

شناسایی و دسته‌بندی ترک‌های روسازی آسفالتی با کمک الگوریتم آشکارسازی YOLOv5

حسن حسین‌زاده^{۱*}، علی قیامی باجگیرانی^۲ و محدثه دلاوریان^۳

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۱/۰۳/۲۷ بازنگری مقاله: ۱۴۰۱/۰۵/۱۰ پذیرش مقاله: ۱۴۰۱/۰۶/۲۷</p>	<p>تشخیص خودکار ترک روسازی برای ارزیابی الزامات تعمیر و نگهداری راه و اطمینان از ایمنی رانندگی ضروری است. اگر ترک‌ها به‌موقع شناسایی و ترمیم نشوند، عمر روسازی به‌صورت تصاعدی کاهش و هزینه‌های تعمیر و نگهداری افزایش پیدا می‌کند. تشخیص سنتی ترک دارای مشکلاتی مانند بازدهی پایین و عدم شناسایی کامل است. این پژوهش با هدف رفع مشکلات روش‌های سنتی تشخیص ترک و استفاده از مدل‌های یادگیری عمیق، روشی مبتنی بر الگوریتم‌های آشکارسازی و تشخیص شی برای تشخیص ترک روسازی را طراحی کرده و ضمن تشریح مفاهیم تئوری، آخرین مدل‌های تشخیص اشیا سری YOLOv5 را برای تشخیص ترک روسازی مورد بحث قرار داده است. در نهایت، یک مدل آشکارسازی ترک و مدیریت روسازی مؤثر ارائه شده است. این مدل قادر است نوع، موقعیت و مشخصات هندسی ترک را با دقت و سرعت بالایی نسبت به سایر روش‌ها مشخص کند. بدین منظور از تصاویر برداشت شده از آسفالت معابر شهر مشهد برای آموزش و ارزیابی مدل استفاده شده است. تصاویر برای دو گزینه ترک خطی و ترک سطحی برچسب‌گذاری شد. سپس مدل‌هایی با به‌کارگیری پنج الگوریتم سری YOLOv5 و یادگیری انتقالی، ایجاد و از نظر دقت و سرعت پیش‌بینی مورد ارزیابی قرار گرفته است. دقت مدل‌ها بین ۷۷ تا ۹۸ درصد و سرعت پیش‌بینی مدل‌ها بین ۱۷/۴ تا ۱۰۵ میلی‌ثانیه است که بیانگر عملکرد مطلوب مدل‌ها است. مدل ۷5s با داشتن دقت ۹۲/۸ درصد و سرعت ۲۳/۹ میلی-ثانیه، به‌عنوان مدل نهایی جهت پیش‌بینی واقعی ترک در یکی از معابر اصلی شهر مشهد استفاده شد. با توجه به ابعاد و نوع ترک پیش‌بینی شده و استفاده از درخت تصمیم پیشنهادی، رویکرد تعمیر و نگهداری برای هر قطعه مشخص گردید.</p>
<p>واژگان کلیدی: مدیریت روسازی، ترک، یادگیری ماشین، یادگیری عمیق، YOLOv5.</p>	

۱-مقدمه

برای جامعه ما حیاتی هستند، به‌منظور تضمین کیفیت خوب خدمات حمل‌ونقل، تعمیر و نگهداری جاده باید تضمین شود [۲]. مهم‌ترین روشی که در حال حاضر اتخاذ شده، بازرسی بصری^۲ است. در حال حاضر، تشخیص آسیب‌دیدگی‌های روسازی عمدتاً به‌صورت دستی انجام می‌شود که دارای معایبی نظیر اتلاف وقت، نیاز به نیروی کار بیشتر، مسدود شدن راه، به خطر افتادن جان افرادی که روسازی را بررسی می‌کنند است و تشخیص تحت تأثیر

در سال‌های اخیر با توسعه سریع شهرها، راه‌سازی وارد مرحله هم‌زیستی ساخت‌وساز و تعمیر و نگهداری شده است [۱]. در یک جامعه، تحول در کیفیت خدمات حمل‌ونقل، کیفیت بالاتری را برای تمام خدمات اصلی، مانند دسترسی بهتر به مشاغل، بهداشت، آموزش و منابع فراهم می‌کند. به همین دلیل، توسعه اقتصادی به کیفیت خدمات حمل‌ونقل وابسته است. از آنجایی که امروزه راه‌ها

* پست الکترونیک نویسنده مسئول: Hosseinzadeh.hassan@eqbal.ac.ir

۱. دانشجوی کارشناسی ارشد مهندسی عمران گرایش راه و ترابری، دانشکده فنی و مهندسی، موسسه آموزش عالی اقبال لاهوری.

۲. استادیار، دانشکده فنی و مهندسی، گروه مهندسی عمران، موسسه آموزش عالی اقبال لاهوری.

۳. استادیار، دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، موسسه آموزش عالی اقبال لاهوری.

^۱Visual

تشخیص ترک روسازی آسفالت ارائه کرده‌اند. مدل FCN می‌تواند ویژگی‌های لایه‌های مختلف را جمع‌آوری کند که در آن‌ها ویژگی‌های سطحی می‌توانند روی اطلاعات فضایی و ویژگی‌های عمیق می‌توانند موقعیت اشیا را تعیین کنند و در نهایت ویژگی‌های مختلف را ادغام کرده و نقشه پیش‌بینی ترک به دست می‌آید. بر این اساس، مدل‌های تشخیص متعددی برای تشخیص روسازی ترک‌دار پیشنهاد شده‌اند [۱۷-۲۰]. تمامی روش‌های بالا می‌توانند برای توپولوژی ساده و پس‌زمینه واحد به نتایج خوبی برسند اما برای روسازی پیچیده عملکرد مناسبی ندارند.

تشخیص روسازی ترک‌دار متعلق به حوزه تشخیص خودکار مبتنی بر بینایی است. برای بهبود صحت و قدرتمندی تشخیص خودکار روسازی ترک‌دار و تحقق تشخیص خودکار صنعتی روسازی ترک‌دار، ما از مدل‌های تشخیص عالی در سایر زمینه‌ها استفاده کردیم و آن‌ها را به زمینه تشخیص روسازی شکسته منتقل می‌کنیم. ژو و همکاران [۲۱] یک روش مؤثر برای تشخیص و مکان‌یابی خودکار ترک‌های پنهان بر اساس رادار سه‌بعدی نفوذ به زمین^۶ (GPR) و مدل‌های یادگیری عمیق پیشنهاد کرده‌اند. این روش پیشنهادی در مقاله [۱۸] با استفاده از YOLOv4^۷ برای تشخیص ترک‌های پنهان به کار رفته است. الگوریتم YOLOv5 که به‌طور رسمی در ژوئن سال ۲۰۲۰ منتشر شد به یکی از مشهورترین مدل‌های تشخیص شی تبدیل شده و بهترین مدل ارائه‌شده تاکنون در بسیاری از زمینه‌هاست [۲۲]. برای دیدن کارایی YOLOv5 در تشخیص شکستگی، این مقاله به بررسی کاربردپذیری و پیاده‌سازی روش این مدل‌ها در تشخیص روسازی ترک آسفالت بر اساس مدل‌های سری YOLOv5 می‌پردازد.

در این پژوهش ابتدا، تصاویر برداشت‌شده از روسازی که دارای ترک خوردگی طولی و سطحی بود، شناسایی و از مجموعه داده‌ها جدا شد. در مجموع بیش از ۵۲۰ نمونه جمع‌آوری، برچسب‌گذاری و به‌طور تصادفی به مجموعه آموزشی^۸، مجموعه آزمایشی^۹ و مجموعه اعتبارسنجی^{۱۰} تقسیم شد. سپس، مدل‌های تشخیص YOLOv5n، YOLOv5s، YOLOv5m، YOLOv5l و YOLOv5x

عوامل انسانی قرار خواهد گرفت. با توجه به توسعه سریع راه‌ها، تأمین تمام شرایط لازم جهت تشخیص دستی در راه‌های بزرگ بسیار دشوار شده است [۳]. برای بهبود سطح خدمات یک‌راه و تشخیص خودکار روسازی آسیب‌دیده، بعضی از محققان روش‌های تشخیص خودکار مبتنی بر فناوری بصری را ارائه کرده‌اند. در گذشته، از فناوری پردازش تصویر دیجیتال برای تشخیص ترک‌ها استفاده می‌شد [۴]. این روش عمدتاً با مقایسه مقدار رنگ خاکستری روسازی ترک‌دار و پس‌زمینه‌اش تشخیص را انجام می‌دهد؛ اما نرخ تشخیص به دلیل پس‌زمینه پیچیده روسازی، نورپردازی متفاوت و تنوع انواع ترک، پایین است [۵، ۶]؛ بنابراین، این روش می‌تواند فقط به‌عنوان یک روش تشخیص کمکی به کار رود. در سال‌های اخیر، با توجه به استفاده گسترده از یادگیری ماشین^۱ به‌ویژه یادگیری عمیق^۲ در حوزه صنعت [۷-۹]، امکان استفاده از مدل‌های یادگیری عمیق برای تشخیص خودکار روسازی آسیب‌دیده و ترک‌دار فراهم شده است [۱۰-۱۲]. چا و همکاران [۱۳] یک الگوریتم تشخیص روسازی ترک‌دار مبتنی بر شبکه عصبی کانولوشن^۳ (CNN) پیشنهاد کرده‌اند. این الگوریتم یک طبقه‌بند مبتنی بر CNN ایجاد کرده و از دو پنجره کشویی برای اسکن تصویر جهت تشخیص ناحیه ترک استفاده می‌کند؛ اما به دلیل پس‌زمینه پیچیده تصویر، مدل تشخیص نمی‌تواند ویژگی‌های داخلی ترک را تشخیص دهد. برای حل مشکلات موجود در روش تشخیص بالا، چن و جهان‌شاهی [۱۴] شبکه عصبی کانولوشن را بهبود داده و یک الگوریتم تشخیص ترک متشکل از شبکه عصبی کانولوشن و ادغام داده نیویز^۴ (NB-CNN) ارائه کردند. در این روش، شبکه عصبی کانولوشن و نیویز ادغام شده‌اند که تا حد زیادی پیچیدگی مدل و تعداد پارامترها را افزایش داده و آموزش مدل را بسیار سخت می‌کند. این می‌تواند اشیا هدف را در تصاویری با مقیاس مختلف تشخیص دهد چون مدل تشخیص کانولوشن کامل^۵ (FCN) [۱۵] ویژگی‌های تصویر لایه‌های حجمی مختلف را ترکیب می‌کند؛ بنابراین، یانگ و همکاران [۱۶] شبکه کانولوشن کامل با ساختارهای رمزنگاری و رمزگشایی را برای

⁶ Ground Penetrating Radar

⁷ You only look once

⁸ Train

⁹ Test

¹⁰ Validation

¹ Machine learning

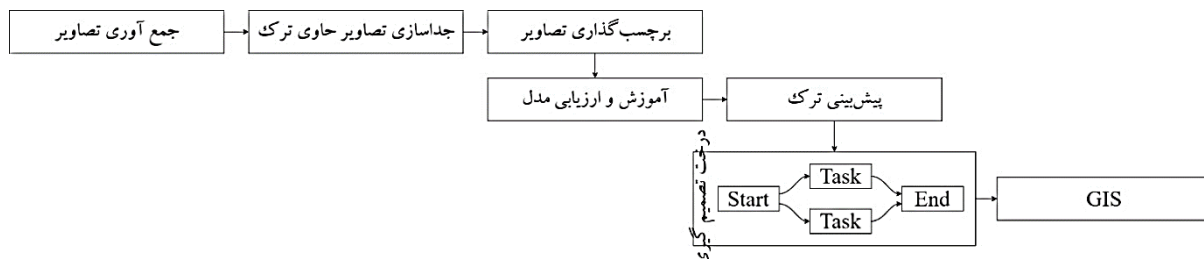
² Deep learning

³ convolutional neural network

⁴ Naïve Bayes

⁵ Fully Convolutional Network

کلانتری مشهد استفاده شد که بر اساس خروجی‌های به‌دست‌آمده شامل نوع ترک و ابعاد آن‌ها و با به‌کارگیری درخت تصمیم‌گیری احصاء شده از نظرات کارشناسان و داده‌های گذشته، در مورد نحوه تعمیر و نگهداری این مسیر پیشنهادهایی ارائه و در محیط GIS^۱ به‌صورت نقشه ترسیم گشت. فرایند کلی این تحقیق در شکل (۱) نشان داده شده است.



شکل ۱: فرایند تشخیص ترک با استفاده از الگوریتم YOLOv5

روش‌های اخیر [۲۳-۲۵] معمولاً فرض می‌کنند که پیکسل مربوط به ترک به‌طور کلی تیره‌تر از اطرافش است و سپس از الگوریتم‌های پردازش آستانه مختلف برای استخراج مقدار خاکستری ناحیه ترک‌دار استفاده می‌کنند. از آنجا که روش بخش‌بندی آستانه^۲، ساده و سریع است کاربرد گسترده‌ای در بخش‌بندی تصویر داشته است. محققان الگوریتم‌های تشخیص خودکار متعددی بر اساس بخش‌بندی آستانه ارائه کرده‌اند. لی و لیو روش آستانه هیستوگرام اختلاف مجاورت برای تشخیص خودکار ترک‌ها در تصاویر را استفاده کرده‌اند. این روش اختلاف میان دو نوع پیکسل (ترک و غیر ترک) را ماکزیمم می‌کند و به نتایج آزمایشی بهتری نسبت به روش آستانه کلاسیک دست می‌یابد. لیو و همکاران [۲۵] رواسازی ترک‌دار را با پردازش تصاویر دودویی به‌دست‌آمده از الگوریتم دامنه متصل^۳ (الگوریتم بسط بخش‌بندی جهت‌دار) تشخیص داده و به نتایج خوبی دست‌یافته‌اند.

از آنجا که روش بخش‌بندی آستانه تنها اطلاعات مقدار خاکستری تصویر را در نظر می‌گیرد و اطلاعات فضایی تصویر را نادیده می‌گیرد و نسبت به نویز حساس است، این الگوریتم اغلب با سایر روش‌ها ترکیب می‌شود تا صحت بخش‌بندی بهبود یابد. گاویلان و همکاران [۲۶] نشان دادند که ویژگی‌های مربوط به نواحی بدون ترک و سالم در تصویر

در سری YOLOv5 را آزمایش کرده و مشخص شد که نرخ تشخیص تمام مدل‌ها به‌جز v5n تشخیص بالای ۹۰ درصد است؛ اما از آنجا که YOLOv5s یک مدل تشخیص سبک‌وزن است، سرعت تشخیص خیلی بهتر از مدل‌های دیگر است. برحسب نرخ تشخیص و کارایی، YOLOv5s می‌تواند نیازهای مهندسی را برآورده سازد. در نهایت مدل ارزیابی شده برای پیش‌بینی ترک‌های خط‌کندرو بزرگراه

بخش‌های این مقاله به شرح زیر هستند. در بخش ۲، مطالعات مرتبط معرفی شده است. در بخش ۳، مدل تشخیص و تصاویر توضیح داده می‌شود. نتایج آزمایش‌ها در بخش ۴ و نتیجه‌گیری در بخش ۵ ارائه شده است.

۲- پیشینه تحقیق

در گذشته از روش‌هایی مانند روش‌های لیزر، مادون قرمز، حرارتی، پرتونگاری و آزمایش حرارتی برای خودکار کردن فرایند تشخیص ترک استفاده شده است. با این حال، اخیراً، روند افزایشی استفاده از روش‌های مبتنی بر تصویر برای تشخیص ترک‌ها وجود داشته است. این روش‌ها را می‌توان به دو نوع پردازش تصویر و یادگیری ماشینی دسته‌بندی کرد. روش‌های پردازش تصویر نیازی به فرایند آموزش مدل ندارند و شامل استفاده از فیلترها، تجزیه و تحلیل مورفولوژیکی، روش‌های آماری و تکنیک‌های نفوذ برای تشخیص ترک است. از سوی دیگر، فرایند یادگیری ماشینی شامل مجموعه‌ای از تصاویر است که برای آموزش به مدل یادگیری ماشین انتخاب شده ارائه می‌شود. چنین روش‌هایی ممکن است شامل مراحل پردازش تصویر باشد، اما وظیفه تشخیص ترک توسط مدل یادگیری ماشین آموزش‌دیده انجام می‌شود. تعدادی از مطالعات انجام‌گرفته شده مرتبط با تشخیص خودکار ترک در ادامه ارائه شده است.

۱-۲- تشخیص خودکار مبتنی بر پردازش تصویر

³ Domain Connected

¹ Geographic Information System

² Threshold segmentation

نشان‌دهنده مثبت‌های اشتباه^۱ هستند؛ بنابراین، برای به دست آوردن ناحیه ترک‌دار، پیشنهاد می‌شود تا مثبت‌های اشتباه در تصویر بدون ترک حذف شوند. برای این منظور میانگین مقدار خاکستری پیکسل‌های اطراف کانتورهای داخلی و خارجی شی خطی در تصویر محاسبه می‌شود. لی و مانو [۲۷] ابتدا تصویر را به چند ناحیه همپوشان تقسیم کردند. سپس، هیستوگرام اختلاف همسایگی برای بخش بندی و ادغام شکستگی‌ها در هر ناحیه از تصویر استفاده می‌شود. در نهایت، ناحیه شکسته در تصویر مشخص می‌شود. این روش در دامنه کوچکی از ویژگی‌های پیچیده و نه در ناحیه بزرگی از پس‌زمینه پیچیده، مؤثر است. روش استخراج آستانه کلاسیک فاقد اطلاعات سراسری است و نسبت به نویز حساس است. اثر تشخیص وابسته به انتخاب آستانه است؛ اما پس‌زمینه جاده در عمل پیچیده است و نویز بسیار زیادی وجود دارد بنابراین این مدل‌ها کاربردی اندکی دارند.

۲-۲- تشخیص خودکار مبتنی بر یادگیری ماشین

روش یادگیری ماشین مبتنی بر ویژگی‌های مهندسی، کاربرد موفقی در بسیاری از زمینه‌ها داشته‌اند. روسازی آسیب‌دیده و ترک‌دار دارای مشخصات بافتی مهمی است. اغلب محققان ویژگی‌های بافت روسازی آسفالت در تصاویر را از دیدگاه‌های مختلف به دست آورده و از روش‌های طبقه‌بندی در یادگیری ماشین برای تشخیص خودکار روسازی ترک‌دار و آسیب‌دیده استفاده می‌کنند. هو و همکاران [۲۸] یک روش تشخیص روسازی شکسته خودکار جدید مبتنی بر تحلیل بافت و توصیف شکل ارائه کرده‌اند. گفته می‌شود که ویژگی‌های بافت، ناهموار هستند؛ بنابراین در این مقاله از شش ویژگی بافت و دو توصیفگر شکل ثابت برای توصیف ویژگی‌های نورپردازی نامنظم و ناهموار در تصاویر استفاده شده است. طبقه‌بند ماشین بردار پشتیبان^۲ برای طبقه‌بندی تصویر به دو دسته ترک‌دار و سالم بکار رفته است. کرد و چامبون [۲۹] یک روش توصیف شکستگی کلی مبتنی بر یادگیری نظارت‌شده^۳ پیشنهاد داده‌اند که می‌تواند برای تمام انواع نقص‌ها و مشکلات موجود در عکس‌ها بکار رود. نویسندگان بر این باور بودند که روسازی دارای شکستگی دارای اطلاعات بافتی قوی

هستند. ویژگی‌های بافت روسازی ترک‌دار در دامنه محلی دارای نوسان و در دامنه کلی نیز غیریکنواخت است؛ بنابراین، این مقاله از فیلترهای خطی و غیرخطی برای توصیف اطلاعات بافت عکس استفاده می‌کند. مشخصات عکس در مقیاس‌های مختلف با استفاده از تبدیل مورفولوژیک، فیلترسازی خطی و فیلترسازی غیرخطی تجزیه و تحلیل شده‌اند. در نهایت، طبقه‌بند AdaBoost برای یادگیری و طبقه‌بندی اطلاعات بافت بکار می‌رود تا ناحیه آسیب‌دیده روسازی آسفالت مشخص شود. آزمایش‌ها نشان می‌دهند که این روش می‌تواند عملکرد تشخیص ترک را تا حدی بهبود دهد اما نمی‌تواند استخراج و تشخیص ترک‌ها را به‌طور کامل انجام دهد. شی و همکاران [۳۰] روشی برای استخراج و تشخیص روسازی شکسته با استفاده از جنگل تصادفی پیشنهاد داده‌اند. چارچوب تشخیص مبتنی بر نمایش و تفکیک ویژگی‌های کانال است و این چارچوب با جنگل تصادفی^۴ ترکیب شده است. این مدل می‌تواند در مجموعه داده‌های کوچک با نظارت کامل آموزش داده شود. بعلاوه، دو هیستوگرام ویژگی پیشنهادی برای نمایش ترک‌ها و حذف نویزی که به اشتباه ترک در نظر گرفته شده به کار می‌رود. هرچند این روش می‌تواند بر بخش کوچکی از تداخل نویز جاده‌ای غلبه کند، هنوز نمی‌تواند ترک‌ها را از پس‌زمینه پیچیده استخراج کند. هوانگ و ناین [۳۱] از ماشین بردار پشتیبان، شبکه عصبی مصنوعی^۵ و جنگل تصادفی برای آموزش و تأیید عملکرد الگوریتم یادگیری ماشین در مجموعه داده استفاده کرده‌اند. مجموعه ویژگی متشکل از ویژگی‌های روسازی سالم و روسازی شکسته می‌تواند به نتایج ایده‌آل‌تری منجر شود. در یک کلمه، مدل تشخیص مبتنی بر الگوریتم یادگیری ماشین تا حد زیادی وابسته به ویژگی‌هایی است که به‌طور دستی از تصاویر استخراج می‌شوند که شامل بافت و رنگ هستند. مدل‌های استخراج ویژگی مختلف باید برای صحنه‌های مختلف، نورپردازی مختلف و غیره طراحی شوند. سطح جاده آسفالت شامل انواع زباله و سایر نویزهاست؛ بنابراین، استخراج ویژگی‌های مؤثر با یک مدل ویژگی یکنواخت برای شکستگی‌ها در محیط جاده‌ای پیچیده و متغیر که منجر به مقاومت ضعیف مدل می‌شود

⁴ Random Forest

⁵ Artificial neural network

¹ False positives

² Support Vector Machine

³ Supervised learning

شکستگی را یاد می‌گیرد. ویژگی‌های کانولوشن عمیق چندمقیاسی یاد گرفته‌شده از لایه‌های کانولوشن مختلف با یکدیگر ادغام می‌شوند تا یک ساختار خطی را تشکیل دهند. ویژگی‌های تصویر به‌دست‌آمده از این روش جزئیات بیشتری را در نگاشت‌های ویژگی مقیاس بزرگ نشان داده و در نگاشت‌های ویژگی مقیاس کوچک مشخصات جامع‌تری را نشان می‌دهند. شبکه ترک عمیق مبتنی بر معماری رمزگذار^۳-رمزگشای^۴ شبکه SEG، ویژگی‌های کانولوشن تولیدشده در شبکه رمزگذار و شبکه رمزگشا را با مقیاس یکسان ادغام می‌کند. این روش می‌تواند استخراج ترک در سطح پیکسل را انجام دهد.

در یک جمله، اثر تشخیص مدل تشخیص مبتنی بر یادگیری عمیق خیلی بیشتر از اثر تشخیص مدل یادگیری ماشین مبتنی بر مهندسی انرژی است. در کنار بهترین مدل‌های تشخیص شی‌ارائه‌شده تاکنون و استفاده از آن‌ها در تشخیص روسازی ترک‌دار می‌توان کارایی تشخیص روسازی آسیب‌دیده را تا حد زیادی بهبود داد.

۳- تشخیص ترک با استفاده از الگوریتم YOLOv5

۳-۱- مجموعه داده

روش تشخیص هدف مبتنی بر شبکه عصبی کانولوشن نیاز به یادگیری ویژگی‌های هدف از تعداد زیادی نمونه دارد. اگر نمونه‌ها معرف نباشند، انتخاب ویژگی‌های خوب دشوار است. تصاویر استفاده‌شده در این تحقیق توسط اداره کل نظارت بر نگهداری و تعمیرات و بهره‌برداری تأسیسات و زیرساخت‌های شهری شهرداری مشهد از معابر اصلی شهر مشهد به‌وسیله اسکنر سطح جاده شرکت آزمایشگاه فنی و مکانیک خاک برداشت شده است. تصاویر دارای ابعاد ۹۹۴×۲۵۰۰ پیکسل که در مقیاس واقعی ۱۰×۳ متر هستند. در مجموع تعداد ۵۲۰ تصویر حاوی خرابی جمع‌آوری که از این تعداد ۴۱۶ تصویر (۸۰ درصد) به‌عنوان مجموعه آموزشی و ۱۰۴ تصویر (۲۰ درصد) به‌عنوان مجموعه آزمایشی استفاده شد. محققان نشان داده‌اند که این ترکیب بهترین عملکرد به همراه داشته است [۳۶]. نمونه‌ای از تصاویر در شکل (۲) نشان داده شده است.

و کار بسیار دشواری است. در مجموع، مدل تشخیص مبتنی بر یادگیری ماشینی را می‌توان تنها در یک حوزه کوچک و نه کلی به کار برد.

۲-۳- تشخیص خودکار مبتنی بر یادگیری عمیق


در سال‌های اخیر، با توسعه روش یادگیری عمیق، امکان تشخیص روسازی شکسته به‌طور خودکار بر اساس مدل یادگیری عمیق فراهم شده است. مدل DCNN^۱ با یادگیری نمونه ترک‌های مختلف عملکرد تشخیص خودکار ترک را تا حد زیادی بهبود بخشیده است. بعضی محققان از روش‌های تشخیص شی [۳۲، ۳۳] یا بخش‌بندی تصویر [۳۴، ۳۵] برای استخراج ترک‌ها استفاده کرده‌اند. این روش‌ها نمی‌توانند شکستگی‌ها را در سطح پیکسل استخراج کنند و همچنین نمی‌توانند نوع آسیب‌دیدگی و شدت آن را به‌درستی تعیین کنند. ژانگ و همکاران [۳۶] یک سیستم تشخیص خودکار به نام شبکه شکستگی مبتنی بر شبکه عصبی کانولوشن پیشنهاد داده‌اند. هدف این سیستم استخراج سطح پیکسل ویژگی‌ها و تشخیص خودکار روسازی ترک‌دار آسفالت سه‌بعدی است. برخلاف CNN‌های متداول، شبکه شکستگی هیچ لایه ادغامی برای کاهش خروجی لایه قبلی ندارد. شبکه ترک^۲ صحت استخراج ترک را با استفاده از تکنولوژی عرض و ارتفاع تصویر در تمامی لایه‌های شبکه تضمین می‌کند. در مقایسه با روش تشخیص شکستگی کلاسیک مبتنی بر یادگیری ماشین، صحت استخراج این روش مشخصاً بهتر از روش کلاسیک است. با الهام از شبکه ترک، فی و همکاران [۳۷] یک شبکه عمیق کارآمد به نام شبکه ترک^۷ مبتنی بر شبکه ترک پیشنهاد داده‌اند که برای تشخیص خودکار ترک سطح پیکسل در تصویر سه‌بعدی روسازی آسفالت بکار رفته است. در مقایسه با شبکه ترک اصلی، شبکه ترک^۷ از اندازه فضای مشابهی برای تمامی لایه‌ها استفاده می‌کند بنابراین یادگیری نظارت‌شده می‌تواند در سطح پیکسل انجام شود. کارایی شبکه ترک^۷ نشان‌دهنده مزیت تکنولوژی یادگیری عمیق در تشخیص خودکار ترک با توجه به تصاویر است. زو و همکاران [۳۸] یک شبکه عصبی کانولوشن عمیق آموزش‌پذیر برای تشخیص خودکار شکستگی ارائه کرده‌اند که شکستگی عمیق نام دارد و ویژگی‌های پیشرفته نمایش

^۳ Encoder

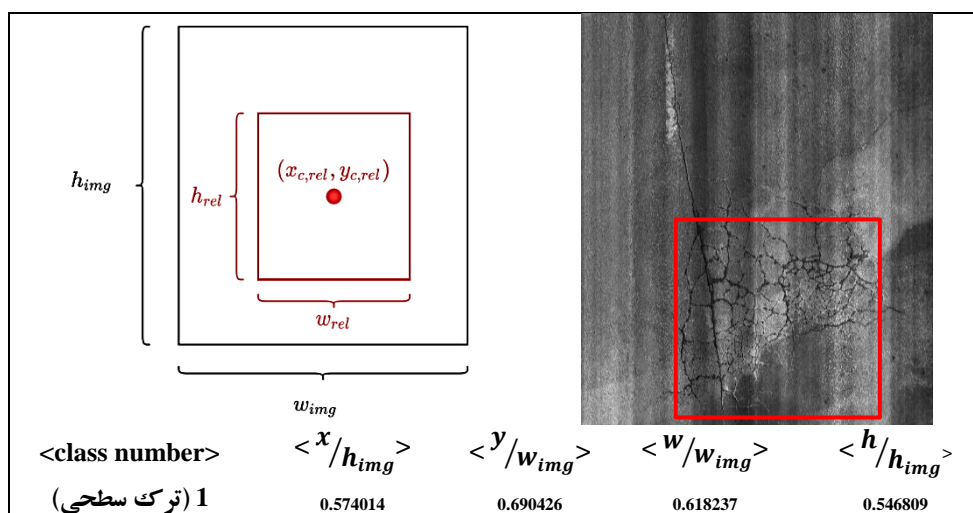
^۴ Decoder

^۱ Designed Deep Convolutional Neural Network

^۲ Crack Network




شکل ۲: نمونه‌ای از تصاویر برداشت‌شده از سطح معابر اصلی شهر مشهد



شکل ۳: الگوی برچسب‌گذاری YOLOv5

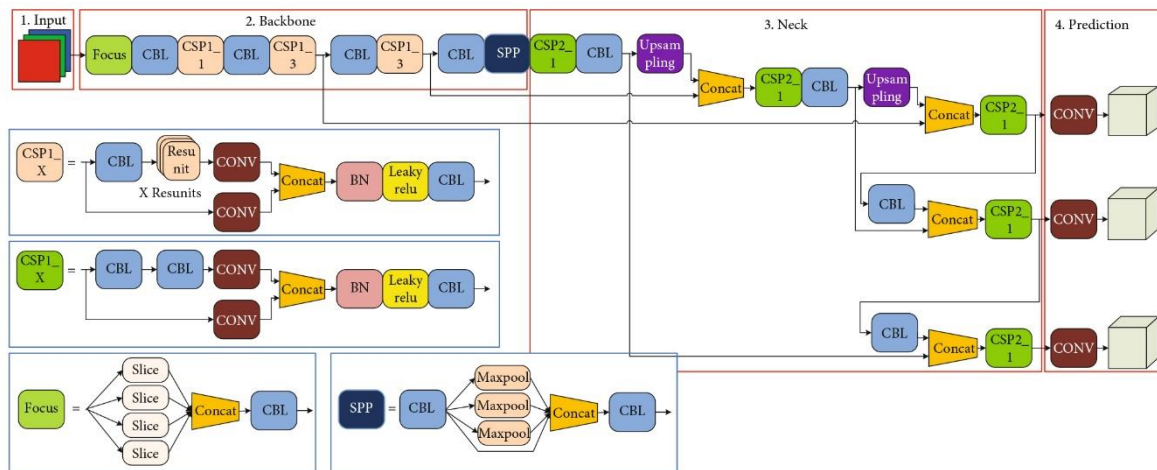
از سامانه تحت وب makesense انجام شده است. تمامی تصاویر برای دو گزینه ترک خطی و ترک سطحی، علامت‌گذاری شدند. در بین ۵۲۰ تصویر استفاده‌شده تعداد ۱۳۹۹ ترک شامل ۲۵۲ ترک سطحی و ۱۱۴۷ ترک خطی علامت‌گذاری و برچسب‌گذاری شدند. ترک‌های خطی به علت تنوع زیادی که در نوع اعوجاج و ناپیوستگی دارند بیشتر انتخاب شدند. نمودار میله‌ای تعداد برچسب‌های مربوط به هر گزینه در شکل (۴) آمده است.



شکل ۴: نمودار میله‌ای تعداد برچسب‌های مشخص‌شده بر روی تصاویر آموزش و آزمایش

از شکل (۲) می‌توان دید که ترک‌های روسازی با اعوجاج، ناپیوستگی و طول مشخص می‌شوند. اداره بزرگراه فدرال^۱ خرابی‌های رایج روسازی را به دودسته خرابی‌های شامل ترک خوردگی و خرابی‌های غیر ترک‌خوردگی تقسیم نموده است. ترک‌خوردگی یکی از متداول‌ترین خرابی‌های روسازی بوده که حجم قابل توجهی از تلاش‌های محققان به‌منظور ایجاد سامانه‌های خودکار تشخیص خرابی را به خود معطوف کرده است [۳۶-۳۹]. خرابی‌های شامل ترک‌خوردگی را می‌توان به دودسته ترک‌های خطی و ترک‌های سطحی یا الگودار تقسیم نمود. از آنجایی که یک روش یادگیری تحت نظارت انتخاب شده است، همه داده‌ها باید قبل از آموزش و آزمایش شبکه برچسب‌گذاری شوند. این مقاله از برچسب زدن مطابق با الگوی YOLO برای علامت‌گذاری استفاده می‌کند. بدین منظور می‌بایست طول و عرض چارچوب احاطه‌کننده ترک و مختصات مرکز این چارچوب نسبت به ابعاد اصلی تصویر مشخص گردد؛ یعنی تمامی ابعاد بر ابعاد تصویر اصلی تقسیم می‌شوند (شکل ۳). این کار با استفاده

^۱ Federal Highway Administration



شکل ۵: ساختار الگوریتم YOLOv5 [۳۹]

چون هر یک از این اجزا و مراحل آن باید به صورت جداگانه آموزش داده شود و بهینه گردد [۴۷، ۴۸]. در اینجا به منظور شناسایی ترک‌های روسازی آسفالتی، از معماری YOLOv5 (که مختص کاربردهای بلادرنگ طراحی شده است) استفاده خواهد شد. YOLOv5 برگزیده چهار بخش است: ورودی^۲، ستون فقرات^۳، گردن^۴ و پیش‌بینی^۵ [۴۹]. جزئیات مربوط به هر کدام در شکل (۵) آمده است. YOLOv5 در مقایسه با YOLOv3 معروف [۵۰]، با بهبودهایی در چهار بخش فوق همراه بوده است [۵۱، ۵۲]:

- در بخش ورودی، داده‌افزایی موزاییکی و محاسبه‌ی تطبیقی جعبه‌ی لنگر^۶ اضافه شده است.
- ساختار تمرکز^۷ و مرحله متقاطع جزئی^۸ به بخش ستون فقرات اضافه شده است.
- ساختار شبکه هرمی^۹ و ویژگی و شبکه تجمیع سریع به بخش گردن اضافه شده است.
- تابع زیان^{۱۰} GIOU_Loss در بخش پیش‌بینی مورد استفاده قرار گرفته است.

این بهبودها باعث شده تا YOLOv5 نسبت به نسخه‌های دیگر YOLO، سریع‌تر و دقیق‌تر باشد. مقالات متعددی عملکرد نسخه پنجم YOLO را با سایر نسخه‌ها بررسی و مطلوب بودن نتایج را نسبت به نسخه‌های گذشته تأیید کرده است [۴۹، ۵۱-۵۴]. از لحاظ سرعت نیز الگوریتم

۳-۲- معرفی مدل YOLOv5

تشخیص اشیا^۱ یکی از الگوریتم‌های پردازش تصویر است که برای شناسایی و موقعیت‌یابی در تصویر استفاده می‌شود. برای اینکه این الگوریتم بتواند شی را در تصویر پیدا کند نیاز دارد که یک مدل از آن شی بسازد. در مرحله بعد الگوریتم شروع به جستجو در عکس می‌نماید. الگوریتم شناسایی اشیا عکس را جستجو می‌کند تا مدل مورد نظر را پیدا نماید [۴۰-۴۲].

در حال حاضر، مدل‌های تشخیص اشیا مبتنی بر یادگیری عمیق را می‌توان به دو دسته تقسیم کرد:

مدل دو مرحله‌ای: ایجاد مناطق کاندید و دسته‌بندی این مناطق به واسطه‌ی شبکه‌ی عصبی پیچشی (سری RCNN [۴۳])

مدل یک مرحله‌ای: طبقه‌بندی اشیا و تعیین موقعیت آن‌ها طی یک مرحله (سری YOLO [۴۴])

پس از RCNN، RCNN سریع [۴۵] و RCNN سریع‌تر [۴۶]، YOLO چارچوب دیگری است که توسط Ross Girshick و مختص مسئله‌ی سرعت تشخیص اشیا ارائه شده است. این چارچوب تاکنون به نسخه‌ی پنجم آن نیز ارتقا یافته است.

روش‌های تشخیص اشیا پیش از YOLO عمل تشخیص اشیا را با طبقه‌بندی کننده انجام می‌دهند. این مسیر نسبتاً پیچیده سرعت پایینی دارد و بهینه‌سازی آن مشکل است،

⁶ Anchor Box

⁷ Focus Structure

⁸ Cross Stage Partial Network

⁹ Pyramid Network

¹⁰ Loss Function

¹ Object Detection

² Input

³ Backbone

⁴ Neck

⁵ Prediction

۴- تابع بهینه‌سازی^۵: در پیاده‌سازی YOLOv5 بهینه‌سازی‌های گرادینان نزولی تصادفی^۶ (SGD) [۶۱] یا آدام^۷ [۶۲] قابل استفاده است. با این حال، SGD تابع بهینه‌سازی پیش‌فرض در نظر گرفته می‌شود.

پنج نسخه از YOLOv5 شامل v5l, v5m, v5s, v5x و وجود دارد. ساختار شبکه‌ای پنج نسخه‌ی فوق از این مدل - از کوچک به بزرگ، میزان دقت تشخیص مربوطه - از کم به زیاد و اما سرعت تشخیص آن‌ها - از سریع به آهسته است. به بیانی دیگر، نسخه‌ی YOLOv5n از کوچک‌ترین شبکه، پایین‌ترین سرعت و کم‌ترین دقت AP^۸ برخوردار است. چنانچه اکثر اشیاء شناسایی شده دارای اندازه‌ای بزرگ باشند، شبکه به سرعت این اشیاء را تشخیص خواهد داد. در صورت وجود تعداد زیادی ترک کوچک در کف خیابان، YOLOv5n قادر به تشخیص اجسام کوچک نخواهد بود [۳۹، ۴۷، ۴۸]. جهت تعیین این که کدام مدل دارای بهترین ترکیب دقت تشخیص و کارایی در شناسایی ترک‌های روسازی است، این مقاله از پنج مدل سری YOLOv5 در فرایند تشخیص ترک استفاده خواهد کرد.

۳-۳- درخت تصمیم پیشنهادی جهت تعیین رویکرد تعمیر و نگهداری روسازی

خروجی مدل YOLOv5 برای هر شی و هدف شناسایی شده، یک چارچوب با مختصات مرکز، طول و عرض و نوع خرابی مشابه با الگوی برچسب‌گذاری است [۶۳، ۶۴]. بر اساس ابعاد تعیین شده در خروجی و تبدیل آن به ابعاد واقعی با توجه به ابعاد تصویر، می‌توان بزرگ‌ترین طول چارچوب را برای طول ترک‌های خطی و مساحت چارچوب را برای تعیین مساحت ترک‌های سطحی در نظر گرفت. بدین صورت هم نوع خرابی و هم ابعاد خرابی ایجاد شده مشخص می‌گردند.

با اعمال نقطه نظرات متخصصان (جلسات تخصصی) در خصوص پارامترها و شاخص‌های پیشنهادی و تجربیات گذشته، الگوریتم درخت تصمیم‌گیری (شکل ۶) بر اساس نوع و ابعاد ترک توسعه یافته و بر اساس آن رویکرد تعمیر و نگهداری به تفکیک هر قطعه تصویر اختصاص می‌یابد.

YOLOv5 تنها با استفاده از یک واحد پردازش گرافیکی^۱ (GPU) و بدون آن که تغییری در میزان دقت تشخیص ایجاد گردد، قادر است سرعت آموزش را افزایش دهد [۴۷، ۴۸]. بخش ستون فقرات مدل استخراج ویژگی‌های برجسته‌ی تصویر ورودی را به انجام می‌رساند. یک شبکه‌ی مرتبه‌ی جزئی متقاطع (CSPNet) [۵۵] به عنوان ستون فقرات مدل استفاده می‌شود. در واقع، CSPNet ها بسیار سریع‌تر از شبکه‌های عمیق‌تر عمل می‌کنند. بخش گردن مدل اهرام ویژگی را ایجاد می‌کند. این مؤلفه به مدل کمک می‌کند تا اشیاء یکسان موجود در اندازه‌ها و مقیاس‌های مختلف را شناسایی و تشخیص دهد. این راه‌کار در داده‌های آموخته‌نشده به نتایج مطلوب‌تری منجر می‌شود. بسیاری از مدل‌ها از انواع مختلفی از اهرام ویژگی نظیر FPN [۵۶]، BiFPN [۵۷]، PANet [۵۸] استفاده می‌کنند که در YOLOv5 نیز به کار گرفته شده است. بخش سر مدل وظیفه‌ی تشخیص نهایی را به انجام می‌رساند. این بخش کادرهای لنگر را بر روی ویژگی‌های تولیدشده اعمال نموده و سپس بردارهای نهایی حاوی احتمالات کلاس، امتیازات شی بودن^۲ و کادرهای محصورکننده^۳ را به عنوان خروجی ارائه می‌دهد. بخش سر در YOLOv5 مشابه YOLOv3 و YOLOv4 است.

۲- تابع فعال‌سازی^۴: تابع فعال‌سازی یکی از مؤلفه‌های مهم این مدل تلقی می‌شود چراکه فعال‌سازی یا عدم فعال‌سازی نورون را تعیین می‌نماید. در YOLOv5 از توابع فعال‌سازی Leaky ReLU [۵۹] و سیگموئید [۶۰] استفاده شده است که در نتیجه‌ی آن نسبت به برقراری سازشی مناسب در میان مقادیر دقت و اشباع اطمینان حاصل می‌شود. در واقع تابع فعال‌سازی Leaky ReLU در لایه‌های میانی/مخفی و تابع فعال‌سازی سیگموئید در لایه‌ی تشخیص نهایی استفاده می‌شود.

۳- تابع هزینه یا تابع زیان: تابع زیان ایجادشده توسط شبکه و بعد از هر لایه، در واقع ترکیبی از امتیاز شی بودن، امتیاز احتمال کلاس و امتیاز رگرسیون کادر محصورکننده است. YOLOv5 از تابع هزینه‌ی آنتروپی متقاطع دودویی استفاده می‌کند.

⁵ Optimization function

⁶ Stochastic Gradient Descent

⁷ Adam

⁸ Average precision

¹ Graphics processing unit

² Objectness scores

³ Bounding boxes

⁴ Activation function

پایتون نسخه ۳,۷,۱۳ نوشته شده است. این مدل‌ها با استفاده از چارچوب pytorch مبتنی بر یادگیری عمیق کلاسیک پیاده‌سازی [۴۷, ۴۸] و بر روی محیط گوگل کولب^۱ با ۱۲,۷ گیگابایت رم و Tesla T4 15 گیگابایت گرافیک (GPU) آموزش دیده شدند. Pytorch برای انجام آزمایش‌های سریع ایجاد شده و قادر است ایده‌های خود را به سرعت به نتیجه تبدیل کند. به همین دلیل، pytorch می‌تواند به سرعت و دقیق نتایج الگوریتم‌های مختلف تشخیص ترک را مقایسه کند.

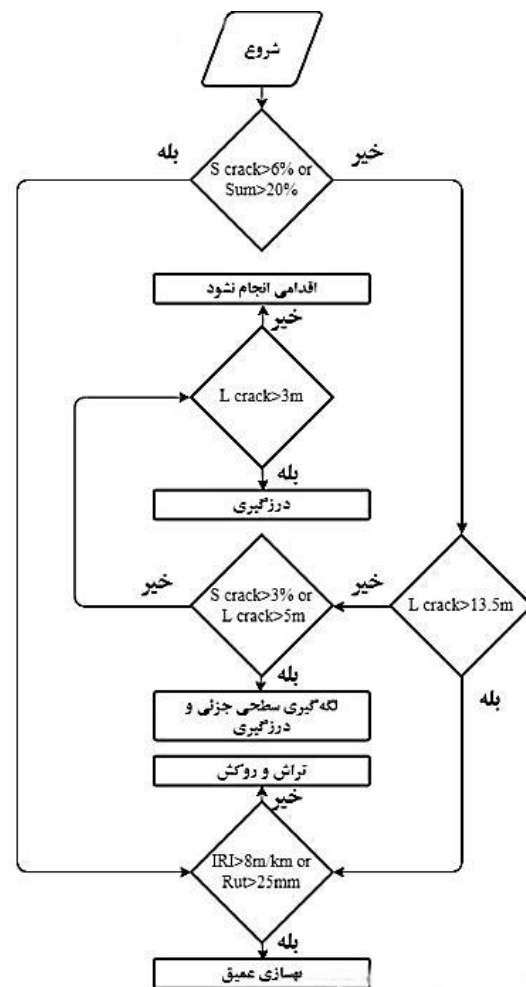
۲-۴- مدل‌سازی

در حالت کلی رایج‌ترین روش‌ها به منظور مدل‌سازی عبارتند از: ۱. ایجاد مدل از پایه و انجام تمامی مراحل و الزامات ساخت مدل و ۲. استفاده از روش انتقال یادگیری^۲ با بهره‌گیری از مدل‌های از پیش تعلیم‌یافته^۳.

در روش اول، برای ایجاد شبکه نیاز است که تمامی اجزا و پارامترهای شبکه توسط افراد متخصص تعیین و طراحی شوند که این امر با توجه به پیچیدگی ساختار شبکه و گستردگی پارامترها نیازمند تخصص بالا و صرف وقت زیاد است. همچنین در این روش به منظور ایجاد شبکه کارآمد نیاز به حجم انبوهی از داده وجود دارد که این امر نیز موجب زمان‌بر شدن روند ساخت شبکه و نیاز به سیستم پردازشی قدرتمند خواهد شد [۶۵-۶۸]. در روش دوم، از قابلیت یادگیری و استخراج ویژگی‌ها اساسی در شبکه‌های از پیش تعلیم‌یافته برای تعلیم مجدد شبکه بر اساس داده‌های جدید استفاده می‌شود و این امر امکان ساخت مدل در زمان کمتر، با تعداد داده‌های کمتر و با صرف توان پردازشی کمتر را فراهم می‌آورد [۶۹-۷۲].

لایه‌های شبکه v5l, v5m, v5s, v5n و v5x که توسط YOLOv5 ارائه می‌شود، از کوچک به بزرگ و پارامترهای شبکه نیز از کوچک به بزرگ افزایش می‌یابد. به منظور به دست آوردن تأثیر مدل‌ها با اندازه‌های مختلف بر اثر تشخیص، از پنج مدل برای مقایسه و تجزیه و تحلیل مجموعه داده‌های ترک جمع‌آوری شده در این مقاله استفاده می‌شود. در این پژوهش از یادگیری انتقالی جهت آموزش مجدد الگوریتم‌های سری YOLOv5 که بر اساس مجموعه داده اشیا مشترک در زمینه (COCO) با ۳۳۰ هزار تصویر و ۸۰ کلاس آموزش دیده شده بودند استفاده شده است

اطلاعات ناهمواری و شیارشدگی سطح جاده برای تصمیم‌گیری بهتر در درخت تصمیم‌گیری به عنوان مکمل نتایج پیش‌بینی شده استفاده شده است. با توجه اینکه طول پیش‌بینی شده برای ترک‌ها در واقع مقدار اندازه‌گیری شده برای یک خط افقی یا عمودی است، لذا در محاسبه طول ترک‌های خطی با توجه به روابط مثلثاتی و ابعاد تصویر، حداکثر ۳ درصد خطا وجود دارد که این خطای محاسباتی در تصمیم‌گیری برای پیش‌بینی اقدام مورد نیاز تأثیرگذار نیست.



S Crack = ترک سطحی
L crack = ترک خطی
Sum = درصد ترک‌های تجمع شده

شکل ۶: درخت تصمیم‌گیری جهت تعیین رویکرد تعمیر و نگهداری

۴- آموزش و ارزیابی مدل و پیش‌بینی ترک

۴-۱- محیط مدل‌سازی

تمام الگوریتم‌های این مقاله توسط زبان برنامه‌نویسی

³ Pre-trained

¹ Google Colab

² Transfer learning

یکی از پارامترهای مهم در ارزیابی مدل‌ها است که میزان دقت و اعتمادپذیری پاسخ‌های مثبت مدل‌ها را مشخص می‌کند یا به عبارت دیگر احتمال صحیح بودن پاسخ‌های مثبت مدل‌ها را تعیین می‌کند. این معیار مطابق رابطه ۱ محاسبه می‌شود. معیار Recall میزان توانایی و حساسیت مدل‌ها را در انجام دسته‌بندی صحیح مشخص می‌کند. مطابق رابطه ۲ این امر با محاسبه نسبت پاسخ‌های مثبت صحیح به مجموع پاسخ‌های مثبت صحیح و پاسخ‌های منفی غلط انجام می‌شود. این معیار همچنین با نام‌های نرخ پاسخ مثبت صحیح و میزان صحت مدل نیز شناخته می‌شود. یکی از جامع‌ترین معیارهای ارزیابی دقت و عملکرد مدل‌های دسته‌بندی و پیش‌بینی، معیار F1-score است که مطابق رابطه ۳ با محاسبه میانگین همسان وزنی دو معیار Precision و Recall تعیین می‌شود [۷۶-۷۸].

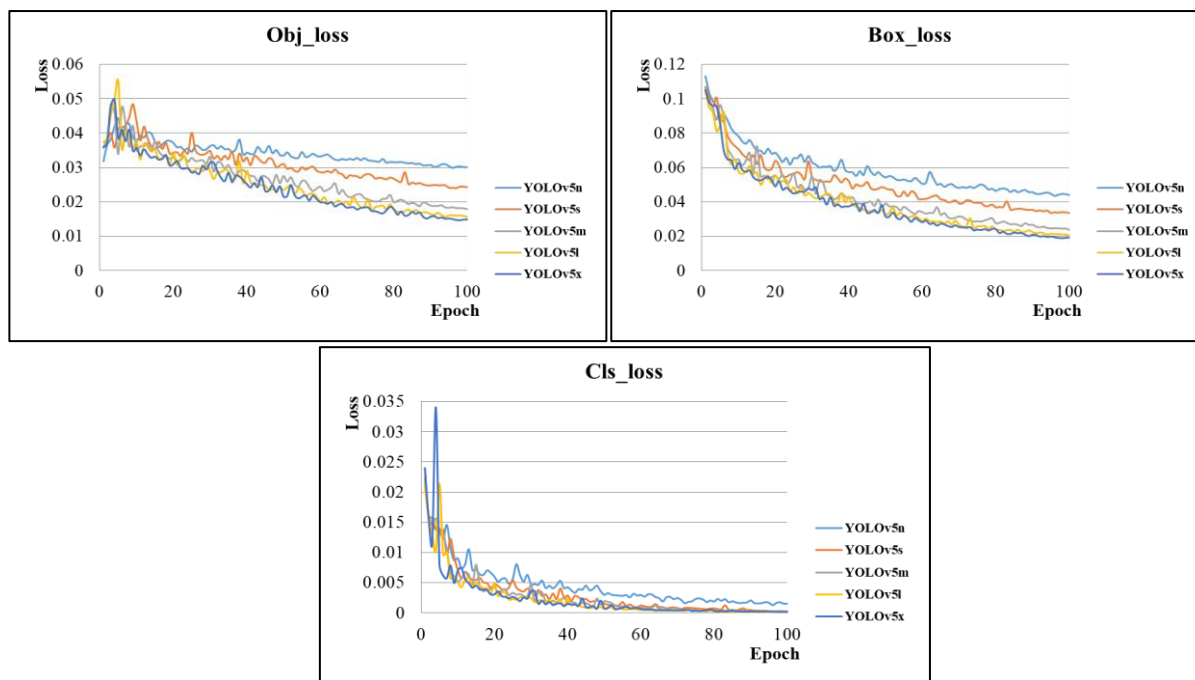
$$Precision = \frac{TP}{TP + FP} \quad (1)$$

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

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

[۷۳، ۷۴]. مدل‌سازی با اندازه دسته ۱۶ و ۱۰۰ دوره انجام شده است. روند تابع زیان فرایند آموزش پنج مدل در شکل (۶) نشان داده شده است. loss میزان خطای شبکه را در هر مرحله نشان می‌دهد. obj-loss برای بررسی اطمینان از حضور شی در تصویر، box-loss برای تعیین خطای چارچوب پیش‌بینی شده برای هر شی و cls-loss خطای دسته‌بندی شی است [۷۵]. از شکل (۷) می‌توان دریافت که در فرآیند با تعداد تکرار مشابه، مدل با لایه‌های عمیق‌تر اثر آموزشی بهتر و هم‌گرایی سریع‌تری دارد. مدل v5n در دوره بیشتری به تعادل رسیده و خطا کمینه شده است ولی در مدل v5x، خطای مدل در دوره‌های پایین‌تری کمینه شده است که نشان‌دهنده این است که وزن‌ها بهتر بهینه شده‌اند. به منظور آزمایش عملکرد مدل YOLOv5 در تشخیص ترک روسازی، این مدل بر روی مجموعه داده شرح داده شده در بخش ۳-۱ آزمایش می‌شود. در این مقاله از معیارهای Precision، Recall، F1 و mAP برای ارزیابی الگوریتم‌های مختلف طبقه‌بندی ترک استفاده شده است. سه معیار اول به ترتیب با TP (مثبت واقعی)^۱، TN (منفی واقعی)، FP (مثبت کاذب)^۲ و FN (منفی کاذب)^۳ محاسبه می‌شود.

تعاریف در جدول ۱ نشان داده شده است. معیار Precision



شکل ۷: روند تابع زیان فرایند آموزش

³ False Negative

¹ True Positive

² True Negative

[۶۷]. اثر تشخیص مدل با منحنی P-R توصیف می‌شود (شکل ۸ را برای جزئیات ببینید).

همان‌طور که گفته شد در روند آموزش، از وزن‌های از قبل آموزش داده شده (YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l و YOLOv5x) ارائه شده توسط YOLOv5 برای آموزش استفاده می‌شود. در فرایند آزمایش، باید اطمینان حاصل شود که تنظیمات پارامترها و وزن‌های آموزش، مانند پارامترهای نرخ یادگیری و تکانه یکسان است.

با توجه به جدول ۲، مشاهده می‌شود که مدل با بالاترین دقت تشخیص YOLOv5x است که mAP به ۰/۹۸۷۴ می‌رسد. با این حال، دقت تشخیص بین چهار مدل v5s, v5m, v5l و v5x تفاوت زیادی ندارد و حداکثر اختلاف ۰/۰۴ است. کوچک‌ترین مدل شبکه، مدل YOLOv5n است که تنها ۱/۹ میلیون پارامتر دارد. با توجه به اندازه‌های مختلف مدل، در فرایند تشخیص، مدل کوچک، زمان کمتری می‌برد. برعکس، مدل بزرگ به زمان بیشتری نیاز دارد؛ بنابراین، برای پنج مدل ذکر شده در بالا، کم‌ترین زمان برای مدل YOLOv5n است.

جدول ۱: تعاریف شاخص‌های استفاده شده در روابط

نماد	تعریف
TP	به تعداد ترک‌هایی اشاره دارد که به درستی به عنوان ترک طبقه بندی شده‌اند
TN	به تعداد پس‌زمینه‌هایی اشاره دارد که به درستی به عنوان پس‌زمینه طبقه بندی شده‌اند
FP	به تعداد پس‌زمینه‌هایی اطلاق می‌شود که به اشتباه به عنوان پس‌زمینه شناسایی شده‌اند
FN	به تعداد ترک‌هایی اشاره دارد که به اشتباه به عنوان پس-زمینه شناسایی شده‌اند

هم precision و هم recall در منحنی P-R میزان تشخیص نمونه‌های مثبت را در نظر می‌گیرند که خطای بین معیارهای ارزیابی را به دلیل عدم تعادل داده‌ها کاهش می‌دهد. هرچه منحنی P-R بالاتر و به سمت راست باشد، مدل عملکرد بهتری خواهد داشت. از آنجایی که منحنی P-R اغلب زیگزاگی است، قضاوت ذهنی است که آیا مدل خوب است یا خیر. یک راه بصری‌تر برای ارزیابی مدل‌ها دقت متوسط (AP) است که نشان دهنده ناحیه زیر منحنی^۱ (AUC) P-R است؛ بنابراین AP بالاتر یعنی مدل یادگیری ماشین بهتر است. mAP میانگینی از مقادیر AP است

جدول ۲: مقایسه عملکرد مدل‌های استفاده شده

مدل	زمان تشخیص (ms)	F1	Recall	Precision	mAP:0.5	تعداد پارامتر (M)
YOLOv5n	۱۷/۴	۰/۷۴	۰/۷۰۲۱	۰/۷۸۳۸	۰/۷۷۴۴	۱/۹
YOLOv5s	۲۳/۹	۰/۸۹	۰/۸۷۰۹	۰/۹۰۵۶	۰/۹۲۸	۷/۲
YOLOv5m	۵۳/۷	۰/۹۵	۰/۹۳۶۶	۰/۹۵۹۵	۰/۹۷۵۴	۲۱/۲
YOLOv5l	۸۹/۷	۰/۹۷	۰/۹۶۸۸	۰/۹۶۹	۰/۹۸۴۲	۴۶/۵
YOLOv5x	۱۰۵/۶	۰/۹۷	۰/۹۶۲۹۷	۰/۹۷۱	۰/۹۸۷۴	۸۶/۷

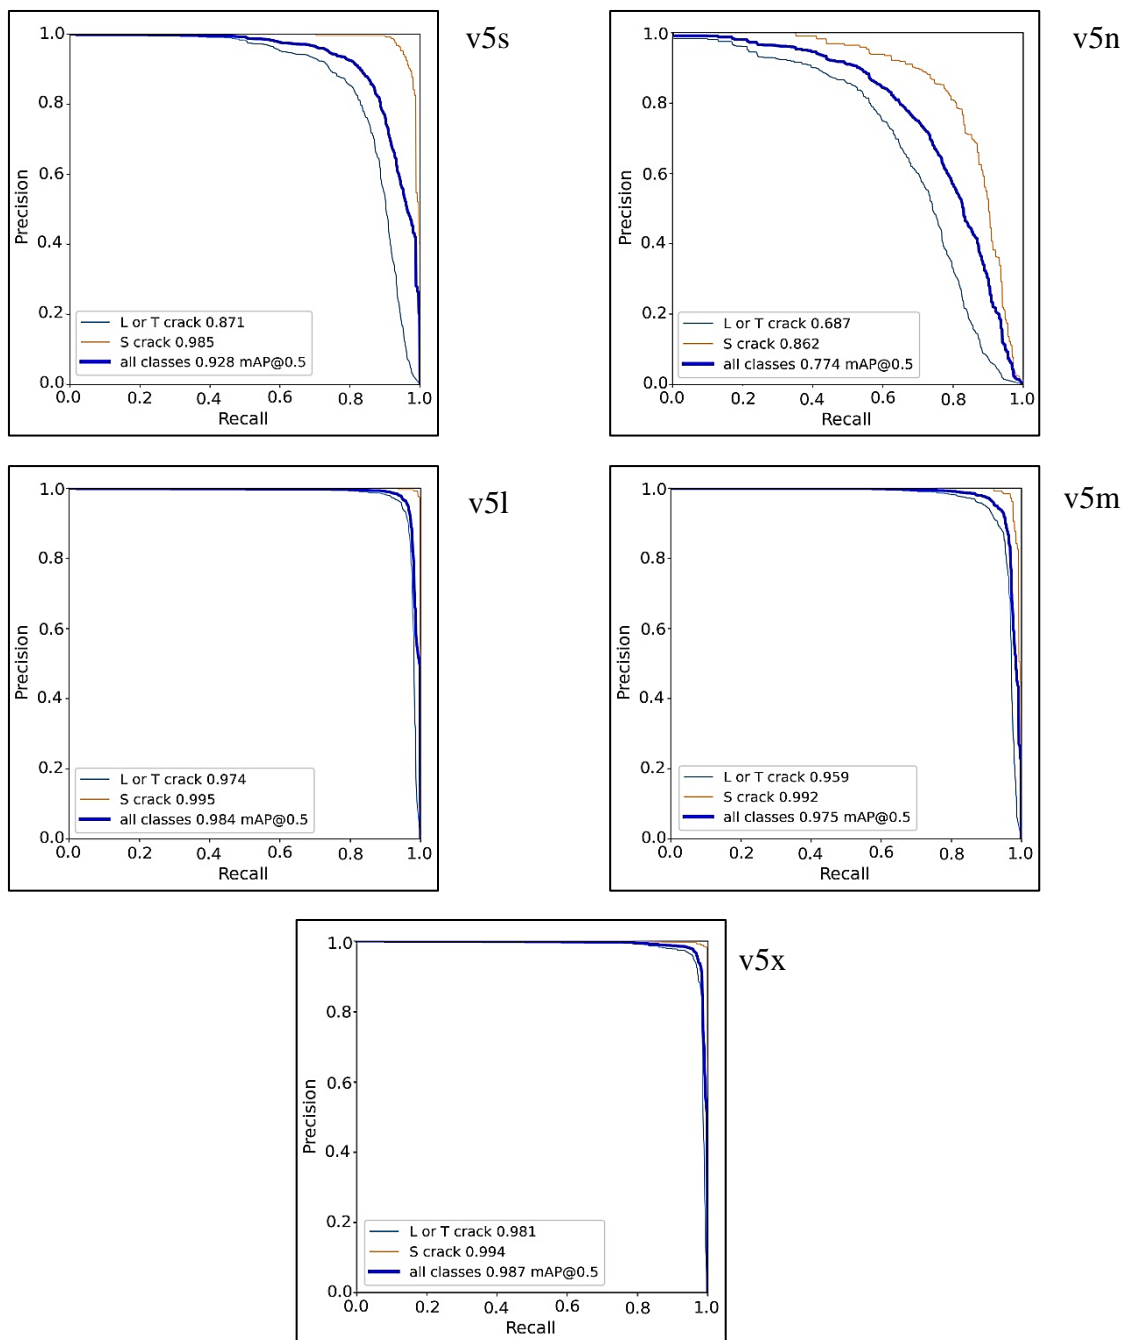
v5n تا ۱۰۵/۶ میلی ثانیه برای v5x متغیر است. تعدادی از نتایج پیش‌بینی شده توسط پنج مدل گفته شده در شکل (۹) نشان داده شده است. تفاوت زیادی بین دقت تشخیص مدل‌ها وجود ندارد و به غیر از v5n سایر مدل‌ها تمامی ترک‌ها را به درستی تشخیص داده‌اند. با توجه به شکل‌ها مشاهده می‌شود که ترک‌ها بر اساس نوع، موقعیت و ابعاد مشخص شده‌اند. ابعاد پیش‌بینی شده برای هر خرابی که شامل طول و عرض چارچوب محصورکننده آن است را می

پس از ساخت مدل و ارزیابی آن‌ها با استفاده از داده‌های آزمایشی، مدل‌های ساخته شده جهت پیش‌بینی ترک‌های روسازی آسفالتی یکی از خطوط کندرو بزرگراه کلانتری مشهد استفاده شد. تصاویر برداشت شده شامل ۲۲۵ تصویر با ابعاد ۹۹۴×۲۵۰۰ پیکسل و ابعاد واقعی ۳×۱۰ متر بود. با اعمال مدل‌های ساخته شده سری YOLOv5 بر روی این تصاویر ترک‌های مسیر شناسایی شدند. زمان تشخیص ترک‌ها برای پنج مدل ساخته شده از ۱۷/۴ میلی ثانیه برای


^۱ Area Under The Curve

طولی و عرضی و از مساحت آن برای ترک‌های سطحی استفاده می‌شود.

توان برای تعیین نوع اقدام لازم در فرایند تعمیر و نگهداری استفاده کرد. از طول این چارچوب برای طول ترک‌های




شکل ۸: نمودار P-R برای مدل‌های v5s, v5n, v5l, v5m و v5x



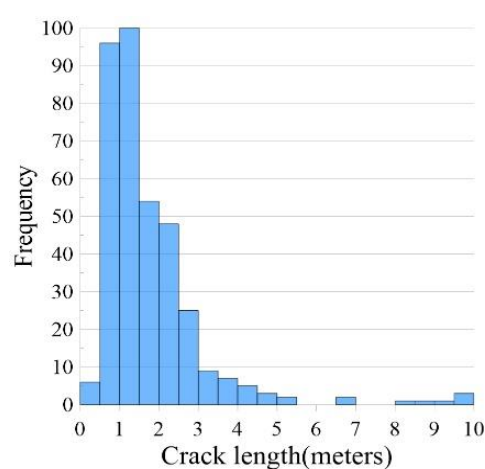
شکل ۹: نتایج پیش‌بینی‌شده مدل‌های سری YOLOv5 بر روی یک تصویر

حداقل و حداکثر درصد خرابی ۰/۴ درصد و ۶۲/۸ درصد شناسایی شد. در شکل (۱۰) هیستوگرام توزیع طول ترک‌های طولی و عرضی و مساحت ترک‌های سطحی آمده است.


پس از شناسایی ترک‌ها و ابعاد آن‌ها و پیاده‌سازی و اعمال الگوریتم درخت تصمیم بررسی ترک‌های پیش‌بینی شده برای هر قطعه تصویر ده متری، اقدام لازم جهت تعمیر و نگهداری تعیین شد که نتایج در شکل (۱۱) و جدول ۳ نشان داده شده است.



شکل ۱۰: هیستوگرام توزیع طول و سطح ترک‌های پیش‌بینی شده



هریک از اطلاعات را به صورت نقشه ارائه کند. با توجه به اینکه هر یک از تصاویر دارای مختصات جغرافیایی هستند لذا می‌توان تمامی نتایج به دست آمده را به صورت یک نقشه قابل درک برای سطوح مختلف سازمانی ارائه کرد تا به راحتی تصمیم‌سازی صورت گیرد (شکل ۱۲).



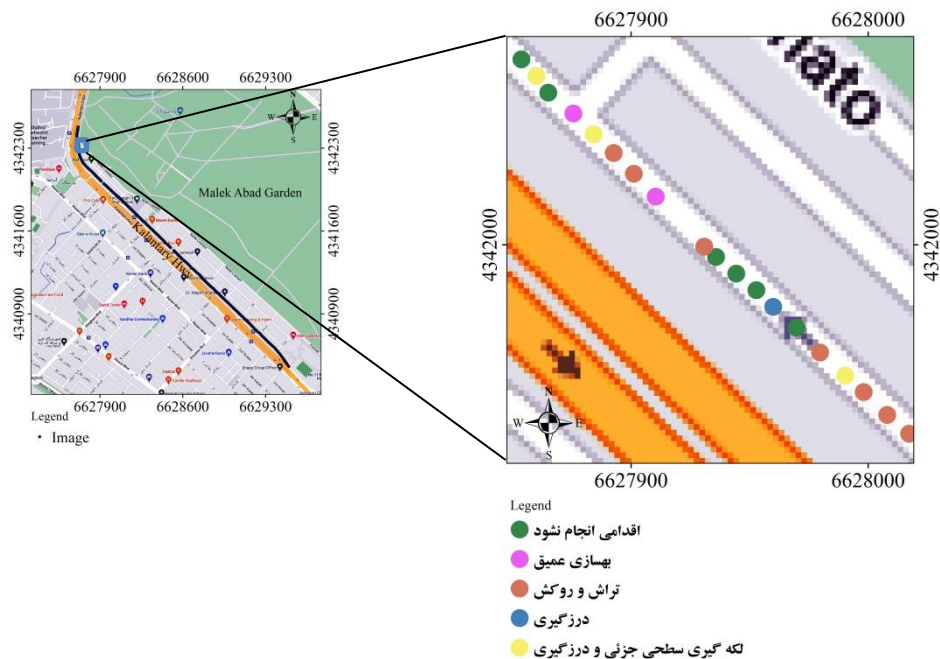
شکل ۱۱: درصد هر رویکرد در معبر بررسی شده

با مقایسه پنج مدل سری YOLOv5 بر اساس سرعت و دقت، نتایج مدل YOLOv5s با توجه به دقت قابل قبول و سرعت تشخیص بالا می‌تواند نیازهای مهندسی را برآورده کند؛ لذا نتایج این مدل به عنوان اطلاعات ورودی جهت تصمیم‌گیری برای اقدامات مورد نیاز تعمیر و نگهداری انتخاب شد. از مجموع ۲۲۵ تصویر، ۱۸۱ تصویر حاوی خرابی و ۴۴ تصویر بدون خرابی تشخیص داده شد. در کل تصاویر حاوی خرابی، ۳۶۳ ترک طولی و عرضی با حداقل و حداکثر طول ۰/۲ متر و ۹/۸ متر و ۱۶۱ ترک سطحی با

جدول ۳: رویکردهای پیش‌بینی شده در معبر بررسی شده

تعداد قطعه	رویکرد پیش‌بینی شده
۴۴	قطع‌های بدون ترک
۶۰	اقدامی انجام نشود
۲۸	درزگیری
۳۶	لکه‌گیری سطحی جزئی و درزگیری
۴۱	تراش و روکش
۱۶	بهسازی عمیق

تمام اطلاعات به دست آمده از این فرایند را می‌توان با استفاده از GIS به بهترین وجه نمایش داد. GIS می‌تواند



شکل ۱۲: نمایش نتایج مدیریت روسازی در GIS

۵- نتیجه‌گیری

نگهداری آینده استفاده کرد. ما در این پژوهش با استفاده از این نتایج و درخت تصمیم‌گیری پیشنهادی توانستیم به نتایج رضایت‌بخشی برسیم.

این تحقیق فقط بر روی تشخیص انواع مختلف ترک متمرکز شد. با توجه خرابی‌های متنوع روسازی شامل تغییر شکل‌ها، خرابی‌های سطحی و ترک‌های سطحی و خطی، پیشنهاد می‌شود جهت کارهای آتی عملکرد مدل YOLOv5 برای تشخیص انواع مختلف آسیب‌دیدگی روسازی آسفالتی ارزیابی شود. تشخیص خودکار ترک روسازی یکی از مطالب تحقیقی دشوار در زمینه تشخیص اشیا است. ویژگی‌های دقیق ترک روسازی با سطح جاده اطراف آن ارتباط معنایی دارد و فناوری تقسیم‌بندی معنایی بعدی را می‌توان برای بهبود بیشتر دقت تشخیص مدل ترکیب کرد. در همین حال، YOLO یک چارچوب تشخیص اشیا مبتنی بر لنگرها است. اگرچه YOLO در کاهش میزان محاسبات در مقایسه با یک مدل بدون لنگر بهینه‌سازی زیادی انجام داده است، اما هنوز به منابع محاسباتی زیادی در فرایند آموزش نیاز دارد. نرخ تشخیص مدل تشخیص سنتی بر اساس لنگرها بیشتر از مدل بدون لنگر است. چگونگی بهبود نرخ تشخیص و کاهش منابع مشکلی است که بسیاری از کاربردهای مهندسی باید در نظر بگیرند. Centernet2 یک چارچوب بدون لنگر را

نظارت بر وضعیت جاده، مانند عیوب سطحی و تشخیص ترک‌های روسازی، یک وظیفه مهم در مدیریت راه است. ترک‌خوردگی رایج‌ترین نوع مشکل روسازی است. در این پژوهش از شبکه‌های عصبی کانولوشن مبتنی بر تشخیص شی برای طبقه‌بندی ترک استفاده شد. با استفاده از الگوریتم YOLOv5 یکی از پیشرفته‌ترین مدل‌های تشخیص اشیا، امکان انتقال این مدل به تشخیص روسازی ترک را مورد بحث قرار گرفت. نتایج نشان داد که دقت تشخیص مدل‌های سری YOLOv5 به جز در ساده‌ترین مدل آن یعنی v5n، بالای ۹۰ درصد است و YOLOv5x با ۹۸/۷۴ درصد بیشترین دقت را به دست آورده است. به لحاظ زمانی، مدل‌های YOLOv5n و YOLOv5s به ۱۷/۴ و ۲۳/۹ میلی‌ثانیه برای تشخیص تصویر با ۶۴۰ × ۶۴۰ پیکسل نیاز دارند؛ بنابراین، اگر به نرخ تشخیص در پروژه واقعی توجه داشته باشیم، می‌توانیم از YOLOv5x استفاده کنیم. اگر لازم باشد هم نرخ تشخیص و هم کارایی تشخیص را در نظر بگیریم، می‌توانیم مدل YOLOv5s را انتخاب کنیم. در کنار سرعت تشخیص بالای الگوریتم YOLOv5 و دقت قابل قبول آن، از خروجی‌های آن که هم نوع ترک را مشخص می‌کنند هم موقعیت و هم ابعاد را، می‌توان به‌منظور مدیریت روسازی و تعیین رویکرد تعمیر و

بدین‌وسیله از اداره کل نظارت بر نگهداری و تعمیرات و اداره نگهداری و تعمیرات معابر و تقاطع‌های شهرداری مشهد به دلیل در اختیار قرار دادن مجموعه تصاویر برداشت‌شده از معابر شهر مشهد و حمایت در انجام این پژوهش کمال تشکر را داریم.

معرفی می‌کند و نرخ تشخیص این مدل از همه مدل‌های موجود بر اساس لنگرها بالاتر است. پیشنهاد centernet2 جهت کارهای بعدی پیشنهاد می‌شود. به‌منظور برآورده کردن الزامات یک مدل سبک‌وزن، در آینده تشخیص مبتنی بر بدون لنگر را مطالعه خواهد شد.

تقدیر و تشکر

مراجع

- [1] J. Tian, Y. Zhang, Y. Yao, X. Yao, C. Shi, and Y. Xu, "Road crack detection algorithm based on YOLOv3," in 2021 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS), 2021, pp. 39-42: IEEE.
- [2] P. Rosa, "Automatic pavement crack detection and classification system," *Transport. Res. Board*, vol. 11, 2012, pp. 57-65.
- [3] H.-N. Nguyen, T.-Y. Kam, and P.-Y. Cheng, "An automatic approach for accurate edge detection of concrete crack utilizing 2D geometric features of crack," *Journal of Signal Processing Systems*, vol. 77, no. 3, 2014, pp. 221-240.
- [4] Z. Yiyang, "The design of glass crack detection system based on image preprocessing technology," in 2014 IEEE 7th Joint International Information Technology and Artificial Intelligence Conference, 2014, pp. 39-42: IEEE.
- [5] Y. Yi, J. Wang, W. Zhou, Y. Fang, J. Kong, and Y. Lu, "Joint graph optimization and projection learning for dimensionality reduction," *Pattern Recognition*, vol. 92, 2019, pp. 258-273.
- [6] Y. Yi, Y. Chen, J. Wang, G. Lei, J. Dai, and H. Zhang, "Joint feature representation and classification via adaptive graph semi-supervised nonnegative matrix factorization," *Signal Processing: Image Communication*, vol. 89, 2020, p. 115984.
- [7] R. Rastgoo and K. Kiani, "Face recognition using fine-tuning of Deep Convolutional Neural Network and transfer learning," *Journal of Modeling in Engineering*, vol. 17, no. 58, 2019, pp. 103-111.
- [8] M. Golshan, M. Teshnehlab, and A. Sharifi, "A Modified Brain Emotional Learning Model Inspired By Online Recurrent Memory Sequential Extreme Learning Machine Based On Neural Networks," *Journal of Modeling in Engineering*, 2022.
- [9] E. Parsaeimehr, M. Fartash, and J. Akbari Torkestani, "An ensemble deep learning model to enhance feature representation for entity detection," *Journal of Modeling in Engineering*, vol. 20, no. 69, 2022.
- [10] D. Ma, H. Fang, B. Xue, F. Wang, M. A. Msekh, and C. L. Chan, "Intelligent detection model based on a fully convolutional neural network for pavement cracks," *Computer Modeling in Engineering & Sciences*, vol. 123, no. 3, 2020, pp. 1267-1291.
- [11] Y. Wang, K. Song, J. Liu, H. Dong, Y. Yan, and P. Jiang, "RENet: Rectangular convolution pyramid and edge enhancement network for salient object detection of pavement cracks," *Measurement*, vol. 170, 2021, p. 108698.
- [12] Y. Yi, J. Wang, W. Zhou, C. Zheng, J. Kong, and S. Qiao, "Non-negative matrix factorization with locality constrained adaptive graph," *IEEE Transactions on circuits and systems for video technology*, vol. 30, no. 2, 2019, pp. 427-441.
- [13] Y. J. Cha, W. Choi, and O. Büyüköztürk, "Deep learning-based crack damage detection using convolutional neural networks," *Computer-Aided Civil and Infrastructure Engineering*, vol. 32, no. 5, 2017, pp. 361-378.
- [14] F.-C. Chen and M. R. Jahanshahi, "NB-CNN: Deep learning-based crack detection using convolutional neural network and Naïve Bayes data fusion," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 5, 2017, pp. 4392-4400.
- [15] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 3431-3440.

- [16] X. Yang, H. Li, Y. Yu, X. Luo, T. Huang, and X. Yang, "Automatic pixel-level crack detection and measurement using fully convolutional network," *Computer-Aided Civil and Infrastructure Engineering*, vol. 33, no. 12, 2018, pp. 1090-1109.
- [17] F. Yang, L. Zhang, S. Yu, D. Prokhorov, X. Mei, and H. Ling, "Feature pyramid and hierarchical boosting network for pavement crack detection," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 4, 2019, pp. 1525-1535.
- [18] H. Chen, H. Lin, and M. Yao, "Improving the efficiency of encoder-decoder architecture for pixel-level crack detection," *IEEE Access*, vol. 7, 2019, pp. 186657-186670.
- [19] Z. Fan et al., "Ensemble of deep convolutional neural networks for automatic pavement crack detection and measurement," *Coatings*, vol. 10, no. 2, 2020, p. 152.
- [20] X. Xiang, Y. Zhang, and A. El Saddik, "Pavement crack detection network based on pyramid structure and attention mechanism," *IET Image Processing*, vol. 14, no. 8, 2020, pp. 1580-1586.
- [21] S. Zhou et al., "Automated detection and classification of spilled loads on freeways based on improved YOLO network," *Machine Vision and Applications*, vol. 32, no. 2, 2021, pp. 1-12.
- [22] E. U. Rahman, Y. Zhang, S. Ahmad, H. I. Ahmad, and S. Jobaer, "Autonomous vision-based primary distribution systems porcelain insulators inspection using UAVs," *Sensors*, vol. 21, no. 3, 2021, p. 974.
- [23] Q. Li, Q. Zou, D. Zhang, and Q. Mao, "FoSA: F* seed-growing approach for crack-line detection from pavement images," *Image and Vision Computing*, vol. 29, no. 12, 2011, pp. 861-872.
- [24] Q. Li and X. Liu, "Novel approach to pavement image segmentation based on neighboring difference histogram method," in *2008 Congress on Image and Signal Processing*, 2008, vol. 2, pp. 792-796: IEEE.
- [25] F. Liu, G. Xu, Y. Yang, X. Niu, and Y. Pan, "Novel approach to pavement cracking automatic detection based on segment extending," in *2008 International Symposium on Knowledge Acquisition and Modeling*, 2008, pp. 610-614: IEEE.
- [26] M. Gavilán et al., "Adaptive road crack detection system by pavement classification," *Sensors*, vol. 11, no. 10, 2011, pp. 9628-9657.
- [27] L. Q. M. Qingzhou, "Land-borne pavement rapid test and measurement," *Journal of Transport Information and Safety*, 2009.
- [28] Y. Hu, C.-x. Zhao, and H.-n. Wang, "Automatic pavement crack detection using texture and shape descriptors," *IETE Technical Review*, vol. 27, no. 5, 2010, pp. 398-405.
- [29] A. Cord and S. Chambon, "Automatic road defect detection by textural pattern recognition based on AdaBoost," *Computer-Aided Civil and Infrastructure Engineering*, vol. 27, no. 4, 2012, pp. 244-259.
- [30] Y. Shi, L. Cui, Z. Qi, F. Meng, and Z. Chen, "Automatic road crack detection using random structured forests," *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 12, 2016, pp. 3434-3445.
- [31] N.-D. Hoang and Q.-L. Nguyen, "A novel method for asphalt pavement crack classification based on image processing and machine learning," *Engineering with Computers*, vol. 35, no. 2, 2019, pp. 487-498.
- [32] H. Li, J. Zong, J. Nie, Z. Wu, and H. Han, "Pavement crack detection algorithm based on densely connected and deeply supervised network," *IEEE Access*, vol. 9, 2021, pp. 11835-11842.
- [33] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiyama, and H. Omata, "Road damage detection using deep neural networks with images captured through a smartphone," *arXiv preprint arXiv:1801.09454*, 2018.
- [34] X. Wang and Z. Hu, "Grid-based pavement crack analysis using deep learning," in *2017 4th international conference on transportation information and safety (ICTIS)*, 2017, pp. 917-924: IEEE.
- [35] B. Kim and S. Cho, "Automated vision-based detection of cracks on concrete surfaces using a deep learning technique," *Sensors*, vol. 18, no. 10, 2018, p. 3452.
- [36] 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, 2017, pp. 805-819.
- [37] Y. Fei et al., "Pixel-level cracking detection on 3D asphalt pavement images through deep-learning-based CrackNet-V," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 1, 2019, pp. 273-284.
- [38] Q. Zou, Z. Zhang, Q. Li, X. Qi, Q. Wang, and S. Wang, "Deepcrack: Learning hierarchical convolutional features for crack detection," *IEEE Transactions on Image Processing*, vol. 28, no. 3, 2018, pp. 1498-1512.

- [39] G. X. Hu, B. L. Hu, Z. Yang, L. Huang, and P. Li, "Pavement Crack Detection Method Based on Deep Learning Models," *Wireless Communications and Mobile Computing*, vol. 2021, 2021.
- [40] Z.-Q. Zhao, P. Zheng, S.-t. Xu, and X. Wu, "Object detection with deep learning: A review," *IEEE transactions on neural networks and learning systems*, vol. 30, no. 11, 2019, pp. 3212-3232.
- [41] Z. Zou, Z. Shi, Y. Guo, and J. Ye, "Object detection in 20 years: A survey," *arXiv preprint arXiv:1905.05055*, 2019.
- [42] A. R. Pathak, M. Pandey, and S. Rautaray, "Application of deep learning for object detection," *Procedia computer science*, vol. 132, 2018, pp. 1706-1717.
- [43] 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.
- [44] 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.
- [45] R. Girshick, "Fast r-cnn," in *Proceedings of the IEEE international conference on computer vision*, 2015, pp. 1440-1448.
- [46] 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.
- [47] G. Jocher. (2020, 21 April). Available: <https://github.com/ultralytics/yolov5>
- [48] A. I. Magazine. (2020, 10 February). Guide to Yolov5 for Real-Time-Object Detection. Available: <https://analyticsindiamag.com/yolov5/>
- [49] J. Yao, J. Qi, J. Zhang, H. Shao, J. Yang, and X. Li, "A real-time detection algorithm for Kiwifruit defects based on YOLOv5," *Electronics*, vol. 10, no. 14, 2021, p. 1711.
- [50] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," *arXiv preprint arXiv:1804.02767*, 2018.
- [51] A. Kuznetsova, T. Maleva, and V. Soloviev, "YOLOv5 versus YOLOv3 for apple detection," in *Cyber-Physical Systems: Modelling and Intelligent Control: Springer*, 2021, pp. 349-358.
- [52] 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.
- [53] Y. Fang, X. Guo, K. Chen, Z. Zhou, and Q. Ye, "Accurate and Automated Detection of Surface Knots on Sawn Timbers Using YOLO-V5 Model," *BioResources*, vol. 16, no. 3, 2021.
- [54] F. Zhou, H. Zhao, and Z. Nie, "Safety helmet detection based on YOLOv5," in *2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA)*, 2021, pp. 6-11: IEEE.
- [55] 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 conference on computer vision and pattern recognition workshops*, 2020, pp. 390-391.
- [56] 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.
- [57] M. Tan, R. Pang, and Q. V. Le, "Efficientdet: Scalable and efficient object detection," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 10781-10790.
- [58] 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.
- [59] B. Xu, N. Wang, T. Chen, and M. Li, "Empirical evaluation of rectified activations in convolutional network," *arXiv preprint arXiv:1505.00853*, 2015.
- [60] J. Turian, J. Bergstra, and Y. Bengio, "Quadratic features and deep architectures for chunking," in *Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics, Companion Volume: Short Papers*, 2009, pp. 245-248.
- [61] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv preprint arXiv:1609.04747*, 2016.

- [62] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv preprint arXiv:1412.6980, 2014.
- [63] D. Thuan, "Evolution of yolo algorithm and yolov5: the state-of-the-art object detection algorithm," 2021.
- [64] W. Wu et al., "Application of local fully Convolutional Neural Network combined with YOLO v5 algorithm in small target detection of remote sensing image," PloS one, vol. 16, no. 10, 2021, p. e0259283.
- [65] S. Albelwi and A. Mahmood, "A framework for designing the architectures of deep convolutional neural networks," Entropy, vol. 19, no. 6, 2017, p. 2427.
- [66] D. Cires, U. Meier, J. Masci, L. Gambardella, and J. Schmidhuber, "High Performance Convolutional Neural Networks for Image Classification," in Proceedings of 22nd International Joint Conference on Artificial Intelligence, pp. 1237-1242.
- [67] J. Snoek, H. Larochelle, and R. P. Adams, "Practical bayesian optimization of machine learning algorithms," Advances in neural information processing systems, vol. 25, 2012.
- [68] L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, and A. Talwalkar, "Hyperband: A novel bandit-based approach to hyperparameter optimization," The Journal of Machine Learning Research, vol. 18, no. 1, 2017, pp. 6765-6816.
- [69] K. Gopalakrishnan, S. K. Khaitan, A. Choudhary, and A. Agrawal, "Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection," Construction and building materials, vol. 157, 2017, pp. 322-330.
- [70] K. Zhang, H. Cheng, and B. Zhang, "Unified approach to pavement crack and sealed crack detection using preclassification based on transfer learning," Journal of Computing in Civil Engineering, vol. 32, no. 2, 2018, p. 04018001.
- [71] Y. Gao and K. M. Mosalam, "Deep transfer learning for image-based structural damage recognition," Computer-Aided Civil and Infrastructure Engineering, vol. 33, no. 9, 2018, pp. 748-768.
- [72] K. Weiss, T. M. Khoshgoftaar, and D. Wang, "A survey of transfer learning," Journal of Big data, vol. 3, no. 1, 2016, pp. 1-40.
- [73] M. Kasper-Eulaers, N. Hahn, S. Berger, T. Sebulonsen, Ø. Myrland, and P. E. Kummervold, "Detecting heavy goods vehicles in rest areas in winter conditions using YOLOv5," Algorithms, vol. 14, no. 4, 2021, p. 114.
- [74] H. Zhang, M. Tian, G. Shao, J. Cheng, and J. Liu, "Target Detection of Forward-Looking Sonar Image Based on Improved YOLOv5," IEEE Access, vol. 10, 2022, pp. 18023-18034.
- [75] Z. Chen et al., "Plant Disease Recognition Model Based on Improved YOLOv5," Agronomy, vol. 12, no. 2, 2022, p. 365.
- [76] J. D. Kelleher, B. Mac Namee, and A. D'arcy, Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies. MIT press, 2020.
- [77] A. Burkov, The hundred-page machine learning book. Andriy Burkov Quebec City, QC, Canada, 2019.
- [78] C. M. Bishop and N. M. Nasrabadi, Pattern recognition and machine learning (no. 4). Springer, 2006.