داده‌افزایی جعبه مرزی و تلفیق پواسن اصلاح شده (MPB^{۱۲}) بهبود یافته است.
- عملکرد شناساگرهای خرابی جاده در شرایط محیطی همچون سایه، نور شدید خورشید و تغییرات روشنایی در پایگاه داده RDD2020 بررسی شده است.

ادامه این مقاله به این شکل نظم‌دهی شده است. بخش دوم به مروری از مقالات موجود در زمینه تشخیص آسیب‌های جاده پرداخته می‌شود. در بخش سوم رویکرد پیشنهادی جهت ایجاد شرایط مختلف محیطی بررسی می‌شود. همچنین در این بخش روش‌های داده‌افزایی اعمالی بر مدل‌ها شرح می‌گردد. بخش چهارم نتایج مدل‌ها در شرایط مختلف بررسی می‌شوند. بخش نهایی نیز به نتیجه‌گیری و پیشنهادها اختصاص داده شده است.

۲- مروری بر ادبیات

یادگیری عمیق در همه زمینه‌ها از جمله تشخیص آسیب‌های جاده در حال پیشرفت است. این روش‌ها در شناسایی و پیش‌بینی انواع الگو و روندها استفاده شده است [۱۶]. شناسایی عوامل جاده‌ای همچون خرابی‌های جاده‌ای و شناسایی خطوط رانندگی موجب افزایش ایمنی و توسعه‌ی صنعت خودروهای خودران شده است [۱۶، ۱۸]. CNN اصلی‌ترین شبکه یادگیری عمیق است که در زمینه تشخیص اشیاء استفاده

تشخیص مدل در شرایط واقعی ایجاد شده‌اند توصیف می‌گردد. در ادامه روش داده افزایی جعبه مرزی شرح می‌گردد.

۳-۱- شناساگر YOLOv5

YOLO یکی از شناخته‌شده‌ترین الگوریتم شناسایی اشیاء به صورت یک مرحله‌ای است [۴۶]. معماری YOLO از سه بخش: ستون فقرات^{۱۲}، گردن^{۱۳} و سر^{۱۴} شبکه تشکیل شده است. در قسمت ستون فقرات، شبکه ویژگی‌ها، بر اساس تصاویر ورودی تجمیع و ایجاد می‌شوند. در گردن این ویژگی‌ها ترکیب می‌شوند و سر با استفاده از این ویژگی‌ها محدوده‌ی اشیاء و کلاس آن‌ها را مشخص می‌نماید.

در YOLOv5 از شبکه فضایی مقطعی (CSPN^{۱۵}) [۴۷] به عنوان ستون فقرات استفاده می‌شود. این ستون فقرات مشکل اطلاعات تکراری گرادیان^{۱۶} را در ستون فقرات‌های بزرگ حل می‌کند و با ادغام تغییرات گرادیان در نقشه ویژگی‌ها، سرعت و دقت تشخیص مدل را افزایش می‌دهد [۲۶]. در قسمت گردن شبکه از (PANet^{۱۷}) [۴۸] استفاده می‌شود. این شبکه می‌تواند الگوریتمی سریع‌تر نسبت به معماری شبکه هرمی ویژگی (FPN^{۱۸}) [۴۹] ایجاد کند. سر شبکه - YOLOv5 نیز همانند YOLOv3 و YOLOv4 است [۲۶]. معماری YOLOv5 در شکل (۱) نشان داده شده است. در این معماری در لایه های میانی از تابع فعال‌ساز سیگموئید خطی (SiLU^{۱۹}) و تابع سیگموئید برای لایه تشخیص استفاده شده است. تابع SiLU مقایسه با واحد خطی اصلاح شده (ReLU^{۲۰}) عملکرد بهتری دارد [۵۰]. در YOLOv5 امکان داده افزایی در فرایند آموزش مدل وجود دارد. این ویژگی استحکام مدل را در برابر تغییرات محیطی در پایگاه داده صحت سنجی افزایش می‌دهد. YOLOv5 شامل پنج مدل است که عمق شبکه و اندازه آن‌ها از YOLOv5n تا YOLOv5x افزایش می‌یابد.

با توجه به بررسی صورت گرفته در پژوهش [۵۱] عملکرد YOLOv5 از Faster R-CNN و YOLOv3 در امر تشخیص آسیب های جاده‌ای بهتر بوده است؛ بنابراین شناساگر YOLOv5 جهت تشخیص آسیب‌های جاده‌ای در این پژوهش انتخاب شده است. همچنین برای ایجاد یک مدل بلادرنگ از YOLOv5n به عنوان معماری پایه استفاده شده است. این معماری کمترین عمق و تعداد پارامترها و بیشترین سرعت را در بین شناساگرهای YOLOv5 دارد. استفاده از شناساگرهای مبتنی بر YOLO، توسعه سریع مدل‌های تشخیص دقیق و بلادرنگ را ممکن می‌سازد. معماری YOLOv5n می‌تواند با سرعت ۱۱۰ فریم بر ثانیه خرابی‌های جاده‌ای را تشخیص دهد. این معماری دارای ۱٫۹ میلیون پارامتر است. با توجه به تعداد پارامترها و سرعت پردازش، مدل YOLOv5n جهت توسعه شناساگرهای بلادرنگ در این پژوهش انتخاب شده است.

خرابی‌های جاده در هشت کلاس طبقه‌بندی نمودند. این طبقه‌بندی در جدول (۱) همراه با تعداد نشان‌های هر کلاس شرح شده است. پایگاه داده‌ی RDD2018 شامل ۹۰۵۳ تصویر و ۱۵۴۳۵ نشان است. این پایگاه در کلاس‌های مختلف متعادل نیست و تعداد نمونه‌های برخی کلاس‌ها بسیار پایین است. با توجه به این دلایل شناساگر ارائه شده توسط نویسندگان [۱۴] حساسیت^{۱۱} پایینی در بیشتر کلاس‌ها دارد.

جدول (۱): طبقه‌بندی کلاس‌ها در RDD2018


نوع آسیب جاده‌ای	نام کلاس	تعداد نمونه
ترک طولی افقی	D00	۲۷۶۸
	D01	۳۷۸۹
	D10	۷۴۲
ترک طولی عرضی	D11	۶۳۶
	D20	۲۵۴۱
ترک سوسماری	D40	۴۰۹
چاله	D43	۸۱۷
رنگ‌رفتگی خطوط عابر	D44	۳۷۳۳
رنگ‌رفتگی خطوط جاده		

آنکلو و همکاران [۴۴] تعداد داده‌های این پایگاه را افزایش دادند. نتایج پژوهش آن‌ها مشخص نمود که افزایش تعداد نمونه‌ها، موجب افزایش دقت و حساسیت شناساگر شده است. در مرجع [۴۵] با بازبینی RDD2018 و داده افزایی، تعداد نمونه‌های پایگاه داده را به میزان ۱۵۵۵۴ نمونه افزایش دادند. آن‌ها این پایگاه را RDD2019 نام‌گذاری کردند.


در سال ۲۰۲۰ پایگاه داده RDD2020 بر اساس پایگاه RDD2019 ایجاد شده است. تعداد تصاویر این پایگاه داده ۲۶۶۲۰ است. برخلاف پایگاه داده‌های قبلی این مجموعه، شامل چهار کلاس (D00, D10, D20, D40) است. بیشتر از یک‌سوم از تصاویر، شامل هیچ نوع آسیب و یا هیچ نشانی نیستند. همچنین توزیع کلاس‌ها در کشورهای هند، چک و ژاپن برابر نیست. این توزیع نامناسب، ایجاد یک مدل انتقال‌پذیر در همه‌ی کشورها را دشوار می‌سازد. ایجاد مدل‌های مقاوم در زمینه تشخیص آسیب‌های جاده، نیازمند تصاویری در ساعات مختلف روز و شرایط مختلف آب و هوایی است. همچنین جمع‌آوری داده در زمینه آسیب‌های جاده‌ای امری دشوار و زمان‌بر است. هیچ‌کدام از مقالات ارائه شده در زمینه تشخیص خرابی‌های جاده به بررسی تأثیر شرایط آب‌وهوایی و عوامل محیطی همچون سایه‌ها در امر شناسایی نپرداخته است. در این پژوهش با بررسی این شرایط و ارائه رویکردی با استفاده از داده افزایی، عملکرد این شناساگرها را در این شرایط بهبود می‌دهیم.

۳- روش پیشنهادی

در این بخش به بررسی شناساگر YOLOv5 [۲۳] در شناسایی خرابی جاده می‌پردازیم. سپس روش‌های داده افزایی که جهت افزایش قدرت



شکل (۱): معماری YOLOv5



شکل (۲): توزیع نشان‌های RDD2020

۳-۱-۳- داده افزایشی سنتی

داده افزایشی موجب ایجاد تنوع و افزایش داده‌ها می‌شود. با استفاده از این روش می‌توان مشکل بیش برآش را در آموزش مدل‌ها کاهش داد. جمع‌آوری و نشان‌گذاری داده‌ها در شرایط محیطی مختلف، دشوار و زمان‌بر است. تکنیک‌هایی همچون تغییر اندازه، معکوس کردن تصویر و بریدن تصادفی و ... می‌توانند تا حدی تنوع در داده‌های آموزشی ایجاد کنند. در این پژوهش با استفاده از ابزار آلبومنتیشن^[۵۶] این تکنیک‌ها در فرایند آموزش مدل قرار داده شده است. این تکنیک‌های داده افزایشی، در تصویر (۳) نشان داده شده است. همچنین از این تکنیک‌ها برای ایجاد داده‌های صحت سنجی جدید استفاده شده است. داده‌های جدید، عملکرد مدل را تحت شرایط متفاوت می‌سنجند.

۳-۲- آماده‌سازی داده‌ها

پایگاه داده RDD2020 شامل کشورهای هند، ژاپن و چک است. هشتاد درصد داده‌های این پایگاه برای آموزش مدل و بیست درصد داده‌های باقی‌مانده جهت صحت سنجی مدل‌ها استفاده شده است. توزیع تعداد نمونه‌ها و تصاویر پایگاه RDD2020 در شکل (۲) نشان می‌دهد بیشتر نمونه‌های این پایگاه از کشور ژاپن جمع‌آوری شده است. بررسی‌های پژوهش [۴] نشان می‌دهد استفاده از تمامی داده‌های این پایگاه موجب کاهش دقت شناساگرها شده است.

مدل‌های پایه این مقاله، ابتدا در پایگاه داده COCO^[۵۲] آموزش داده شده‌اند و سپس جهت آموزش شناساگرهای پایه خرابی‌های جاده استفاده می‌شوند. این امر زمان آموزش شناساگرها را کاهش می‌دهد. تمامی مدل‌های این پژوهش ابتدا به میزان ۳۰۰ اپاک با نرخ های آموزش $Lr0$ برابر با 0.00032 و $Lr1$ برابر 0.0012 آموزش داده شده‌اند. همچنین اندازه بچ 32 ^[۵۷] و بهینه ساز SGD ^[۵۸] برای آموزش انتخاب شده است.

۳-۳- داده افزایشی

شناساگرهای مبتنی بر یادگیری عمیق و شبکه‌های عصبی در حالت کلی مقاوم نیستند [۵۳]. آن‌ها تحت تأثیر تغییرات و یا اغتشاشات نامحسوس نتیجه نادرست ایجاد می‌کنند [۵۴]. تکنیک‌های داده افزایشی موجب تعمیم‌پذیری شناساگرها و بهبود عملکرد آن‌ها در شرایط واقعی می‌شود [۵۵]. در این بخش با استفاده از تکنیک‌های داده افزایشی سنتی و جعبه مرزی، کمبودهای پایگاه داده RDD2020 بهبود داده می‌شود.

۳-۲-۳- داده افزایشی جعبه مرزی



منبع



چرخش افقی



سیاه سفید



تغییر تضاد



نور شدید خورشید



CLAHE



سایه تضاد



محو تصویر

شکل (۳): انواع داده افزایشی‌های سنتی

در زمینه داده‌افزایی، تبدیل‌هایی مانند معکوس کردن افقی و عمودی، کل تصویر را تغییر می‌دهند. برخی تبدیل‌ها مخصوص جعبه مرزی اشیاء هستند. این جعبه مرزی نمایانگر مختصات اشیاء در تصاویر است. در این نوع داده افزایشی تبدیل‌ها فقط در محدوده‌ی شیء صورت می‌پذیرد. در این روش با اعمال تبدیل‌هایی همچون تغییر روشنایی، چرخش افقی و عمودی در محدوده‌ی شیء، تصاویر جدیدی با داده‌های اولیه ایجاد می‌شود [۵۷]. در این پژوهش داده‌های هر کشور را با توجه به تعداد نمونه‌های هر کلاس دسته‌بندی نمودیم.

در پایگاه داده‌ی ژاپن کلاس D40 کمترین تعداد نمونه را در بین تمامی کلاس‌ها دارد. این کلاس اندازه کوچک‌تری نسبت به دیگر خرابی‌های جاده دارد. در پایگاه داده هند، تعداد نمونه‌های کلاس D10 بسیار پایین است. در داده‌های کشور چک تعداد نمونه همه کلاس‌ها به‌صورت کلی پایین است. اگر کل پایگاه را در نظر بگیریم داده‌های کلاس D10 و D40 از همه کمتر هستند. با توجه به این مسائل، تعداد نمونه‌های کلاس D10 و D40 با استفاده از داده افزایشی جعبه مرزی افزایش می‌یابند. سه رویکرد داده افزایشی چرخش افقی، عمودی و ترکیب افقی، عمودی بر داده‌های کلاس‌های D10 و D40 انجام شده است. این روش تعداد داده‌های این کلاس‌ها را سه برابر می‌نماید.

انجام داده افزایشی جعبه مرزی به تنهایی موجب ایجاد تصاویری می‌شود که تفاوت‌های محسوس با تصاویر اصلی دارند. این شرایط ساختگی موجب یادگیری ویژگی‌های نادرست در شناساگرها می‌شود. در شکل (۴)، چرخش افقی کلاس D10 باعث برجستگی لبه‌های شیء در تصویر اصلی شده است. حل این چالش نیازمند یک الگوریتم تلفیق تصویر است.

تلفیق تصاویر کاربردهای فراوانی همچون حذف اشیاء ناخواسته در تصاویر، الصاق تصاویر پانوراما و چسباندن اشیاء به تصاویر به صورت طبیعی را دارد. در روش تلفیق پواسن از دامنه گرادین جهت تلفیق دو تصویر استفاده می‌شود. این الگوریتم به گونه‌ای تصاویر را با یکدیگر تلفیق می‌کند که گرادین بین دو تصویر متناسب باقی بماند.

روش تلفیق پواسن از مشکل نشت رنگی و نشت تصویر رنج می‌برد. در پژوهش [۵۸] با ارائه تلفیق پواسن اصلاح‌شده مشکل نشت رنگ را در تلفیق پواسن کاهش دادند و تصاویر طبیعی‌تری را ایجاد نمودند. داده‌های جدید ایجاد شده توسط داده افزایشی جعبه مرزی، دارای لبه‌هایی آشکار و غیر طبیعی هستند. این مشکل با استفاده فرایند MPB بهبود داده می‌شود. ابتدا تصویر بدون داده افزایشی به عنوان تصویر هدف و تصویر جدید ایجاد شده، به عنوان تصویر مرجع، در نظر گرفته می‌شوند. در ادامه با استفاده از رویکرد MPB محدوده‌ای از تصاویر که با استفاده از داده افزایشی جعبه مرزی تغییر داشته، با تصویر هدف تلفیق می‌شود. در این روش هر تصویر نیازمند یک ماسک است که محدوده تلفیق را مشخص نماید. فرایند ایجاد این ماسک و تلفیق تصاویر مرجع و هدف در شکل (۵) مشخص گردیده است.

آموزش داده افزایشی سنتی نیز در فرایند آموزش مدل‌ها استفاده شده است.

۴- بررسی نتایج

در این بخش نتایج انواع روش‌های داده افزایشی و تأثیر آن‌ها بر استحکام مدل‌های شناساگر بررسی می‌شود. در این پژوهش جهت بررسی عملکرد همه مدل‌ها، سنجش با استفاده از دو پایگاه داده صحت سنجی انجام می‌شود. در پایگاه صحت سنجی اول هیچ تبدیل یا تغییراتی بر داده‌ها اعمال نشده است. در پایگاه صحت سنجی دوم، داده‌هایی جدید با استفاده رویکردهای داده افزایشی سنتی ایجاد شده‌اند. در این داده‌ها شرایط محیطی مختلفی مانند سایه‌های مصنوعی، شدت روشنایی متفاوت و تغییرات کنتراست تصویر و... ایجاد شده است. تمامی آزمایش‌ها در این پژوهش در دو حالت همراه داده افزایشی همگام آزمودن (TTA^{۲۴}) و حالت معمولی صورت می‌پذیرند. عملیات داده افزایشی در همگام آزمودن موجب اعمال تبدیل‌های چرخش تصویر و افزایش اندازه تصویر به میزان ۳۰ درصد می‌شود. نتایج شناسایی مدل برای این تبدیل‌ها پیش از عملیات سرکوب غیر حداکثری (NMS^{۲۵}) با یکدیگر ترکیب می‌شود. عملیات TTA زمان پردازش را دو برابر می‌نماید.

۴-۱- مشخصه‌های سنجش

در این پژوهش یک تشخیص، زمانی صحیح شمرده می‌شود که کادر پیشنهادی مدل شناساگر، حداقل ۵۰ درصد از کادر داده‌های مرجع را دربر گیرد. این معیار به عنوان تقاطع بین اتحاد (IoU^{۲۶}) شناخته می‌شود. دقت نشان‌دهنده نسبت تعداد مثبت صحیح به کل تشخیص‌هایی است که مدل به عنوان مثبت شناسایی نموده است. این معیار با استفاده از معادله (۱) محاسبه می‌شود. در این معادله مثبت صحیح TP به معنای تشخیص درست یک آسیب جاده با $IoU > 0.5$ است. همچنین مثبت کاذب FP به معنای تشخیص نادرست یک محدوده به عنوان آسیب جاده‌ای، در صورتی که هیچ نوع آسیبی در آنجا موجود نیست. حساسیت معیاری است که نسبت بین تعداد تشخیص‌های مثبت صحیح به تعداد کل مثبت‌های صحیح و منفی‌های صحیح است. منفی کاذب FN، به معنی تشخیص نادرست مدل در محدوده‌ای که شی وجود دارد ولی به درستی شناسایی و طبقه‌بندی نمی‌شود. این معیار با استفاده از معادله (۲) محاسبه می‌گردد.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$



منبع

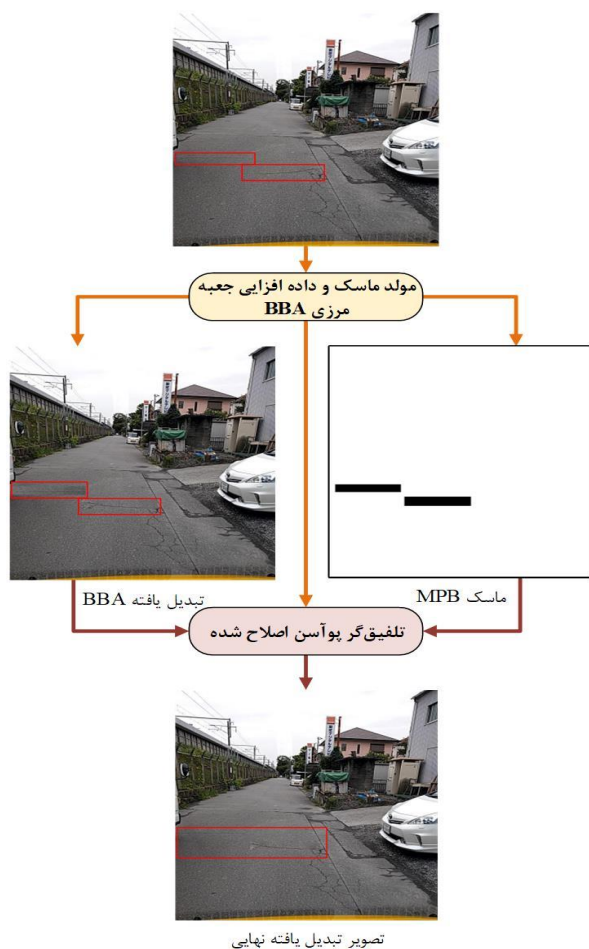


تبدیل یافته توسط BBA

شکل (۴) اثر چرخش افقی در تبدیل داده افزایشی جعبه مرزی

این ماسک با کوچک نمودن محدوده کادر شی تبدیل یافته ایجاد می‌شود. ابتدا با توجه به اندازه تصویر یک تصویر سفید به اندازه تصویر اصلی ایجاد می‌شود. سپس طول و عرض شی در مختصات تصویر با ضریب ۰.۲۵ کوچک می‌شود. محدوده‌ی این مختصات جدید در تصویر ماسک با پیکسل سیاه پر می‌شود. سپس نشان جدید تصویر تبدیل یافته ایجاد می‌شود. برخی داده‌ها در این روش کیفیت مناسبی ندارند و با بازبینی تصاویر از داده‌های آموزشی مدل‌ها حذف می‌شوند. شکل (۶) نمونه تصاویر داده افزایشی جعبه مرزی و فرایند تلفیق پواسن اصلاح شده را نشان می‌دهد. با استفاده از داده‌های جدید مدل‌های پایه به صورت تطبیقی به میزان ۲۰۰ اپیاک آموزش داده شدند. در این

جدول (۴) و (۵) قرار دارد. مدل IND_B به عنوان مدل پایه این قسمت انتخاب شده است. این مدل در پایگاه صحت سنجی IND_VAL در معیار F1-Score و mAP به مقدار ۰,۳۲۸ و ۰,۱۹۱ رسیده است. مدل‌های آموزش داده شده در پایگاه داده هند به دلیل تعداد کم داده‌ها در کلاس D10 و نشان گذاری ضعیف، دقت کلی پایینی دارند. مدل IND_B با استفاده از داده افزایشی سنتی به میزان ۲۰۰ ایپاک دوباره آموزش داده شد. مدل IND_AUG دقت بهتری در دو داده صحت سنجی هند دارد. مدل IND_AUG در پایگاه صحت سنجی IND_VAL به میزان ۱۱ درصد در F1-Score بهبود داشته است. همچنین در IND_VAL_AUG در هر دو معیار سنجش پژوهش ۲۰ درصد بهبود داشته است. ارزیابی مدل IND_BBA در پایگاه IND_VAL و IND_AUG_VAL نشان می‌دهد که این مدل به مقدار ۳ و ۹ درصد در معیار F1-Score و در معیار mAP ۵ و ۱۹ درصد به ترتیب در دو داده صحت سنجی بهبود داشته است. نشان گذاری پایگاه داده هند نسبت ژاپن دقت پایین‌تری دارد؛ همین مورد باعث کاهش دقت شناساگرها شده است. رویکرد BBA موجب افزایش دقت شناساگر در کلاس D10 شده است اما این رویکرد، جبرانی برای تعداد کم داده‌های واقعی این کلاس نیست.



شکل (۵): فرایند تلفیق تصاویر

معیار F1-Score تعادلی بین معیارهای دقت و حساسیت است. این معیار صحت کل مدل را با استفاده از معادله (۳) محاسبه می‌کند. معیاری دیگری که در این پژوهش جهت بررسی مدل‌ها استفاده می‌شود میانگین متوسط دقت (mAP^{TV}) است. این معیار میانگین دقت برای تمامی کلاس‌ها است. این معیار در مقادیر حساسیت ۰ تا ۱ محاسبه می‌گردد.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$


۴-۲- نتایج مدل‌های ژاپن

سه مدل شناساگر جهت بررسی رویکردهای پیشنهادی در پایگاه داده ی ژاپن ارزیابی شدند. نتایج معیارهای mAP و F1-Score این مدل‌ها به ترتیب در جدول (۲) و (۳) قرار دارد. مدل پایه ژاپن به نام JP_B در پایگاه صحت سنجی JP_VAL به مقدار ۰,۳۴ و ۰,۴۰۷ به ترتیب در معیارهای mAP و F1-Score رسیده است. کمترین مقدار mAP و F1-Score در این مدل، مربوط به کلاس D40 و D10 است. این مدل در پایگاه صحت سنجی JP_AUG_VAL دقت پایین‌تری دارد. دقت پایین مدل به دلیل تفاوت داده‌های صحت سنجی با داده‌های آموزش مدل است. در ادامه مدل JP_AUG که با استفاده فرایند داده افزایشی آموزش داده شده است. این مدل در دو پایگاه صحت سنجی ژاپن ارزیابی شد. این مدل نسبت به مدل JP_B در داده‌ی صحت سنجی JP_VAL در معیار mAP و F1-Score به ترتیب به میزان ۷ و ۸ درصد بهبود داشته است. همچنین این مدل در پایگاه صحت سنجی JP_AUG_VAL در معیار mAP و F1-Score به ترتیب به میزان ۱۷ و ۱۱ درصد از مدل پایه عملکرد بهتری داشته است. این موارد نشان می‌دهد استفاده از رویکردهای داده افزایشی سنتی موجب بهبود دقت شناساگر در شرایط محیطی مختلف شده است.

ارزیابی مدل JP_BBA نشان می‌دهد که این مدل پس از آموزش با داده‌های جدید به دقت بالاتری در کلاس‌های D10 و D40 رسیده است. این مدل در داده‌های صحت سنجی JP_VAL و JP_AUG_VAL به بهترین عملکرد در بین مدل‌های ژاپن رسیده است. این مدل ۳۳ درصد در F1-Score و ۵۰ درصد در mAP نسبت به مدل پایه بهبود داشته است. این نتایج نشان می‌دهد استفاده از رویکرد داده افزایشی جعبه مرزی همراه با داده افزایشی سنتی در پایگاه داده ژاپن موجب بهبود دقت شناساگر شده است. همچنین به صورت کلی عملکرد مدل‌های ژاپن با استفاده از TTA تا حدی بهبود می‌یابند.

۴-۳- نتایج مدل‌های هند

همانند ژاپن سه مدل برای داده‌های کشور هند آموزش داده شده است. نتایج معیارهای mAP و F1-Score این مدل‌ها به ترتیب در



تلفیق MPB

تبدیل یافته BBA

ماسک MPB

منبع

شکل (۶): نمونه‌های داده افزایی جعبه مرزی


چک شده است. استفاده از داده افزایی جعبه مرزی باعث بهبود ۵ درصد در معیار mAP و ۱۷ درصد در F1-Score نسبت به مدل پایه در پایگاه صحت سنجی CZ_VAL شده است. پایگاه داده‌ی کشور چک در RDD2020 کمترین تعداد نمونه را در همه کلاس‌ها دارد. همچنین بیشتر داده‌های این پایگاه دارای هیچ آسیب یا خرابی جاده ای نیستند. بررسی بیشتر داده‌های این قسمت نشان داد برخی تصاویر به درستی نشان‌گذاری نشده‌اند. برای نمونه در شکل (۷) کلاس خرابی باید به دلیل ترک عمودی، D00 انتخاب شود اما در این تصویر کلاس D10 انتخاب شده است. نشان‌های نادرست دقت شناساگر را کاهش می‌دهند.

۴-۴- نتایج مدل‌های چک

مدل پایه کشور چک CZ_B کمترین دقت را نسبت به مدل‌های دیگر کشورها دارد. نتایج ارزیابی این مدل‌ها به ترتیب در جدول (۶) و (۷) قرار دارد. مدل CZ_B به مقدار ۰,۰۸۷ و ۰,۱۶ به ترتیب در معیار mAP و F1-Score در پایگاه صحت سنجی CZ_VAL رسیده است. استفاده از فرایند داده افزایی سنتی در آموزش مدل در این پایگاه باعث بهبود دقت شناساگر در شرایط متفاوت محیطی در پایگاه داده

۴-۵- نتایج کلی مدل‌ها

در این بخش جهت بررسی عملکرد کلی مدل‌ها در پایگاه داده‌ی RDD2020 داده‌های صحت سنجی تمامی کشورها با یکدیگر تجمیع می‌شوند. این داده‌ها شامل داده‌های بدون داده افزایی و همراه با داده افزایی در همه کشورها هستند. در این ارزیابی بهترین مدل‌ها از نظر معیار F1-Score و mAP در هر کشور جهت ایجاد مدل تجمیعی انتخاب شده است. مدل تجمیعی RDD2020_Ensemble از ترکیب مدل‌های JP_BBA و IND_BBA و CZ_BBA ایجاد شده است. مدل RDD2020_Ensemble به مقادیر ۰,۴۱۳ و ۰,۳۳۵ در معیار F1-Score و mAP رسیده است. نتایج جدول‌های (۸) و (۹) نشان می‌دهد مدل JP_BBA بهترین عملکرد را نسبت به تمامی مدل‌ها در کل پایگاه داده RDD2020 دارد. بررسی‌های این قسمت مشخص نمود؛ تجمیع مدل‌های هر کشور موجب افزایش دقت کلی نمی‌شود زیرا داده‌های RDD2020 در کشورهای مختلف، شرایط یکسانی ندارند. باتوجه به تعداد بیشتر داده‌های ژاپن در این پایگاه مدلی که با داده‌های ژاپن آموزش داده شده است دقت کلی بهتری نسبت به دیگر مدل‌ها، در شرایط مختلف دارد.



شکل (۷): نشان گذاری نادرست در پایگاه داده RDD2020

۵- نتیجه‌گیری

در این مقاله با بررسی شناساگرهای آسیب جاده‌ای در شرایط محیطی مختلف مشخص شد پایگاه داده‌ی موجود در این زمینه تنوع کافی را برای ایجاد یک مدل مقاوم ندارد. ادغام رویکردهای داده افزایی در فرایند آموزش مدل، موجب افزایش مقاومت شناساگرها در برابر تغییرات محیطی شده است. با ترکیب رویکرد داده افزایی جعبه مرزی و تلفیق پوآسن اصلاح شده توانستیم داده‌های جدید، برای کلاس‌های D10 و D40 به صورت طبیعی ایجاد کنیم. این داده‌ها دقت مدل‌های شناساگر را به صورت کلی افزایش دادند. مدل‌های ارائه شده برای کاربرد سیستم‌های متحرک و نهفته مناسب هستند. این پژوهش نشان می‌دهد داده افزایی در هنگام آزمودن موجب افزایش دقت شناساگرها می‌شود. بررسی پایگاه داده RDD2020 نشان می‌دهد این پایگاه نیاز به افزایش تعداد نمونه‌های واقعی، در کشورهای هند و چک دارد. همچنین برخی از نشان‌های این مجموعه نیاز به بازبینی دارند تا بتوان مدلی دقیق‌تر با استفاده از این داده‌ها ایجاد نمود. جهت ایجاد شناساگر خرابی جاده در خودروهای خودران، نیاز به داده‌هایی در شرایط باران شدید و پر شدن چاله‌ها از آب است. این داده‌ها باید در شرایط واقعی و مصنوعی جمع‌آوری شوند تا بتوان مدل‌هایی جامع در این زمینه ایجاد شود. یک سیستم شناساگر خرابی جاده‌ای خودکار و دقیق می‌تواند هشدار لازم را به سیستم رانندگی خودران ارائه دهد. این اطلاعات می‌تواند جهت تنظیم سرعت یا تغییر مسیر در این خودروها استفاده شوند.

جدول (۲): mAP مدل‌های ژاپن

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
JP_B	JP_VAL	۰,۲۶۴	۰,۵۰۵	۰,۲۴۸	۰,۳۴۲	۰,۳۴
JP_B_TTA	JP_VAL	۰,۲۷۷	۰,۴۹۴	۰,۲۵	۰,۳۱۲	۰,۳۳۳
JP_B	JP_AUG_VAL	۰,۲۲۴	۰,۴۶	۰,۲۰۲	۰,۳۱	۰,۲۹۹
JP_B_TTA	JP_AUG_VAL	۰,۲۴	۰,۴۵۹	۰,۲۱	۰,۲۹۱	۰,۳
JP_AUG	JP_VAL	۰,۳۲۶	۰,۴۸۶	۰,۲۷۲	۰,۳۶۷	۰,۳
JP_AUG_TTA	JP_VAL	۰,۳۴۹	۰,۴۹۴	۰,۲۹۲	۰,۳۶	۰,۳۶۳
JP_AUG	JP_AUG_VAL	۰,۲۹۵	۰,۴۶	۰,۲۴۴	۰,۳۴۳	۰,۳۳۶
JP_AUG_TTA	JP_AUG_VAL	۰,۳۱۹	۰,۴۶۹	۰,۲۵۴	۰,۳۴۴	۰,۳۴۷
JP_BBA	JP_VAL	۰,۴۵۵	۰,۶۶۳	۰,۳۸۱	۰,۵۰۱	۰,۵
JP_BBA_TTA	JP_VAL	۰,۴۶	۰,۶۸۸	۰,۴۰۲	۰,۴۷۸	۰,۵۰۷
JP_BBA	JP_AUG_VAL	۰,۴۲۳	۰,۶۲۷	۰,۳۴۹	۰,۴۷۸	۰,۴۶۹
JP_BBA_TTA	JP_AUG_VAL	۰,۴۲۶	۰,۶۵۴	۰,۳۶۹	۰,۴۵۷	۰,۴۷۷

جدول (۳): F1-Score مدل‌های ژاپن

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
JP_B	JP_VAL	۰,۳۳۵	۰,۵۴۴	۰,۳۳۹	۰,۴۰۴	۰,۴۰۷
JP_B_TTA	JP_VAL	۰,۳۶	۰,۵۲	۰,۳۳۳	۰,۳۸	۰,۴۰۳
JP_B	JP_AUG_VAL	۰,۳۰۵	۰,۵۱۹	۰,۲۹۷	۰,۳۸۹	۰,۳۷۹
JP_B_TTA	JP_AUG_VAL	۰,۳۱۴	۰,۵۰۷	۰,۲۹۷	۰,۳۷	۰,۳۷۸
JP_AUG	JP_VAL	۰,۳۹۲	۰,۵۴۷	۰,۳۲۹	۰,۴۳۴	۰,۴۳
JP_AUG_TTA	JP_VAL	۰,۳۹۹	۰,۵۲۲	۰,۳۶۹	۰,۴۳۱	۰,۴۳۷
JP_AUG	JP_AUG_VAL	۰,۳۵۵	۰,۵۲۳	۰,۳۲۲	۰,۴۱۷	۰,۴۰۷
JP_AUG_TTA	JP_AUG_VAL	۰,۳۸۱	۰,۵۰۵	۰,۳۳۵	۰,۴۲۲	۰,۴۱۷
JP_BBA	JP_VAL	۰,۴۹۷	۰,۶۵	۰,۴۳۷	۰,۵۱۴	۰,۵۲۶
JP_BBA_TTA	JP_VAL	۰,۴۸	۰,۶۳۴	۰,۴۵۸	۰,۵۰۸	۰,۵۲۲
JP_BBA	JP_AUG_VAL	۰,۴۶۹	۰,۶۱۵	۰,۴۱۳	۰,۵۰۲	۰,۵۰۱
JP_BBA_TTA	JP_AUG_VAL	۰,۴۶۲	۰,۶۱۶	۰,۴۳۵	۰,۴۹۴	۰,۵۰۳

جدول (۴): mAP مدل‌های هند

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
IND_B	IND_VAL	۰,۲۱۸	۰,۳۸۴	۰,۰۰۱	۰,۱۵۹	۰,۱۹۱
IND_B_TTA	IND_VAL	۰,۲۴۹	۰,۳۱۸	۰,۰۰۱	۰,۱۲۹	۰,۱۷۴
IND_B	IND_AUG_VAL	۰,۱۷۶	۰,۳۲۴	۰,۰۰۱	۰,۱۰۸	۰,۱۵۲
IND_B_TTA	IND_AUG_VAL	۰,۲۰۷	۰,۲۸۵	۰,۰۰۱	۰,۱۰۴	۰,۱۴۹
IND_AUG	IND_VAL	۰,۲۵۴	۰,۳۹۴	۰,۰۰۱	۰,۱۵۶	۰,۲۰۱
IND_AUG_TTA	IND_VAL	۰,۲۷	۰,۳۱۲	۰,۰۰۱	۰,۱۶۴	۰,۱۸۷
IND_AUG	IND_AUG_VAL	۰,۲۲۲	۰,۳۶۷	۰,۰۰۱	۰,۱۴۸	۰,۱۸۵
IND_AUG_TTA	IND_AUG_VAL	۰,۲۴۴	۰,۲۹۶	۰,۰۰۱	۰,۱۴۷	۰,۱۷۲
IND_BBA	IND_VAL	۰,۲۳۲	۰,۳۸۷	۰,۰۲۲	۰,۱۵۸	۰,۲
IND_BBA_TTA	IND_VAL	۰,۲۶۹	۰,۳۰۹	۰,۰۰۷	۰,۱۶۴	۰,۱۸۷
IND_BBA	IND_AUG_VAL	۰,۲۰۵	۰,۳۶	۰,۰۱	۰,۱۴۷	۰,۱۸
IND_BBA_TTA	IND_AUG_VAL	۰,۲۴۵	۰,۲۹	۰,۰۰۳	۰,۱۵۴	۰,۱۷۳

جدول (۵): F1-Score مدل‌های هند

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
IND_B	IND_VAL	۰,۲	۰,۴۳۳	.	۰,۲۶۵	۰,۳۲۸
IND_B_TTA	IND_VAL	۰,۳۳۲	۰,۳۷۱	.	۰,۲۲۵	۰,۳
IND_B	IND_AUG_VAL	۰,۲۶۶	۰,۴۰۵	.	۰,۲۰۹	۰,۲۸۸
IND_B_TTA	IND_AUG_VAL	۰,۲۸۸	۰,۳۵۷	.	۰,۱۹۴	۰,۲۶۵
IND_AUG	IND_VAL	۰,۳۳۹	۰,۴۶۳	.	۰,۲۸۵	۰,۳۶۳
IND_AUG_TTA	IND_VAL	۰,۳۳۷	۰,۳۸۵	.	۰,۲۵۲	۰,۳۳۶
IND_AUG	IND_AUG_VAL	۰,۳۱۲	۰,۴۴۵	.	۰,۲۷۸	۰,۳۴۴
IND_AUG_TTA	IND_AUG_VAL	۰,۳۱۳	۰,۳۶۶	.	۰,۲۴۶	۰,۳۱۸
IND_BBA	IND_VAL	۰,۳۰۱	۰,۴۵۶	.	۰,۲۶۳	۰,۳۳۶
IND_BBA_TTA	IND_VAL	۰,۳۴۷	۰,۳۷۸	.	۰,۲۶۴	۰,۳۱۹
IND_BBA	IND_AUG_VAL	۰,۲۸۱	۰,۴۲۶	.	۰,۲۴۴	۰,۳۱۳
IND_BBA_TTA	IND_AUG_VAL	۰,۳۱۸	۰,۳۶۲	.	۰,۲۴۵	۰,۲۹۹

جدول (۶): mAP مدل‌های چک

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
CZ_B	CZ_VAL	۰,۰۱۲	۰,۰۹۲	۰,۰۸۱	۰,۱۷۷	۰,۰۸۷
CZ_B_TTA	CZ_VAL	۰,۰۱۲	۰,۰۹۲	۰,۰۸۱	۰,۱۷۷	۰,۰۸۷
CZ_B	CZ_AUG_VAL	۰,۰۰۴	۰,۱۹۸	۰,۰۵۷	۰,۱۴	۰,۰۸۷
CZ_B_TTA	CZ_AUG_VAL	۰,۰۱۵	۰,۱۱۸	۰,۰۵۵	۰,۱۶۱	۰,۰۸۷
CZ_AUG	CZ_VAL	۰,۰۱۸	۰,۰۹۳	۰,۰۸۳	۰,۱۵۸	۰,۰۸
CZ_AUG_TTA	CZ_VAL	۰,۰۱۸	۰,۰۹۳	۰,۰۸۳	۰,۱۵۸	۰,۰۶۸
CZ_AUG	CZ_AUG_VAL	۰,۰۰۸	۰,۲۲۷	۰,۰۷۱	۰,۱۲۱	۰,۰۷۶
CZ_AUG_TTA	CZ_AUG_VAL	۰,۰۲۱	۰,۱۴	۰,۰۵۹	۰,۱۴۷	۰,۰۶۶
CZ_BBA	CZ_VAL	۰,۰۰۴	۰,۲۳۹	۰,۰۷	۰,۱۴۵	۰,۰۷۷
CZ_BBA_TTA	CZ_VAL	۰,۰۲۱	۰,۰۷۹	۰,۰۸۲	۰,۱۸۳	۰,۰۷۷
CZ_BBA	CZ_AUG_VAL	۰,۰۰۷	۰,۲۱۸	۰,۰۴۹	۰,۱۳۲	۰,۰۷۱
CZ_BBA_TTA	CZ_AUG_VAL	۰,۰۲۲	۰,۱۲۷	۰,۰۵۹	۰,۱۷۵	۰,۰۷۱

جدول (۷): F1-Score مدل‌های چک

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
CZ_B	CZ_VAL	۰,۰۳۱	۰,۱۹۳	۰,۲۲۳	۰,۲۱۵	۰,۱۶
CZ_B_TTA	CZ_VAL	۰,۰۳۱	۰,۱۹۳	۰,۲۲۳	۰,۲۱۵	۰,۱۸۲
CZ_B	CZ_AUG_VAL	۰,۰۳۶	۰,۲۹۶	۰,۱۶۵	۰,۲۲۹	۰,۱۹۶
CZ_B_TTA	CZ_AUG_VAL	۰,۰۳۲	۰,۲۵۶	۰,۱۷۵	۰,۲	۰,۱۸۳
CZ_AUG	CZ_VAL	۰,۰۷۶	۰,۱۸۵	۰,۰۸۲	۰,۲۷۷	۰,۱۷
CZ_AUG_TTA	CZ_VAL	۰,۰۷۶	۰,۱۸۵	۰,۰۸۲	۰,۲۷۷	۰,۱۷
CZ_AUG	CZ_AUG_VAL	۰,۰۷۳	۰,۲۱۴	۰,۱۶۱	۰,۲۴۱	۰,۱۷۳
CZ_AUG_TTA	CZ_AUG_VAL	۰,۰۷۶	۰,۲۶۶	۰,۰۶۸	۰,۲۵۹	۰,۱۸
CZ_BBA	CZ_VAL	۰,۰۳۶	۰,۲۸۵	۰,۱۸۶	۰,۲۳۲	۰,۱۸۶
CZ_BBA_TTA	CZ_VAL	۰,۰۶۴	۰,۲۱۳	۰,۱۵۷	۰,۲۶۹	۰,۱۸۷
CZ_BBA	CZ_AUG_VAL	۰,۰۵۶	۰,۲۴	۰,۱۴۹	۰,۲۳۲	۰,۱۷
CZ_BBA_TTA	CZ_AUG_VAL	۰,۰۵۵	۰,۲۷۳	۰,۱۳۸	۰,۲۶۶	۰,۱۸۸

جدول (۸): F1-Score مدل‌ها، در ارزیابی کل پایگاه داده‌ی صحت سنجی RDD2020

نام مدل	پایگاه داده صحت سنجی	D40	D20	D10	D00	نتیجه کلی
RDD2020_Ensemble	RDD2020_VAL	۰,۱۹	۰,۵۳	۰,۳۵	۰,۲۹	۰,۳۴
RDD2020_Ensemble_TTA	RDD2020_VAL	۰,۲۱	۰,۵۳	۰,۳۶	۰,۲۵	۰,۳۴
RDD2020_Ensemble	RDD2020_AUG_VAL	۰,۱۸	۰,۵	۰,۳۱	۰,۲۷	۰,۳۲
RDD2020_Ensemble_TTA	RDD2020_AUG_VAL	۰,۱۸	۰,۴۹	۰,۳۳	۰,۲۴	۰,۳۱
JP_BBA	RDD2020_VAL	۰,۲۷	۰,۵۲	۰,۳۶	۰,۳۵	۰,۳۸
JP_BBA_TTA	RDD2020_VAL	۰,۲۸	۰,۵۴	۰,۳۸	۰,۳۳	۰,۳۸
JP_BBA	RDD2020_AUG_VAL	۰,۲۵	۰,۴۹	۰,۳۲	۰,۳۳	۰,۳۵
JP_BBA_TTA	RDD2020_AUG_VAL	۰,۲۶	۰,۵۱	۰,۳۴	۰,۳۲	۰,۳۶
IND_BBA	RDD2020_VAL	۰,۱۲	۰,۱۸	۰,۰۱	۰,۰۷	۰,۰۹
IND_BBA_TTA	RDD2020_VAL	۰,۱۴	۰,۱۶	۰,۰۱	۰,۰۹	۰,۰۴
IND_BBA	RDD2020_AUG_VAL	۰,۱۲	۰,۱۶	۰,۰۱	۰,۰۸	۰,۰۹
IND_BBA_TTA	RDD2020_AUG_VAL	۰,۱۲	۰,۱۶	۰,۰۱	۰,۰۸	۰,۰۹
CZ_BBA	RDD2020_VAL	۰,۰۱	۰,۰۲	۰,۰۴	۰,۰۶	۰,۰۳
CZ_BBA_TTA	RDD2020_VAL	۰,۰۱	۰,۰۳	۰,۰۳	۰,۰۸	۰,۰۴
CZ_BBA	RDD2020_AUG_VAL	۰,۰۱	۰,۰۲	۰,۰۳	۰,۰۵	۰,۰۳
CZ_BBA_TTA	RDD2020_AUG_VAL	۰,۰۱	۰,۰۳	۰,۰۲	۰,۰۷	۰,۰۱

جدول (۹): mAP مدل‌ها، در ارزیابی کل پایگاه داده‌ی صحت سنجی RDD2020

نتیجه کلی	D00	D10	D20	D40	پایگاه داده صحت سنجی	نام مدل
۰,۴۲	۰,۳۸	۰,۴۱	۰,۵۶	۰,۲۹	RDD2020_VAL	RDD2020_Ensemble
۰,۴۱	۰,۳۵	۰,۴۳	۰,۵۳	۰,۲۸	RDD2020_VAL	RDD2020_Ensemble_TTA
۰,۴	۰,۳۶	۰,۳۸	۰,۵۳	۰,۲۷	RDD2020_AUG_VAL	RDD2020_Ensemble
۰,۴	۰,۳۴	۰,۳۹	۰,۵۲	۰,۲۶	RDD2020_AUG_VAL	RDD2020_Ensemble_TTA
۰,۴۴	۰,۴	۰,۴۲	۰,۵۶	۰,۳۶	RDD2020_VAL	JP_BBA
۰,۴۴	۰,۴	۰,۴۵	۰,۵۵	۰,۳۶	RDD2020_VAL	JP_BBA_TTA
۰,۴۱	۰,۳۹	۰,۳۹	۰,۵۲	۰,۳۴	RDD2020_AUG_VAL	JP_BBA
۰,۴۲	۰,۳۹	۰,۴۲	۰,۵۳	۰,۳۴	RDD2020_AUG_VAL	JP_BBA_TTA
۰,۲۴	۰,۱۵	.	۰,۲۷	۰,۱۹	RDD2020_VAL	IND_BBA
۰,۲۵	۰,۱۷	.	۰,۲۳	۰,۲۱	RDD2020_VAL	IND_BBA_TTA
۰,۲۴	۰,۱۷	.	۰,۲۳	۰,۱۹	RDD2020_AUG_VAL	IND_BBA
۰,۲۴	۰,۱۷	.	۰,۲۳	۰,۱۹	RDD2020_AUG_VAL	IND_BBA_TTA
۰,۱	۰,۱۳	۰,۱۲	۰,۰۲	۰,۰۴	RDD2020_VAL	CZ_BBA
۰,۱۲	۰,۱۶	۰,۰۹	۰,۰۳	۰,۰۳	RDD2020_VAL	CZ_BBA_TTA
۰,۰۹	۰,۱۲	۰,۱	۰,۰۲	۰,۰۳	RDD2020_AUG_VAL	CZ_BBA
۰,۱۱	۰,۱۴	۰,۰۷	۰,۰۳	۰,۰۴	RDD2020_AUG_VAL	CZ_BBA_TTA

- [7] Z. Du, J. Yuan, F. Xiao, and C. Hettiarachchi, "Application of image technology on pavement distress detection: A review", Measurement, vol. 184, pp 109900. 2021.
- [8] V. Pham, C. Pham, and T. Dang, "Road damage detection and classification with detectron2 and faster r-cnn", in IEEE International Conference on Big Data (Big Data), 2020, pp. 5592-5601 .
- [9] H. Oliveira and P. L. Correia, "CrackIT—An image processing toolbox for crack detection and characterization", in IEEE International Conference on Image Processing (ICIP), 2014, pp. 798-802 .
- [10] A. Zhang et al., "Automated pixel- level pavement crack detection on 3D asphalt surfaces using a deep- learning network", Computer- Aided Civil and Infrastructure Engineering, vol. 32, no. 10, pp. 805-819, 2017.
- [11] S. Li, Y. Cao, and H. Cai, "Automatic pavement-crack detection and segmentation based on steerable matched filtering and an active contour model", Journal of Computing in Civil Engineering, vol. 31, no. 5, p. 04017045, 2017.
- [12] N. Kanopoulos, N. Vasanthavada, and R. L. Baker, "Design of an image edge detection filter using the Sobel operator", IEEE Journal of Solid-State Circuits, vol. 23, no. 2, pp. 358-367, 1988.
- [13] L. Yang, X. Wu, D. Zhao, H. Li, and J. Zhai, "An improved Prewitt algorithm for edge detection based on noised image", in 4th International

مراجع

- [1] Z. Pei, R. Lin, X. Zhang, H. Shen, J. Tang, and Y. Yang, "Cfm: A consistency filtering mechanism for road damage detection", in IEEE International Conference on Big Data (Big Data), 2020 pp. 5584-5591 .
- [2] V. Mandal, A. R. Mussah, and Y. Adu-Gyamfi, "Deep learning frameworks for pavement distress classification: A comparative analysis", in IEEE International Conference on Big Data (Big Data), 2020pp. 5577-5583 .
- [3] Y. Li, P. Che, C. Liu, D. Wu, and Y. Du, "Cross- scene pavement distress detection by a novel transfer learning framework", Computer- Aided Civil and Infrastructure Engineering, vol. 36, no. 11, pp. 1398-1415, 2021.
- [4] D. Arya et al., "Deep learning-based road damage detection and classification for multiple countries", Automation in Construction, vol. 132, p. 103935, 2021.
- [5] A. Ragnoli, M. R. De Blasiis, and A. Di Benedetto, "Pavement distress detection methods: A review", Infrastructures, vol. 3, no. 4, p. 58, 2018.
- [6] T. B. Coenen and A. Golroo, "A review on automated pavement distress detection methods", Cogent Engineering, vol. 4, no. 1, p. 1374822, 2017.

- object detection", arXiv preprint arXiv:2004.10934, 2020.
- [25] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement", arXiv preprint arXiv:1804.02767, 2018.
- [26] U. Nepal and H. Eslamiat, "Comparing YOLOv3, YOLOv4 and YOLOv5 for autonomous landing spot detection in faulty UAVs", *Sensors*, vol. 22, no. 2, p. 464, 2022.
- [27] M. Li, Z. Zhang, L. Lei, X. Wang, and X. Guo, "Agricultural greenhouses detection in high-resolution satellite images based on convolutional neural networks: Comparison of faster R-CNN, YOLO v3 and SSD", *Sensors*, vol. 20, no. 17, p. 4938, 2020.
- [28] Y. J. Wang, M. Ding, S. Kan, S. Zhang, and C. Lu, "Deep proposal and detection networks for road damage detection and classification", in *IEEE International Conference on Big Data (Big Data)*, 2018, pp. 5224-5227.
- [29] W. Liu et al., "Ssd: Single shot multibox detector", in *European conference on computer vision*, 2016: Springer, pp. 21-37.
- [30] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", in *Proceedings of the IEEE Conference on Computer Vision and Pattern recognition*, 2016, pp. 770-778.
- [31] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition", arXiv preprint arXiv:1409.1556, 2014.
- [32] W. Wang, B. Wu, S. Yang, and Z. Wang, "Road damage detection and classification with faster R-CNN", in *2018 IEEE International Conference on Big Data (Big data)*, 2018, pp. 5220-5223.
- [33] F. Kluger et al., "Region-based cycle-consistent data augmentation for object detection", in *2018 IEEE International Conference on Big Data (Big Data)*, 2018: IEEE, pp. 5205-5211.
- [34] H. Maeda, T. Kashiwayama, Y. Sekimoto, T. Seto, and H. Omata, "Generative adversarial network for road damage detection", *Computer-Aided Civil and Infrastructure Engineering*, vol. 36, no. 1, pp. 47-60, 2021.
- [35] I. Goodfellow et al., "Generative adversarial nets", *Advances in Neural Information Processing Systems*, vol. 27, 2014.
- [36] T. Karras, T. Aila, S. Laine, and J. Lehtinen, "Progressive growing of gans for improved quality, stability, and variation", arXiv preprint arXiv:1710.10196, 2017.
- Congress on Image and Signal Processing, 2011, vol. 3, pp. 1197-1200.
- [14] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiwayama, and H. Omata, "Road damage detection and classification using deep neural networks with smartphone images", *Computer- Aided Civil and Infrastructure Engineering*, vol. 33, no. 12, pp. 1127-1141, 2018.
- [15] D. Arya, H. Maeda, S. K. Ghosh, D. Toshniwal, and Y. Sekimoto, "RDD2020: An annotated image dataset for automatic road damage detection using deep learning", *Data in Brief*, vol. 36, p. 107133, 2021.
- [16] M. S. Sohrabi and M. Moazzami, "A Hybrid Approach for Probabilistic mid-term Electricity Price Forecasting using deep learning", *Journal of Iranian Association of Electrical and Electronics Engineers, Research* vol. 20, no. 4, pp. 123-132, 2023.
- [17] N. Aghaei, G. Akbarizadeh, and A. Kosarian, "Using ShuffleNet to design a deep semantic segmentation model for oil spill detection in synthetic aperture radar images", *Journal of Iranian Association of Electrical and Electronics Engineers, Research* vol. 19, no. 3, pp. 131-144, 2022.
- [18] M. Molaei and A. Amirkhani, "Policy-based Auto-Driving in Highway based on Distributional Reinforcement Learning Methods", *Journal of Iranian Association of Electrical and Electronics Engineers, Research* vol. 19, no. 2, pp. 209-222, 2022.
- [19] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 580-587.
- [20] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 779-788.
- [21] S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks", *Advances in Neural Information Processing Systems*, vol. 28, 2015.
- [22] R. Girshick, "Fast r-cnn", in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, pp. 1440-1448.
- [23] Glenn Jocher, "ultralytics/YOLOv5: v6.0 – YOLOv5n \Nano\ models, Roboflow integration, TensorFlow export, OpenCV DNN support", *Zenodo*, Oct. 12, 2021. Doi: 10.5281/zenodo.5563715.
- [24] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "Yolov4: Optimal speed and accuracy of

- Conference on Computer Vision and Pattern Recognition Workshops, 2020, pp. 390-391.
- [48] S. Liu, L. Qi, H. Qin, J. Shi, and J. Jia, "Path aggregation network for instance segmentation", in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018, pp. 8759-8768.
- [49] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection", in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017, pp. 2117-2125.
- [50] S. Elfving, E. Uchibe, and K. Doya, "Sigmoid-weighted linear units for neural network function approximation in reinforcement learning", Neural Networks, vol. 107, pp. 3-11, 2018.
- [51] V. Hegde, D. Trivedi, A. Alfarrarjeh, A. Deepak, S. H. Kim, and C. Shahabi, "Yet another deep learning approach for road damage detection using ensemble learning", in IEEE International Conference on Big Data (Big Data), 2020, pp. 5553-5558.
- [52] T.-Y. Lin et al., "Microsoft coco: Common objects in context", in European Conference on Computer Vision, 2014: Springer, pp. 740-755.
- [53] H. Zhang and J. Wang, "Towards adversarially robust object detection", in Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019, pp. 421-430.
- [54] M. Khodabandeh, A. Vahdat, M. Ranjbar, and W. G. Macready, "A robust learning approach to domain adaptive object detection", in Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019, pp. 480-490.
- [55] R. Volpi, H. Namkoong, O. Sener, J. C. Duchi, V. Murino, and S. Savarese, "Generalizing to unseen domains via adversarial data augmentation", Advances in Neural Information Processing Systems, vol. 31, 2018.
- [56] A. Buslaev, V. I. Iglovikov, E. Khvedchenya, A. Parinov, M. Druzhinin, and A. A. Kalinin, "Albumentations: fast and flexible image augmentations", Information, vol. 11, no. 2, p. 125, 2020.
- [57] B. Zoph, E. D. Cubuk, G. Ghiasi, T.-Y. Lin, J. Shlens, and Q. V. Le, "Learning data augmentation strategies for object detection", in European Conference on Computer Vision, 2020: Springer, pp. 566-583.
- [58] M. Afifi and K. F. Hussain, "MPB: A modified poisson blending technique", Computational Visual Media, vol. 1, no. 4, pp. 331-341, 2015.
- [37] P. Pérez, M. Gangnet, and A. Blake, "Poisson image editing", in ACM SIGGRAPH 2003 Papers, 2003, pp. 313-318.
- [38] M.-T. Cao, Q.-V. Tran, N.-M. Nguyen, and K.-T. Chang, "Survey on performance of deep learning models for detecting road damages using multiple dashcam image resources", Advanced Engineering Informatics, vol. 46, p. 101182, 2020.
- [39] S. R. Bose and V. S. Kumar, "Efficient inception V2 based deep convolutional neural network for real-time hand action recognition", IET Image Processing, vol. 14, no. 4, pp. 688-696, 2020.
- [40] A. Alfarrarjeh, D. Trivedi, S. H. Kim, and C. Shahabi, "A deep learning approach for road damage detection from smartphone images", in 2018 IEEE International Conference on Big Data (Big Data), 2018: IEEE, pp. 5201-5204.
- [41] P.-j. Chun, K. HASHIMOTO, N. KATAOKA, N. KURAMOTO, and M. OHGA, "Asphalt pavement crack detection using image processing and naive bayes based machine learning approach", Journal of Japan Society of Civil Engineers, Ser. E1 (Pavement Engineering), vol. 70, no. 3, 2015.
- [42] E. Zalama, J. Gómez- García- Bermejo, R. Medina, and J. Llamas, "Road crack detection using visual features extracted by Gabor filters", Computer- Aided Civil and Infrastructure Engineering, vol. 29, no. 5, pp. 342-358, 2014.
- [43] W. R. L. d. Silva and D. S. d. Lucena, "Concrete cracks detection based on deep learning image classification", in Proceedings, 2018, vol. 2, no. 8: MDPI AG, p. 489.
- [44] A. Angulo, J. A. Vega-Fernández, L. M. Aguilar-Lobo, S. Natraj, and G. Ochoa-Ruiz, "Road damage detection acquisition system based on deep neural networks for physical asset management", in Mexican International Conference on Artificial Intelligence, 2019: Springer, pp. 3-14.
- [45] H. Maeda, T. Kashiyama, Y. Sekimoto, T. Seto, and H. Omata, "Generative adversarial network for road damage detection", Computer- Aided Civil and Infrastructure Engineering, vol. 36, no. 1, pp. 47-60, 2021.
- [46] L. Liu et al., "Deep learning for generic object detection: A survey", International Journal of Computer Vision, vol. 128, no. 2, pp. 261-318, 2020.
- [47] C.-Y. Wang, H.-Y. M. Liao, Y.-H. Wu, P.-Y. Chen, J.-W. Hsieh, and I.-H. Yeh, "CSPNet: A new backbone that can enhance learning capability of CNN", in Proceedings of the IEEE/CVF

زیر نویس‌ها

- ¹ Sobel
- ² Prewitt
- ³ Convolutional Neural Networks
- ⁴ Bounding Box Augmentation
- ⁵ Modified Poisson Blending
- ⁶ Random Forest
- ⁷ Generative Adversarial Networks
- ⁸ Poisson Blending
- ⁹ Bayes Classifier
- ¹⁰ Gabor Filters
- ¹¹ Recall
- ¹² Backbone
- ¹³ Neck
- ¹⁴ Head
- ¹⁵ Cross Stage Partial Network
- ¹⁶ Gradient
- ¹⁷ Path Aggregation Network
- ¹⁸ Feature Pyramid Network
- ¹⁹ Sigmoid Linear Unit
- ²⁰ Rectified Linear Unit
- ²¹ Batch
- ²² Stochastic Gradient Decent
- ²³ Albumentation
- ²⁴ Test Time Augmentation
- ²⁵ Non Maximum Suppression
- ²⁶ Intersection Over Union
- ²⁷ Mean Average Precision

