

طبقه‌بندی و کمی‌سازی خودکار ترک روسازی آسفالتی با استفاده از الگوریتم‌های تشخیص اشیا مبتنی بر یادگیری عمیق

مقاله علمی - پژوهشی

حسن حسین‌زاده*، دانشجوی کارشناسی ارشد، دانشکده فنی و مهندسی، مؤسسه آموزش عالی اقبال لاهوری، مشهد، ایران
علی قیامی باجگیرانی، استادیار، دانشکده فنی و مهندسی، مؤسسه آموزش عالی اقبال لاهوری، مشهد، ایران
محدثه دلاوریان، استادیار، دانشکده فنی و مهندسی، مؤسسه آموزش عالی اقبال لاهوری، مشهد، ایران
*پست الکترونیکی نویسنده مسئول: hosseinzadeh.hassan@eqbal.ac.ir

دریافت: ۱۴۰۳/۰۸/۰۱ - پذیرش: ۱۴۰۴/۰۳/۰۱

صفحه ۳۱۵-۳۲۸

چکیده

تشخیص ترک روسازی یک روش مهم در تعمیر و نگهداری جاده و ایمنی ترافیک است. به طور سنتی، ارزیابی وضعیت جاده با بازرسی میدانی انجام می‌شد که باتوجه به صرف زمان و هزینه زیاد و وابسته بودن نتایج به نظر ارزیاب باید با روش‌های خودکار جایگزین شود تا هم حجم کار و در نتیجه هزینه‌های تعمیر و نگهداری را کاهش یابد. این مقاله به بررسی عملکرد الگوریتم‌های YOLOv3 و YOLOv5 برای تشخیص خودکار ترک به می‌پردازد. این مدل‌ها قادر هستند نوع، موقعیت و مشخصات هندسی ترک را با دقت و سرعت بالایی نسبت به روش‌های دیگر مشخص کنند. به منظور مدل‌سازی، از تصاویر برداشت شده از معابر سطح مشهد استفاده شده است. این تصاویر برای گزینه‌های ترک خطی و سطحی برچسب‌گذاری شدند. سپس مدل‌هایی با به کارگیری مدل v3 و پنج الگوریتم سری v5 و یادگیری انتقالی، ایجاد و از نظر دقت و سرعت پیش‌بینی مورد ارزیابی قرار گرفتند. دقت مدل‌ها بین ۷۷ تا ۹۸ درصد و سرعت پیش‌بینی مدل‌ها بین ۱۷/۴ و ۱۰۵ میلی‌ثانیه است که بیانگر عملکرد مطلوب مدل‌ها است. در نهایت مدل v5s باتوجه به دقت قابل قبول (۹۲/۸) و سرعت بالای پیش‌بینی (۲۳/۹ میلی‌ثانیه) به نسبت سایر مدل‌ها به عنوان مدل مطلوب جهت پیش‌بینی ترک‌ها در یکی از معابر مشهد استفاده شد. سپس براساس خروجی‌های مدل، رویکرد تعمیر و نگهداری ارائه گردید.

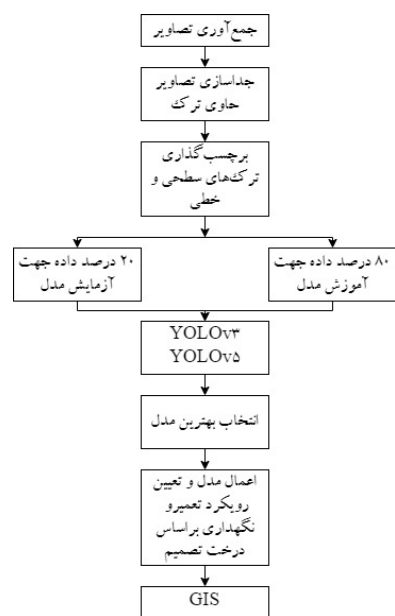
واژه‌های کلیدی: مدیریت روسازی، تشخیص خودکار ترک، یادگیری عمیق، YOLOv3، YOLOv5

۱-مقدمه

2018; Nie et al., 2019; Pauly et al., 2017; Yang et al., 2021; A. Zhang et al., 2018; Zhang et al., 2016). الگوریتم‌های تشخیص اشیا مبتنی بر یادگیری عمیق را می‌توان به دو گروه دسته‌بندی کرد. اولین مورد آشکارسازهای دو مرحله‌ای است، که شامل شبکه‌های نماینده مانند R-CNN (شبکه‌های عصبی کانولوشن مبتنی بر منطقه سریع و R-CNN سریع‌تر است) (Girshick, 2015; Liu et al., 2017; (Soviany et al., 2018). این روش‌ها، ابتدا مجموعه زیادی

بسیاری از سیستم‌های پیشرفته مبتنی بر هوش مصنوعی برای شهرها و جوامع هوشمند پایدار بر روی شبکه‌های عصبی عمیق ساخته شده‌اند که به دلیل عملکرد بهبودیافته این شبکه‌ها در مقایسه با سایر تکنیک‌های یادگیری ماشینی موجود است (Buduma et al., 2022; Ian et al., 2016). محققان به دلیل کاربردهای متنوع این سیستم‌ها از آن‌ها برای تشخیص خرابی‌های روسازی آسفالتی استفاده زیادی کرده‌اند (Chen et al., 2017; Hsieh et al., 2020; Mandal et al.,

مجموعه داده‌ها جدا شوند. با برجسب گذاری به طور تصادفی باید تصاویر به مجموعه آموزشی، مجموعه آزمایش و مجموعه اعتبارسنجی تقسیم شوند. سپس، مدل تشخیص YOLOv3 و مدل‌های تشخیص v5x، v5l، YOLOv5m، v5s، v5n و در سری YOLOv5 را آزمایش کرده و از نظر دقت و سرعت مقایسه خواهند شد. برحسب نرخ تشخیص و کارایی، مدلی که دارای سرعت و دقت قابل قبول است و نیاز مهندسی ما را برآورده می‌کند شناسایی و در نهایت از مدل ارزیابی شده برای پیش‌بینی ترک‌های یکی از معابر اصلی شهر مشهد استفاده خواهد شد که بر اساس خروجی‌های به دست آمده 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، پیشنهاداتی ارائه می‌گردد. فرآیند تحقیق در شکل ۱ نشان داده شده است.



شکل ۱. فرآیند تشخیص ترک

۲- پیشینه تحقیق

با توسعه سریع تحقیقات در تشخیص ترک، بسیاری از محققین پژوهش‌های زیادی را در این راستا انجام داده‌اند که عملکرد قابل توجهی در تشخیص خرابی‌های جاده دارند. این مقالات را می‌توان به چند گروه دسته‌بندی کرد، مانند روش‌های آستانه شدت، روش‌های مبتنی بر فیلتر، روش‌های انتخاب مسیر حداقل، روش‌های یادگیری ماشین و روش یادگیری عمیق. روش‌های

پیشنهاد یا همان چارچوب برای هر تصویر تولید می‌کنند. سپس، هر یک از پیشنهادها به یک سائز مشخص تغییر سائز می‌شوند و برای استخراج ویژگی در اختیار شبکه‌های عصبی کانولوشن قرار می‌گیرند. در نهایت، یک طبقه‌بندی‌کننده برای طبقه‌بندی کردن این چارچوب تولید شده بکار برده می‌شود. این مدل‌ها دقیق‌ترینند، اما زمان‌بر نیز هستند (Soviany et al., 2018). گروه دوم آشکارسازهای یک مرحله‌ای هستند، مانند YOLO سری‌های آن که تشخیص شی را به عنوان یک مشکل رگرسیون ساده در نظر می‌گیرد، مرحله پیشنهاد در اینجا نادیده گرفته می‌شود و محلی‌سازی و طبقه‌بندی شی هر دو در یک مرحله تکمیل می‌شوند. این مدل‌ها نسبت به آشکارسازهای دو مرحله‌ای دقت کمتری دارند، اما سریع‌تر هستند، که آن‌ها را برای سیستم‌های بلادرنگ مناسب می‌کند (Bochkovski et al., 2020; Jocher, 2020; Liu et al., 2018; Magazine, 2020; Redmon et al., 2018).

نظارت بر سطوح جاده برای نگهداری خوب جاده‌ها اهمیت حیاتی دارد و امکان کیفیت بالاتر خدمات حمل‌ونقل و متعاقباً توسعه را فراهم می‌کند (Hou, 2019). ترک خوردگی رایج‌ترین نوع آسیب روسازی است (Shahin, 1994). تشخیص سریع و دقیق ترک‌های روسازی برای ارزیابی یکپارچگی روسازی و بهبود سطح نگهداری جاده مفید است و برای اطمینان از ایمنی ترافیک اهمیت زیادی دارد (Rosa, 2012). روش‌های تشخیص ترک روسازی موجود به انسان برای استخراج دستی ویژگی‌های تصویر و شناسایی ترک‌های روسازی متکی است. این روش نادرست است و خطاها به راحتی رخ می‌دهد زیرا افراد مختلف قضاوت‌های متفاوتی ارائه می‌دهند. بنابراین قضاوت عینی و علمی در مورد خرابی‌های راه دشوار است. همچنین بازرسی بصری انسان، نیروی انسانی و زمان زیادی را مصرف می‌کند (Desai, 2020; Nguyen et al., 2014). به منظور دستیابی به مدل تشخیص کارآمد، سریع و دقیق ترک‌های روسازی، بازرسی بصری انسان را می‌توان با روش‌های تشخیص خودکار جایگزین کرد.

این مطالعه به منظور بررسی عملکرد الگوریتم‌های تشخیص اشیای مبتنی بر یادگیری عمیق در تشخیص ترک روسازی آسفالتی، دو الگوریتم تک‌مرحله‌ای YOLOv3 و YOLOv5 آزمایش و نتایج آن‌ها را با یکدیگر مقایسه می‌کند. در این پژوهش ابتدا، تصاویر برداشت شده از روسازی را که دارای ترک خوردگی خطی و سطحی هستند، می‌بایست شناسایی و از

همکاران (Fei et al., 2019) یک شبکه عمیق کارآمد به نام شبکه ترک V مبتنی بر شبکه ترک پیشنهاد داده‌اند که برای تشخیص خودکار ترک سطح پیکسل در تصویر سه بعدی روسازی آسفالت بکار رفته است. در مقایسه با شبکه ترک اصلی، شبکه ترک V از اندازه فضای مشابهی برای تمامی لایه‌ها استفاده می‌کند بنابراین یادگیری نظارت شده می‌تواند در سطح پیکسل انجام شود. کارایی شبکه ترک V نشان دهنده مزیت تکنولوژی یادگیری عمیق در تشخیص خودکار ترک با توجه به تصاویر است. زو و همکاران (Zou et al., 2018) یک شبکه عصبی کانولوشن عمیق آموزش‌پذیر برای تشخیص خودکار شکستگی ارائه کرده‌اند که شکستگی عمیق نام دارد و ویژگی‌های پیشرفته نمایش شکستگی را یاد می‌گیرد. ویژگی‌های کانولوشن عمیق چندمقیاسی یاد گرفته شده از لایه‌های کانولوشن مختلف با یکدیگر ادغام می‌شوند تا یک ساختار خطی را تشکیل دهند. ویژگی‌های تصویر بدست آمده 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-رمزگشای 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 شی ارائه‌شده تاکنون و استفاده از آن‌ها در تشخیص روسازی ترک‌دار می‌توان کارایی تشخیص روسازی آسیب‌دیده را تا حد زیادی بهبود داد.

۳- مفاهیم نظری

YOLO یک شبکه عصبی کانولوشنال عمیق تک‌مرحله‌ای است که می‌تواند اشیا را در یک تک توزیعی روبه‌جلو، با استفاده از شبکه عصبی تشخیص دهد که این امر باعث می‌شود برای استفاده عملی، گزینه مناسبی باشد. الگوریتم YOLO ابتدا تصویر ورودی را دریافت و سپس آن را به SXS سلول شبکه‌ای تقسیم می‌کند. هر سلول مجموعه‌ای از چارچوب‌ها را تولید می‌کند. چارچوب پیش‌بینی می‌کند که آیا آن سلول شامل شی هست یا خیر و یک ضریب اعتماد بازمی‌گرداند. سپس، YOLO

مبتنی بر پردازش تصویر عمدتاً با مقایسه مقدار رنگ خاکستری روسازی ترک‌دار و پس‌زمینه‌اش تشخیص را انجام می‌دهد (Li et al., 2011; Liu et al., 2008). اما، نرخ تشخیص به دلیل پس‌زمینه پیچیده روسازی، نورپردازی متفاوت و تنوع انواع ترک، پایین است. مدل‌های تشخیص مبتنی بر الگوریتم یادگیری ماشین تا حد زیادی وابسته به ویژگی‌هایی است که به طور 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 زیاده 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 و کار بسیار دشواری است (Cord et al., 2012; Hoang et al., 2019). در مجموع، مدل تشخیص مبتنی بر یادگیری ماشینی را می‌توان تنها در یک حوزه کوچک و نه کلی به کار برد. در سال‌های اخیر، با توسعه روش یادگیری عمیق، امکان تشخیص روسازی شکسته به طور خودکار بر اساس مدل یادگیری عمیق فراهم شده است. مدل شبکه‌های عصبی انتشار پیچیده با یادگیری نمونه ترک‌های مختلف عملکرد تشخیص خودکار ترک را تا حد زیادی بهبود بخشیده است. بعضی محققان از روش‌های تشخیص شی (H. Li et al., 2018; Maeda et al., 2021) یا بخش‌بندی تصویر (Kim et al., 2017; Wang et al., 2018) برای استخراج ترک‌ها استفاده کرده‌اند.

این روش‌ها نمی‌توانند شکستگی‌ها را در سطح پیکسل استخراج کنند و همچنین نمی‌توانند نوع آسیب دیدگی و شدت آن را به درستی تعیین کنند. ژانگ و همکاران (Zhang et al., 2017) 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 سه بعدی است. برخلاف CNN‌های متداول، شبکه شکستگی هیچ لایه ادغامی برای کاهش خروجی لایه قبلی ندارد. شبکه ترک 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



۳-۱- الگوریتم YOLOv3

الگوریتم Darknet-53. ستون فقرات YOLOv3 است که تشکیل شده از ۵۳ لایه کانولوشنی که مسئول استخراج اطلاعات مربوطه از تصویر ورودی است. یکی از مهم‌ترین کاربردهای آن، به‌کارگیری FPN (شبکه با خصوصیت هرمی) است (Lin et al., 2017). این عمل که تشکیل شده از چندین مسیر پایین به بالا و بالا به پایین، برای استخراج نقشه ویژگی‌ها از چندین تصویر، ضروری است. در عین حال، بخش سر نیز از لایه YOLO تشکیل شده است. در یک شناساگر تک مرحله‌ای، کاربرد سر، انجام آخرین پیش‌بینی است، که برای این منظور، از یک بردار مختصات کادر محصور کننده، عرض، طول و عنوان کلاس و همچنین، احتمالش تشکیل شده است. تصویر، ابتدا توسط Darknet-53 پردازش می‌شود که در نتیجه آن، ویژگی‌ها پیش از اینکه در یک شبکه هرمی به کار رفته و ترکیب شوند، استخراج می‌شوند. در نهایت، نتایج توسط لایه YOLO ایجاد می‌شوند (Redmon et al., 2018). می‌توانید این فرآیند را در شکل ۳ ببینید.

احتمالات کلاس برای هر شی داخل کادرهای محصورکننده را مشخص کرده و مشخصه‌های کادر محصورکننده شامل مختصات مرکز، طول و عرض و ضریب اعتماد را تعریف می‌کند (Bochkovski et al., 2020; Jocher, 2020; Liu et al., 2018; Magazine, 2020; Redmon et al., 2018). بعد احتمالات کلاس را برای هر سلول شبکه پیش‌بینی می‌کند و در پایان ضریب برای هر کادر محصورکننده سلول‌ها طبق معادله ۱ محاسبه می‌شود.

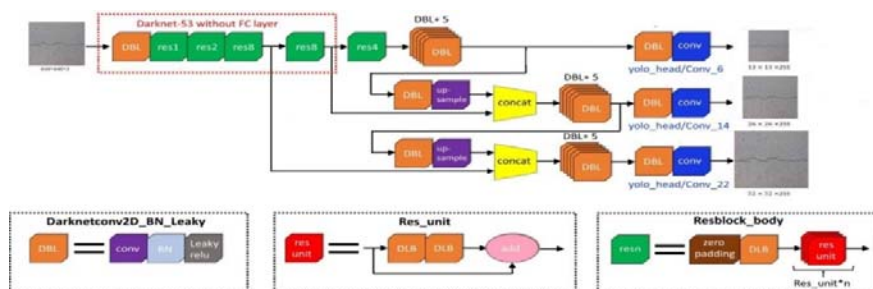
$$P(C_i/O) \times P(O) \times IOU_{pred}^{truth} = P(C_i) \times IOU_{pred}^{truth} \quad (1)$$

سپس YOLO، برای حذف کادرهای محصورکننده اضافی و تشخیص اینکه کدام کادر محصورکننده برای یک سلول شبکه بهینه‌تر است، از روش فرونشینی بیشینه استفاده کرده و به‌وسیله آن، IOU (اشتراک بر اجتماع) را محاسبه می‌کند که در شکل شماره ۲ مشاهده می‌کنید.

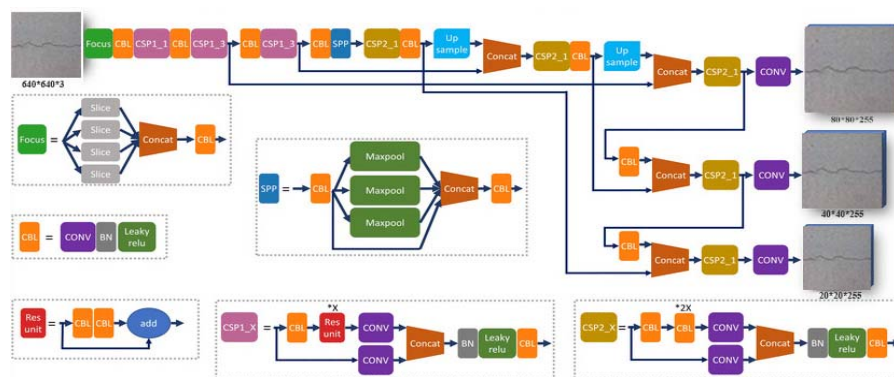


شکل ۲. فیلترکردن چندین تشخیص

(کادر پیش‌بینی شده به رنگ قرمز و جعبه حقیقت به رنگ آبی است)



شکل ۳. معماری مدل YOLOv3



شکل ۴. معماری مدل YOLOv5

ایجاد می‌کند (Magazine, 2020). این فرآیند را می‌توانید در

شکل ۴ مشاهده کنید.

خروجی مدل YOLOv5 برای هر شی و هدف شناسایی شده مطابق با توضیحات داده شده، شامل ابعاد کادر محصورکننده است (Thuan, 2021; Wu et al., 2021). با توجه به هدف این مطالعه که تشخیص خودکار ترک‌های روسازی است، پس از شناسایی هر ترک در تصاویر، ابعاد چارچوب محصورکننده آن‌ها نیز مشخص می‌شوند. براساس ابعاد مشخص شده برای هر ترک، می‌توان رویکرد تعمیر و نگهداری مناسب با آن را مشخص کرد. 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 نقطه‌نظرات متخصصان (جلسات تخصصی) در خصوص پارامترها و شاخص‌های پیشنهادی و تجربیات گذشته و همچنین مطالعات انجام‌شده مرتبط با موضوع (Desai, 2020; Hosseinzadeh et al., 2022; Hou, 2019)، الگوریتم درخت تصمیم‌گیری زیر (شکل ۵) بر اساس نوع و ابعاد ترک توسعه‌یافته و بر اساس آن رویکرد تعمیر و نگهداری به تفکیک هر قطعه تصویر اختصاص می‌یابد. اطلاعات ناهمواری و شیارشدگی سطح جاده که توسط اسکنر سطح جاده برداشت شده است، برای تصمیم‌گیری بهتر در درخت تصمیم‌گیری به‌عنوان مکمل نتایج پیش‌بینی شده استفاده می‌گردد.

۳-۲- الگوریتم YOLOv5

مؤسسه Ultralytics، مدل YOLOv5 را در سال ۲۰۲۰، به‌عنوان یک مدل جدید ارائه داد (Magazine, 2020; Thuan, 2021). این مدل از PyTorch استفاده کرده و CSPDarknet53 ستون فقرات و پشتیبان اصلی آن است. الگوریتم CSPDarknet53 یک شبکه عصبی کانولوشن که از DarkNet-53 استفاده می‌کند. این الگوریتم از یک استراتژی CSPNet بهره می‌گیرد تا نقشه ویژگی لایه پایه را به دو قسمت تقسیم کند و سپس آنها را از طریق یک سلسله مراتب مرحله‌ای ادغام کند. وظیفه این پشتیبان، تبدیل تغییر گرادیان به نگاشت ویژگی و جلوگیری از تکرار اطلاعات گرادیان در موارد وسیع و بزرگ است، که منجر به بهبود دقت، به حداقل رسیدن سرعت استنتاج و کاهش حجم مدل به واسطه کاهش یافتن تعداد پارامترها می‌شود. علاوه بر این، جریان اطلاعات را با استفاده از PANet (شبکه تجمیع مسیر) افزایش می‌دهد که مهمترین کارایی آن محسوب می‌شود. PANet از یک شبکه با ویژگی هرمی (FPN) که دارای تعداد زیادی لایه‌های پایین به بالا و بالا به پایین است، استفاده می‌کند. این امر، باعث تقویت و بهبود توزیع ویژگی سطح پایین می‌شود. PANet دقت محلی‌سازی شیء را با تقویت محلی‌سازی در سطوح پایین‌تر، بهبود می‌بخشد. علاوه بر این، راس YOLOv5 دقیقاً مشابه YOLOv3 است. یعنی سه خروجی مجزا از نگاشت‌های ویژگی ایجاد می‌کند تا بتواند پیش‌بینی چند مقیاسی انجام دهد. ابتدا، تصویر به CSPDarknet53 ارسال می‌شود، که در نتیجه آن، ویژگی‌ها استخراج می‌شوند و سپس، ویژگی به PANet ارسال می‌شوند تا ترکیب شوند. در آخر، لایه YOLO، نتایج را

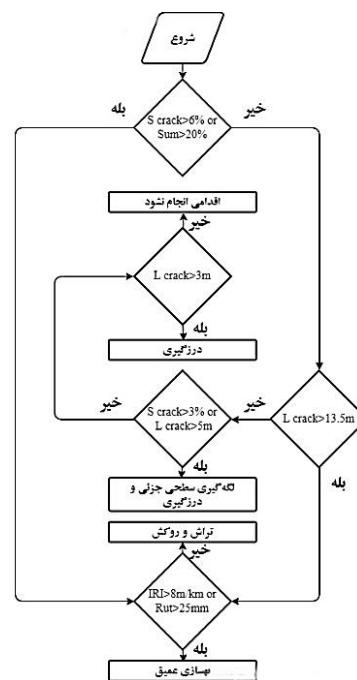
شکل و خرابی سطحی) به ندرت در آزادراهها و راههای شریانی دیده می‌شود و عمده خرابی این مسیرها انواع مختلف ترک‌خوردگی است. ترک‌خوردگی یکی از متداول‌ترین خرابی‌های روسازی بوده که حجم قابل‌توجهی از تلاش‌های محققان به‌منظور ایجاد سامانه‌های خودکار تشخیص خرابی را به خود معطوف کرده است (H. Li et al., 2021; Maeda et al., 2018; Shi et al., 2016). خرابی‌های شامل ترک‌خوردگی را می‌توان به دودسته ترک‌های خطی و ترک‌های سطحی یا الگودار تقسیم نمود.

از آنجایی‌که مدل استفاده شده یک مدل با نظارت است. لذا، 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 چهارچوب احاطه‌کننده ترک و مختصات مرکز این چهارچوب نسبت به ابعاد اصلی تصویر مشخص گردد (شکل ۶). سامانه‌های متعددی این می‌توانند در انجام این کار کمک کنند مانند roboflow، LabelImg، makesense و غیره که در این تحقیق از سامانه تحت وب makesense استفاده شده است. تمامی تصاویر برای دو گزینه ترک خطی و ترک سطحی، علامت‌گذاری شدند. در بین ۵۲۰ تصویر استفاده شده تعداد ۱۳۹۹ ترک شامل ۲۵۲ ترک سطحی و ۱۱۴۷ ترک خطی علامت‌گذاری و برچسب‌گذاری شدند. نمودار میله‌ای تعداد برچسب‌های مربوط به هر گزینه در شکل ۷ آمده است.



$$(x_{c,rel}, y_{c,rel}, w_{rel}, h_{rel}) = \left(\frac{x_{c,abs}}{w_{img}}, \frac{y_{c,abs}}{h_{img}}, \frac{w_{abs}}{w_{img}}, \frac{h_{abs}}{h_{img}} \right)$$

شکل ۶. الگوی برچسب‌گذاری YOLO



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

شکل ۵. درخت تصمیم‌گیری جهت تعیین رویکرد تعمیر و نگهداری

۴- نتایج تجربی و بحث و بررسی

۴-۱- مجموعه داده و معیارهای ارزیابی

تصاویر استفاده 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. اسکنر سطح جاده با سرعت ۸۰ کیلومتر بر ساعت در قطعات ده متری این تصاویر را با پسوند Jpg در قالب رنگی RGB ثبت کرده است. تصاویر دارای ابعاد ۹۹۴×۲۵۰۰ پیکسل هستند که در مقیاس واقعی ۱۰×۳ متر هستند. در مجموع تعداد ۵۲۰ تصویر حاوی خرابی جمع‌آوری شده 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 (Shi et al., 2016).

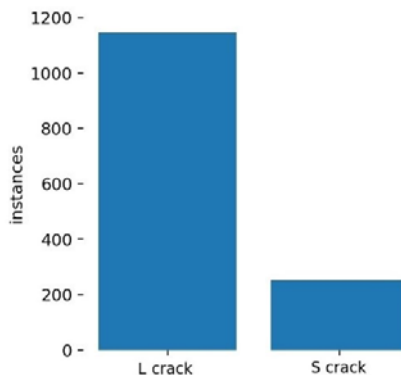
خرابی‌های رایج روسازی را می‌توان به دودسته خرابی‌های شامل ترک‌خوردگی و خرابی‌های غیر ترک‌خوردگی تقسیم نموده است. در شهر مشهد خرابی‌های غیر ترک‌خوردگی (تغییر

است؛ بنابراین AP بالاتر یعنی مدل یادگیری ماشین بهتر است. mAP میانگینی از مقادیر AP است (S. Li et al., 2021).

۴-۲- نتایج مدل سازی

یادگیری انتقالی به معنای استفاده از یک مدل از پیش آموزش دیده در یک کاربرد جدید است. این مبحث، امروزه در یادگیری عمیق بسیار مورد توجه است، زیرا امکان آموزش شبکه‌های عصبی عمیق را با داده‌های نسبتاً کمی فراهم می‌کند. همان‌طور که می‌دانیم، آموزش با داده کم بسیار ارزشمند است، زیرا در اکثر مسائل دنیای واقعی، داده‌های میلیونی و برجسب‌دار برای آموزش مدل‌های پیچیده یادگیری عمیق وجود ندارد (Gao et al., 2018; Gopalakrishnan et al., 2017; Weiss et al., 2016; K. Zhang et al., 2018). در این پژوهش از آموزش مجدد مدل‌های YOLOv3 و YOLOv5 از پیش تعلیم دیده شده با استفاده از مجموعه داده اشیا مشترک در زمینه (COCO) استفاده شده است. هر دو مدل در Colab با کارت گرافیک Tesla T4 آموزش و ارزیابی شدند. پنج نسخه از YOLOv5 شامل YOLOv5s, YOLOv5n, YOLOv5m, YOLOv5l و YOLOv5x 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 برخوردار است. چنانچه اکثر اشیا شناسایی شده دارای اندازه‌ای بزرگ باشند، شبکه به سرعت این اشیا را تشخیص خواهد داد. در صورت وجود تعداد زیادی ترک کوچک در کف خیابان، YOLOv5n قادر به تشخیص اجسام کوچک نخواهد بود (Hu et al., 2021; Jocher, 2020; Magazine, 2020).

برای آموزش مدل YOLOv3 و مدل‌های سری YOLOv5، نزول گرادینان تصادفی به عنوان بهینه‌ساز مرحله آموزش با تکانه ۰٫۹ استفاده شد. کاهش وزن، نرخ یادگیری و IOU به ترتیب روی ۰/۰۰۰۵، ۰/۰۰۱ و ۰/۵ ثابت شده است. سایز تصاویر آموزشی ۶۴۰×۶۴۰ پیکسل است. مجموعه‌های آموزشی و تأیید برای آموزش وارد شبکه شدند. پس از ۱۰۰ تکرار آموزش، منحنی‌های مقدار تابع زیان مجموعه‌های آموزشی و تأیید تعیین شد (شکل ۷). زیان میزان خطای شبکه را در هر مرحله نشان



شکل ۷. نمودار میله‌ای تعداد برجسب‌های مشخص شده بر روی تصاویر آموزش و آزمایش

برای ارزیابی عملکرد تشخیص شبکه YOLOv3 و YOLOv5، استفاده از معیارهای ارزیابی مناسب بسیار مهم است. معیارهای 'Recall'، 'precision'، 'F-score' و AP و meanAP به‌عنوان معیارهای ارزیابی مورد استفاده قرار گرفتند و به ترتیب به صورت زیر تعریف شدند (Bishop et al., 2006; Burkov, 2019; Kelleher et al., 2020)

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

$$AP_i = \int_0^1 P(R) dR \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

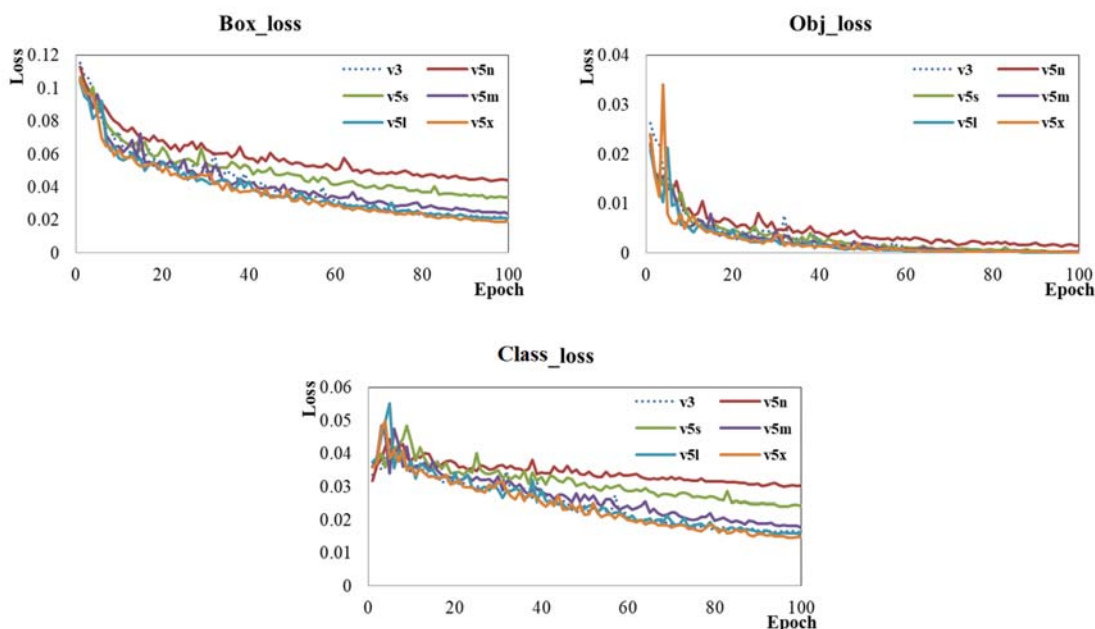
که در آن TP نشان‌دهنده تعداد نمونه‌های مثبتی است که به درستی شناسایی شده‌اند، FP نشان‌دهنده تعداد نمونه‌های منفی است که به اشتباه شناسایی شده‌اند و FN نشان‌دهنده تعداد نمونه‌های مثبتی است که شناسایی نشده‌اند. هم precision و هم recall در منحنی P-R میزان تشخیص نمونه‌های مثبت را در نظر می‌گیرند که خطای 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 نشان‌دهنده ناحیه زیر منحنی P-R

تأثیری در افزایش دقت آن‌ها ندارد. اما مدل‌های $v5s$ و $v5n$ در تکرار ۱۰۰ به بیشترین مقدار که می‌توانند برسند، رسیده‌اند. $v5x$ با مقدار ۰/۹۷۱، بیشترین مقدار Precision را به دست آورده است. برای معیار Recall نیز مدل‌های $v3$ ، $v5m$ ، $v5l$ و $v5x$ زودتر به مقدار ثابتی رسیده‌اند و نتیجه مطلوب‌تری را کسب کرده‌اند. مدل $v5x$ با ۰/۹۷۶۲ بیشترین امتیاز را کسب کرده است.

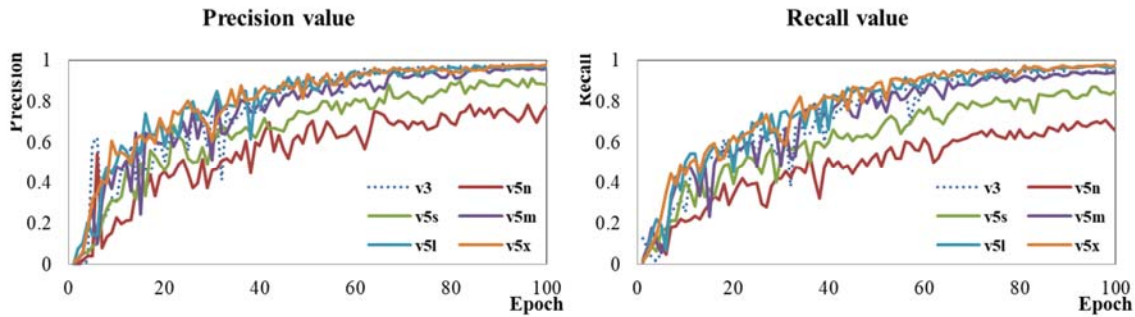
برای به‌دست‌آوردن مقدار mAP برای هر مدل، منحنی P-R ترسیم شد و سپس مساحت زیر هر نمودار به دست آمد. نمودار P-R برای هر مدل در شکل ۱۰ آمده است. همچنین طبق تعریف هرچه این نمودار به سمت راست و بالا متمایل باشد، مقدار mAP بالاتر در نتیجه مدل عملکرد بهتری داشته است. نتایج برای هر مدل در جدول ۲ ارائه شده است. باتوجه‌به جدول ۲، مشاهده می‌شود که مدل با بالاترین دقت تشخیص YOLOv5x است که mAP:0.5 به ۰/۹۸۷۴ می‌رسد. با این حال، دقت تشخیص بین چهار مدل $v5l$ ، $v5m$ ، $v5s$ و $v5x$ تفاوت زیادی ندارد و حداکثر اختلاف در ۰/۰۴ است. روند تغییرات mAP_0.5 در کل ۱۰۰ تکرار در شکل ۱۰ آورده شده است. باتوجه‌به نتایج ارائه شده، مدل $v5x$ دارای بیشترین دقت و مدل $v5n$ دارای کمترین میزان دقت است.

می‌دهد. obj-loss برای بررسی اطمینان از حضور شی در تصویر، box-loss برای تعیین خطای چهارچوب پیش‌بینی شده برای هر شی و cls-loss خطای دسته‌بندی شی است (Magazine, 2020). هرچه مقدار تابع ضرر کوچکتر باشد، چهارچوب پیش‌بینی دقیق‌تر و مدل دقت بالاتری دارد. همان‌طور که در شکل ۸ نشان داده شده است، مقدار تابع زیان در طول فرایند آموزش روند نزولی دارد. الگوریتم شیب تصادفی نزول شبکه را بهینه و وزن شبکه و سایر پارامترها به طور مداوم به‌روز می‌کند. تابع زیان تا مقدار تکرار ۱۰ با سرعت کاهش یافته و دقت مدل‌ها افزایش می‌یابد. از شکل ۷ می‌توان دریافت که در فرایند با تعداد تکرار مشابه، مدل با لایه‌های عمیق‌تر اثر آموزشی بهتر و هم‌گرایی سریع‌تری دارد. مدل $v5n$ در تکرار بیشتر خطای آن کم شده است در حالی که مدل $v5x$ در دوره کمتری به حداقل خطا رسیده است. مدل $v3$ نیز بهتر از مدل‌های $v5s$ و $v5n$ عمل کرده و خطای آن در دوره کمتری کمینه شده است.


به‌منظور بررسی عملکرد مدل‌ها از معیارهای ذکر شده در بخش ۴-۱ استفاده شده است. مقادیر Precision و Recall در شکل ۹ نشان داده شده است. شکل‌گیری این منحنی‌ها به این صورت است که بعد از آموزش در هر تکرار، مدل در همان مرحله بر روی تصاویر آزمایشی اعمال می‌شود و مقادیر شاخص‌های ارزیابی براساس ماتریس درهم‌ریختگی محاسبه می‌گردد که مقدار Precision برای مدل‌های $v3$ ، $v5m$ ، $v5l$ و $v5x$ در تکرار ۶۰ به حالت حدوداً ثابتی رسیده و افزایش تعداد تکرار



شکل ۸ روند مقادیر زیان برای مدل‌های $v3$ ، $v5n$ ، $v5s$ ، $v5m$ ، $v5l$ و $v5x$



شکل ۹. مقادیر Precision و Recall برای مدل‌های v3, v5n, v5s, v5m, v5l و v5x



شکل ۱۰. روند مقدار mAP برای مدل‌های v3, v5n, v5s, v5m, v5l و v5x

جدول ۲. مقایسه عملکرد مدل‌های v3, v5n, v5s, v5m, v5l و v5x

mAP:0.5	Precision	Recall	F1	مدل
۰/۷۷۴۴	۰/۷۸۳۸	۰/۷۰۲۱	۰/۷۴	YOLOv5n
۰/۹۲۸	۰/۹۰۵۶	۰/۸۷۰۹	۰/۸۹	YOLOv5s
۰/۹۷۵۴	۰/۹۵۹۵	۰/۹۳۶۶	۰/۹۵	YOLOv5m
۰/۹۸۴۲	۰/۹۶۹	۰/۹۶۸۸	۰/۹۷	YOLOv5l
۰/۹۸۷۴	۰/۹۷۱	۰/۹۷۶۲	۰/۹۷	YOLOv5x
۰/۹۶۹	۰/۹۷۹۹	۰/۹۴۹۸	۰/۹۶	YOLOv3

با بهینه‌کردن برجسب‌گذاری تصاویر می‌توان این خطا را بهبود بخشید. پس از ساخت مدل و ارزیابی آن‌ها با استفاده از داده‌های آزمایشی، مدل‌های ساخته شده جهت پیش‌بینی ترک‌های روسازی آسفالتی مسیر کندروی غرب به شرق بزرگراه کلانتری مشهد استفاده شد. با اعمال مدل‌های ساخته شده سری YOLOv5 بر روی تصاویر، ترک‌های مسیر شناسایی شدند. زمان تشخیص ترک‌ها برای پنج مدل ساخته شده از ۱۷/۴ میلی‌ثانیه برای v5n تا ۱۰۵/۶ میلی‌ثانیه برای v5x متغیر است (جدول ۳).

بر اساس ماتریس درهم‌ریختگی نهایی (شکل ۱۲)، مدل‌های سری YOLO استفاده‌شده در این تحقیق در تشخیص ترک‌های سطحی دقیق‌ترند زیرا ترک‌های سطحی دارای ساختار منظم‌اند ولی ترک‌های خطی دارای شکل ظاهری متفاوت و اعوجاج زیادی هستند؛ لذا برای افزایش دقت مدل‌ها می‌بایست تعداد بیشتری از این نوع ترک برای آموزش مدل‌ها استفاده کنیم. بعضی از مدل‌ها، بخشی از پس‌زمینه را به‌عنوان ترک‌های سطحی و خطی در نظر گرفته‌اند. از دلایل بروز چنین خطایی می‌تواند برجسب‌گذاری نشدن همه ترک‌ها در تصویر و یا خوب ترسیم نشدن کادر محصورکننده برای ترک‌ها باشد؛ لذا

v5s		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.87	0	0.13
	S Crack	0	0.98	0.02
	Background	0	0.13	0.87

v5n		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.7	0	0.3
	S Crack	0.01	0.85	0.13
	Background	0	0.13	0.87

v5l		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.97	0	0.03
	S Crack	0	1	0
	Background	0	0.08	0.92

v5m		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.96	0	0.04
	S Crack	0.01	0.97	0.02
	Background	0	0.09	0.91


v3		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.91	0	0.09
	S Crack	0	1	0
	Background	0	0.03	0.97

v5x		Predicted		
		L Crack	S Crack	Background
TRUE	L Crack	0.97	0	0.03
	S Crack	0	1	0
	Background	0	0.09	0.91


شکل ۱۲. ماتریس درهم‌ریختگی نهایی برای مدل‌های v3، v5n، v5s، v5m، v5l و v5x

جدول ۳. زمان پیش‌بینی برای مدل‌های v3، v5n، v5s، v5m، v5l و v5x

مدل	زمان پیش‌بینی (میلی ثانیه)
YOLOv5n	۱۷/۴
YOLOv5s	۲۳/۹
YOLOv3	۳۲/۳
YOLOv5m	۵۳/۷
YOLOv5l	۸۹/۷
YOLOv5x	۱۰۵/۶



شکل ۱۳. ترک‌های پیش‌بینی شده توسط مدل v5s بر روی یک تصویر



شکل ۱۴. هیستوگرام توزیع طول و سطح ترک‌های پیش‌بینی شده

۵- نتیجه‌گیری

ترک خوردگی‌ها از خرابی‌های اولیه سطوح آسفالت هستند که اگر به‌موقع رسیدگی نشوند تبدیل به خرابی‌های اساسی مانند چاله‌ها می‌گردند و هزینه‌های ترمیم و بازسازی را بسیار افزایش می‌دهند. طبقه‌بندی ترک‌ها به‌صورت بصری بسیار پرهزینه، وقت‌گیر، خطرناک و یک کار فشرده ذهنی است، به همین دلیل نتایج می‌تواند غیرقابل اعتماد و متفاوت باشد. از سوی دیگر سیستم‌های نظارت سریع و ارزیابی آسفالت مانند سامانه‌های اسکن لیزری برای تشکیل نگاشت سطح ترک و آشکارسازی آنها مناسب هستند اما نمی‌توانند ترک‌ها را به‌درستی طبقه‌بندی کنند و همچنین بسیار گران هستند. این پژوهش مفاهیم نظری الگوریتم‌های سری YOLO به‌ویژه نسخه سوم و پنجم آن و کاربرد آن در حوزه تشخیص خودکار ترک روسازی را مورد بحث قرار داد. با استفاده از الگوریتم YOLO یکی از پیشرفته‌ترین مدل‌های تشخیص اشیاء و انتقال این مدل به تشخیص ترک روسازی، نتایج نشان داد که دقت تشخیص مدل‌های سری YOLO نسخه سوم و پنجم به جز v5n، بالای ۹۰ درصد است و v5x با ۹۸/۷۴ درصد بیشترین دقت را به دست آورده است. به لحاظ زمانی، مدل v3 در ۳۲/۳ میلی‌ثانیه و مدل‌های v5s و v5n به ۱۷/۴ و ۲۳/۹ میلی‌ثانیه برای تشخیص نیاز دارند؛ بنابراین، اگر دقت مدل مدنظر باشد می‌توانیم از v5x استفاده کنیم. اگر لازم باشد هم نرخ و هم سرعت تشخیص را در نظر بگیریم، می‌توانیم مدل v5s را انتخاب کنیم. با توجه به خروجی‌های مدل YOLO که هم نوع

با مقایسه دقت و سرعت مدل YOLOv3 و مدل‌های سری YOLOv5، v5s با توجه به دقت قابل قبول و سرعت تشخیص بالا می‌تواند نیازهای مهندسی ما را برآورده کند؛ لذا نتایج این مدل به‌عنوان اطلاعات ورودی جهت تصمیم‌گیری برای اقدامات مورد نیاز تعمیر و نگهداری انتخاب شدند. یکی از پیش‌بینی‌های انجام شده توسط مدل v5s در شکل ۱۳ نشان داده شده است. براساس نتایج پیش‌بینی شده، از مجموع ۲۲۵ تصویر، ۱۸۱ تصویر حاوی خرابی و ۴۴ تصویر بدون خرابی تشخیص داده شد. در کل تصاویر حاوی خرابی، ۳۶۳ ترک خطی با حداقل و حداکثر طول ۰/۲ متر و ۹/۸ متر و ۱۶۱ ترک سطحی با حداقل و حداکثر درصد خرابی ۰/۴ درصد و ۶۲/۸ درصد شناسایی شد. در شکل ۱۴ 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 ذکر شده در بخش بر روی ترک‌های پیش‌بینی شده برای هر قطعه تصویر ده متری، اقدام لازم جهت تعمیر و نگهداری تعیین شد که نتایج در جدول ۴ نشان داده شده است. با توجه به نتایج به‌دست آمده می‌توان دریافت تمامی مدل‌های استفاده شده در این پژوهش به جز v5n عملکرد قابل قبولی را در تشخیص خودکار ترک روسازی با توجه به سرعت و دقت داشته‌اند. به‌منظور تعیین ابعاد خرابی‌های شامل طول و سطح ترک‌ها می‌بایست در آموزش مدل و برچسب‌گذاری ترک‌ها دقت بیشتری شود چون به دلیل وجود ترک‌های خطی با اعوجاج زیاد، اگر در هر تغییر مسیر ترک خطی، تشخیصی صورت نگیرد طول پیش‌بینی بسیار کمتر از طول واقعی ترک خواهد بود لذا تصمیم‌گیری براساس آن با خطای زیادی همراه خواهد بود. 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 استفاده شده، حداکثر ۳ درصد خطا وجود دارد که این خطای محاسباتی در تصمیم‌گیری برای پیش‌بینی اقدام مورد نیاز تأثیرگذار نیست.

جدول ۴. رویکردهای پیش‌بینی شده

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

مختلف آسیب‌دیدگی روسازی آسفالتی ارزیابی شود. پارامترهای اساسی یادگیری نظیر تعداد نرخ یادگیری، تعداد تکرار و غیره در اغلب مطالعات به‌صورت تجربی و با سعی و خطا تعیین می‌شوند و این نیاز احساس می‌شود که تحقیقاتی باهدف بهینه‌سازی این پارامترها صورت گیرد. اگرچه YOLO در کاهش میزان محاسبات در مقایسه با یک مدل بدون چارچوب بهینه‌سازی زیادی انجام داده است، اما هنوز به منابع محاسباتی زیادی در فرایند آموزش نیاز دارد. مقایسه عملکرد YOLO با سایر مدل‌های بدون چارچوب می‌تواند موضوع مناسبی برای مطالعات آینده باشد.

۶- پی‌نوشت‌ها

1- You Only Look Once

ترک را مشخص می‌کنند هم موقعیت و هم ابعاد را، می‌توان به‌منظور مدیریت روسازی و تعیین رویکرد تعمیر و نگهداری آینده استفاده کرد. ما در این پژوهش با استفاده از نتایج مدل v5s با توجه به دقت و سرعت مطلوب و درخت تصمیم‌گیری پیشنهادی توانستیم به نتایج رضایت‌بخشی برسیم. با توجه به انجام پژوهش حاضر، ضرورت انجام پژوهش‌های بیشتر احساس می‌شود. بر همین اساس چند پیشنهاد ارائه می‌گردد. -به‌منظور افزایش دقت و تعمیم‌پذیری مدل‌ها، از تعداد تصاویر بیشتر با پیچیدگی بیشتر پس‌زمینه، نورپردازی‌های متفاوت و شرایط مختلف برای آموزش مدل‌ها استفاده شود. -برای افزایش سرعت پیش‌بینی می‌توان از سامانه‌های با حافظه GPU بالاتر استفاده کرد به‌طوری‌که بتوان از طریق تصویربرداری، ترک‌ها را به‌طور برخط پیش‌بینی کرد. -این تحقیق فقط بر روی تشخیص انواع مختلف ترک متمرکز شد. پیشنهاد می‌شود مدل‌های YOLO برای تشخیص انواع

۷- مراجع

-Gopalakrishnan, K., Khaitan, S. K., Choudhary, A., & Agrawal, A. (2017). Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection. *Construction and building materials*, 157, 322-330.
-Hoang, N.-D., & Nguyen, Q.-L. (2019). A novel method for asphalt pavement crack classification based on image processing and machine learning. *Engineering with Computers*, 35(2), 487-498.
-Hosseinzadeh, H., Ghiami Bajgirani, A., & Delavarian, M. (2022). Detection and classification of asphalt pavement cracks using YOLOv5. *Journal of Modeling in Engineering*.
-Hou, Y. (2019). *Pixel-level Pavement Crack Detection Using Deep Convolutional Neural Network with Residual Blocks* University of Missouri-Columbia].
-Hsieh, Y.-A., & Tsai, Y. J. (2020). Machine learning for crack detection: Review and model performance comparison. *Journal of Computing in Civil Engineering*, 34(5), 04020038.
-Hu, G. X., Hu, B. L., Yang, Z., Huang, L., & Li, P. (2021). Pavement Crack Detection Method Based on Deep Learning Models. *Wireless Communications and Mobile Computing*, 2021.
-Ian, G., Yoshua, B., & Aaron, C. (2016). *Deep Learning (Adaptive Computation and Machine Learning Series)*. In: The MIT Press Cambridge, MA, USA.
-Jocher, G. (2020). Retrieved 21 April from <https://github.com/ultralytics/yolov5>.
-Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. MIT PRESS.

-Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4). Springer.
-Bochkovskiy, A., Wang, C.-Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
-Buduma, N., Buduma, N., & Papa, J. (2022). *Fundamentals of deep learning*. O'Reilly Media, Inc.
-Burkov, A. (2019). *The hundred-page machine learning book*, Vol. 1. Andriy Burkov Quebec City, QC, Canada.
-Chen, F.-C., & Jahanshahi, M. R. (2017). NB-CNN: Deep learning-based crack detection using convolutional neural network and Naïve Bayes data fusion. *IEEE Transactions on Industrial Electronics*, 65(5), 4392-4400.
-Cord, A., & Chambon, S. (2012). Automatic road defect detection by textural pattern recognition based on AdaBoost. *Computer-Aided Civil and Infrastructure Engineering*, 27(4), 244-259.
-Desai, A. A. (2020). Asphalt pavement crack detection and classification using deep Convolutional Neural Networks Georgia Institute of Technology].
-Fei, Y., Wang, K. C., Zhang, A., Chen, C., Li, J. Q., Liu, Y., Yang, G., & Li, B. (2019). Pixel-level cracking detection on 3D asphalt pavement images through deep-learning-based CrackNet-V. *IEEE Transactions on Intelligent Transportation Systems*, 21(1), 273-284.
-Gao, Y., & Mosalam, K. M. (2018). Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering*, 33(9), 748-768.
-Girshick, R. (2015). Fast r-cnn. *Proceedings of the IEEE international conference on computer vision*,

- Research Board, National Research Council, Washington, DC, 57-65.
- Shahin, M. Y. (1994). Pavement management for airports, roads, and parking lots.
- Shi, Y., Cui, L., Qi, Z., Meng, F., & Chen, Z. (2016). Automatic road crack detection using random structured forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(12), 3434-3445.
- Soviany, P., & Ionescu, R. T. (2018). Optimizing the trade-off between single-stage and two-stage deep object detectors using image difficulty prediction. *2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*.
- Thuan, D. (2021). Evolution of yolo algorithm and yolov5: the state-of-the-art object detection algorithm.
- Wang, X., & Hu, Z. (2017). Grid-based pavement crack analysis using deep learning. *2017 4th international conference on transportation information and safety (ICTIS)*.
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big data*, 3(1), 1-40.
- Wu, W., Liu, H., Li, L., Long, Y., Wang, X., Wang, Z., Li, J., & Chang, Y. (2021). Application of local fully Convolutional Neural Network combined with YOLO v5 algorithm in small target detection of remote sensing image. *PloS one*, 16(10), e0259283.
- Yang, C., Chen, J., Li, Z., & Huang, Y. (2021). Structural crack detection and recognition based on deep learning. *Applied sciences*, 11(6), 2868.
- Zhang, A., Wang, K. C., Fei, Y., Liu, Y., Tao, S., Chen, C., Li, J. Q., & Li, B. (2018). Deep learning-based fully automated pavement crack detection on 3D asphalt surfaces with an improved CrackNet. *Journal of Computing in Civil Engineering*, 32(5), 04018041.
- Zhang, A., Wang, K. C., Li, B., Yang, E., Dai, X., Peng, Y., Fei, Y., Liu, Y., Li, J. Q., & Chen, C. (2017). Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep learning network. *Computer-Aided Civil and Infrastructure Engineering*, 32(10), 805-819.
- Zhang, K., Cheng, H., & Zhang, B. (2018). Unified approach to pavement crack and sealed crack detection using preclassification based on transfer learning. *Journal of Computing in Civil Engineering*, 32(2), 04018001.
- Zhang, L., Yang, F., Zhang, Y. D., & Zhu, Y. J. (2016). Road crack detection using deep convolutional neural network. *2016 IEEE international conference on image processing (ICIP)*.
- Zou, Q., Zhang, Z., Li, Q., Qi, X., Wang, Q., & Wang, S. (2018). Deepcrack: Learning hierarchical convolutional features for crack detection. *IEEE Transactions on Image Processing*, 28(3), 1498-1512.
- Kim, B., & Cho, S. (2018). Automated vision-based detection of cracks on concrete surfaces using a deep learning technique. *Sensors*, 18(10), 3452.
- Li, H., Zong, J., Nie, J., Wu, Z., & Han, H. (2021). Pavement crack detection algorithm based on densely connected and deeply supervised network. *IEEE Access*, 9, 11835-11842.
- Li, Q., Zou, Q., Zhang, D., & Mao, Q. (2011). FoSA: F* seed-growing approach for crack-line detection from pavement images. *Image and Vision Computing*, 29(12), 861-872.
- Li, S., Gu, X., Xu, X., Xu, D., Zhang, T., Liu, Z., & Dong, Q. (2021). Detection of concealed cracks from ground penetrating radar images based on deep learning algorithm. *Construction and Building Materials*, 273, 121949.
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Liu, B., Zhao, W., & Sun, Q. (2017). Study of object detection based on Faster R-CNN. 2017 Chinese Automation Congress (CAC),
- Liu, C., Tao, Y., Liang, J., Li, K., & Chen, Y. (2018). Object detection based on YOLO network. *2018 IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC)*.
- Liu, F., Xu, G., Yang, Y., Niu, X., & Pan, Y. (2008). Novel approach to pavement cracking automatic detection based on segment extending. *2008 International Symposium on Knowledge Acquisition and Modeling*.
- Maeda, H., Sekimoto, Y., Seto, T., Kashiya, T., & Omata, H. (2018). Road damage detection using deep neural networks with images captured through a smartphone. *arXiv preprint arXiv:1801.09454*.
- Magazine, A. I. (2020). *Guide to Yolov5 for Real-Time-Object Detection*. Retrieved 10 February from <https://analyticsindiamag.com/yolov5>.
- Mandal, V., Uong, L., & Adu-Gyamfi, Y. (2018). Automated road crack detection using deep convolutional neural networks. *2018 IEEE International Conference on Big Data (Big Data)*.
- Nguyen, H.-N., Kam, T.-Y., & Cheng, P.-Y. (2014). An automatic approach for accurate edge detection of concrete crack utilizing 2D geometric features of crack. *Journal of Signal Processing Systems*, 77(3), 221-240.
- Nie, M., & Wang, C. (2019). Pavement Crack Detection based on yolo v3. *2019 2nd International Conference on Safety Produce Informatization (IICSPI)*.
- Pauly, L., Hogg, D., Fuentes, R., & Peel, H. (2017). Deeper networks for pavement crack detection. *Proceedings of the 34th ISARC*.
- Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Rosa, P. (2012). Automatic pavement crack detection and classification system. *Transportation*

Automatic Classification and Quantification of Asphalt Pavement Cracks Using Deep Learning-based Object Detection Algorithms

*Hassan Hosseinzadeh, M.Sc., Grad., Department of Civil Engineering,
Technical and Engineering Faculty, Eqbal Lahori Institute of Higher Education, Mashhad, Iran.*

*Ali Ghiami Bajgirani, Assistant Professor, Department of Civil Engineering,
Technical and Engineering Faculty, Eqbal Lahori Institute of Higher Education, Mashhad, Iran.*

*Mohadesseh Delavarian, Assistant Professor, Department of Computer Engineering,
Technical and Engineering Faculty, Eqbal Lahori Institute of Higher Education, Mashhad, Iran.*

E-mail: hosseinzadeh.hassan@eqbal.ac.ir

Received: January 2025- Accepted: April 2025

ABSTRACT

Pavement crack detection is an important method in road maintenance and traffic safety. Traditionally, road condition assessment was done by field inspection, which is time-consuming and costly, and the results are dependent on the evaluator's opinion, it should be replaced by automated methods to reduce both workload and thus maintenance costs. This paper examines the performance of YOLOv3 and YOLOv5 algorithms for automatic crack detection. These models are able to determine the type, position and geometric characteristics of the crack accurately and at a high speed compared to other methods. For the purpose of modeling, the images taken from Mashhad surface roads have been used. These images were labeled for linear and surface crack options. Then, models were created using the v3 model and five v5 series algorithms and transfer learning and were evaluated in terms of accuracy and prediction speed. The accuracy of the models is between 77 and 98% and the prediction speed of the models is between 17.4 and 105 milliseconds, which indicates the optimal performance of the models. Finally, v5s model was used as the final model for predicting cracks in one of Mashhad roads due to its acceptable accuracy (92.8) and high prediction speed (23.9 milliseconds) compared to other models. Then, based on the outputs of the model, the maintenance approach was presented.

Keywords: Pavement Management, Automatic Crack Detection, Deep Learning, YOLOv3, YOLOv5