

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری

### عمیق

فاطمه خزاعی، کارشناس ارشد، گروه مهندسی کنترل، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران  
محمدرضا محمدی (مسئول مکاتبات)، استادیار، گروه هوش مصنوعی، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران، تهران،

ایران

**E-mail: mrmohammadi@iust.ac.ir**

حسین بلندی، استاد، گروه مهندسی کنترل، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

پذیرش: ۱۴۰۳/۱۱/۰۸

دریافت: ۱۴۰۳/۰۷/۰۸

### چکیده

در این مطالعه، روشی برای تشخیص مانع در راه آهن ارائه شده است. این فرایند به سه مرحله تفکیک پذیر است: در مرحله اول، تمامی اشیاء موجود در تصویر توسط شبکه YOLO شناسایی می شوند. در مرحله دوم، نیاز است که تمامی ریل های موجود در تصویر شناسایی شوند، به همین منظور، شبکه UNet روی مجموعه داده Railsem19 آموزش داده شده است. در ادامه این مرحله، بایستی مسیر حرکت قطار از میان ریل های شناسایی شده جدا شود؛ بنابراین، به طراحی و شبیه سازی نوعی الگوریتم شناسایی مسیر حرکت قطار پرداخته شده که علاوه بر توانایی شناسایی مسیر حرکت قطار در شرایطی که ریل ها کاملاً از هم مجزا هستند، در بعضی از شرایط خاص مانند نواحی جلوی سوزن که ریل به دو شاخه تقسیم می شود، نیز توانایی تشخیص مسیر حرکت قطار را دارد. در مرحله سوم، اشتراک بین مسیر حرکت قطار و مکان اشیاء به دست آمده توسط YOLO بررسی می شود. در صورت اشتراک، مانع در مسیر حرکت قطار بوده و در غیر این صورت، مسیر ایمن در نظر گرفته می شود. الگوریتم پیشنهادی تشخیص مانع، پس از شبیه سازی، روی مجموعه داده شامل ۱۶۶۴ تصویر مورد ارزیابی قرار گرفت و با دقت (Accuracy) حدود ۸۷ درصد، قادر بود موانع را تشخیص دهد. سپس، به بررسی نتایج الگوریتم تشخیص سوزن پیشنهادی پرداخته شده و مشاهده شد که این الگوریتم نیز توانایی شناسایی مسیر حرکت قطار با دقت بالا (Accuracy نزدیک به ۹۹ درصد) را دارد.

واژه های کلیدی: یادگیری عمیق، راه آهن، تشخیص اشیاء، سوزن ریل، مسیر حرکت قطار

## ۱. مقدمه

مانع در راه آهن پیشنهادی در این مطالعه، با توانایی شناسایی ۸۰ کلاس، می تواند در این زمینه بسیار مفید باشد.

برای بیان اهمیت موضوع تشخیص مانع، به بررسی تعدادی از حوادث راه آهن که به دلیل وجود موانع در تقاطع ها و مسیرهای دیگر راه آهن رخ داده اند، می پردازیم: برای مثال، حادثه ریلی که در تاریخ ۱۸ خرداد ۱۴۰۱ رخ داد، به دلیل وجود بیل مکانیکی در مسیر قطار بود. این گونه حوادث که هر ساله اتفاق می افتند، موجب خروج قطار از ریل می شوند. همچنین، هر سال به طور میانگین ۵۰ نفر در بریتانیا در اثر تصادف در راه آهن جان خود را از دست می دهند (Marinov, & Dent, ۲۰۱۹). وزارت حمل و نقل و گردشگری ژاپن نیز گزارش هایی را در مورد سوانح و حوادث بزرگ راه آهن منتشر می کند که دسترسی به آنها برای عموم آزاد است. با بررسی این گزارش ها، مشخص می شود که در چند سال اخیر، بیش از ده حادثه تنها به خاطر برخورد با سنگ ها و درختان رخ داده که منجر به خروج قطار از ریل شده است (Lin, & Hsieh, Hsu, Ke, Liu, ۲۰۱۵). حمل و نقل ریلی بدون شک یکی از ایمن ترین روش های جابه جایی است؛ با این حال، رابط بین جاده و راه آهن که گذرگاه های همسطح نامیده می شود، پتانسیل بالایی برای تصادفات راه آهن دارد. عملیات راه آهن از دیرباز به عنوان یک روش حمل و نقل راحت و مؤثر در تایوان شناخته شده است، به ویژه با تلاش برای گسترش شبکه و افزایش سرعت قطار. با این وجود، افزایش اخیر در تعداد سوانح ریلی نگرانی های جدی را در مورد ایمنی آن برانگیخته است. در سال های ۲۰۱۰ تا ۲۰۱۳، تعداد ۲۳۹۶ تصادف در راه آهن تایوان به وقوع پیوسته که از این تعداد، ۱۰۴ مورد مربوط به تقاطع های همسطح بوده است (Nakason, Nagamine, Ukai, & Mukojima, 2017).

در این مقاله به معرفی یک الگوریتم تشخیص مانع در راه آهن پرداخته شده است. الگوریتم پیشنهادی توانایی تشخیص موانع به صورت On-Board را دارد و فرض می شود که یک دوربین با وضوح بالا و با قابلیت تشخیص تا فاصله ۵۰۰ متری روی بدنه

یکی از مهم ترین بخش هایی که باعث توسعه کشور می شود، بخش حمل و نقل است. قطار یکی از مهم ترین و سریع ترین راه های حمل و نقل است که امکان جابه جایی افراد و کالاها را بین نقاط دور دست فراهم می کند. در حال حاضر، تصادفات زیادی در حمل و نقل ریلی رخ می دهد که منجر به تلفات جان صدها نفر می شود. مشاهده می شود که بیشتر تصادفات در مسیر راه آهن به دلیل وجود موانع موجود در مسیر حرکت قطار است که منجر به خروج قطار از ریل می شود (S, 2019). از مهم ترین مزایای شبکه های حمل و نقل ریلی نسبت به جاده، می توان به ایمنی راه آهن و پایین بودن آمار سوانح آن اشاره کرد. اما به دلیل ماهیت راه آهن، سوانح محدود آن بازتاب وسیع و هزینه های گزافی را در پی خواهد داشت که از نظر اقتصادی خسارات سنگینی را بر مجموعه حمل و نقل ریلی وارد کرده و از نظر اجتماعی سبب کاهش سهم بازار جهانی آن خواهد شد. با توسعه سریع اقتصاد و علم در سراسر جهان، حمل و نقل ریلی به طور قابل توجهی از نظر فناوری توسعه یافته و به یکی از محبوب ترین روش های حمل و نقل مدرن تبدیل شده است (Yao, et al., 2020). اتحادیه بین المللی راه آهن گزارش ایمنی تصادف بیش از ۳۰ شرکت راه آهن در اوراسیا و خاورمیانه را در سال ۲۰۲۰ منتشر کرده است. این گزارش اشاره می کند که ۹۰ درصد حوادث ریلی ناشی از تجاوز شخص ثالث به خطوط ریلی است (Qi & Yu, ۲۰۲۱). خطوط راه آهن شهری برای حرکت ایمن و سرویس بهینه، به سیستم های کنترل و علائم پیشرفته نظیر اینترلاکینگ، حفاظت اتوماتیک، مدارهای راه، ماشین سوزن و... مجهز می شوند. در نتیجه از بروز تصادف و سرعت غیرمجاز جلوگیری می گردد. اما این سیستم ها فقط توانایی شناسایی اشیاء محدودی مانند اشیاء فلزی را دارند. از این رو با توجه به شدت حوادث ریلی و آمار تلفات بالای آنها که هر ساله اتفاق می افتد، نیازمند سیستم تشخیص مانع مناسب با توانایی شناسایی کلاس های متنوعی از موانع هستیم. از این رو الگوریتم تشخیص


## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه‌آهن با استفاده از یادگیری عمیق

قسمت تقسیم می‌شود و هریک از قسمت‌ها و تصویر اصلی به صورت مجزا به عنوان ورودی به شبکه SSD داده می‌شوند و در نهایت ناحیه‌ها ادغام می‌شوند. هر چه تعداد ناحیه‌های تقسیم شده بیش‌تر باشد، دقت افزایش و سرعت کاهش می‌یابد. که در این مقاله نتیجه‌گیری شده است که با تقسیم تصویر به چهار قسمت، مصالحه مناسبی بین دقت و سرعت انجام می‌شود. الگوریتم پیشنهادی در این مقاله توانایی تشخیص سه کلاس از موانع شامل انسان، سنگ و قطار را دارد.

در (Xu, et al., 2019) روش تشخیص موانع چند مرحله‌ای پیشنهاد شده است. که این روش دارای دو مرحله ایجاد نقشه ویژگی<sup>۱</sup> و ترکیب ویژگی<sup>۲</sup> است. در مرحله اول، تصویر ورودی با استفاده از یک شبکه عصبی باقیمانده (RNN) به نقشه‌های ویژگی چند مقیاسی تبدیل می‌شود. نقشه‌های ویژگی چند مقیاسی، شناسایی اشیاء با اندازه‌های مختلف در فواصل مختلف را بهبود می‌بخشد. به طور خاص، ویژگی‌های سطح پایین فاقد اطلاعات معنایی هستند، اما اطلاعات دقیق مکان شیء را ارائه می‌دهند، درحالی‌که ویژگی‌های سطح بالا غنی از اطلاعات معنایی هستند؛ اما فقط اطلاعات مکان تقریبی را ارائه می‌کنند. هنگامی که نقشه‌های ویژگی چند مقیاسی ایجاد می‌شوند، یک سری لایه‌های پیچشی برای استخراج ویژگی‌ها اضافه می‌شوند و شبکه، کادر محصورکننده<sup>۳</sup> و درجه اطمینان<sup>۴</sup> را برای موانع احتمالی محاسبه می‌کند. الگوریتم پیشنهادی در این مقاله توانایی شناسایی سه کلاس قطار، چمدان و انسان را دارد.

در (Drizi & Boukadoum, 2024) از یادگیری انتقالی Inception - ResNet - v2 برای تنظیم دقیق وزن‌های شبکه استفاده شده است. که تنظیم دقیق وزن‌ها روی مجموعه داده Railsem19 انجام شده است. با توجه به اندازه کوچک مجموعه داده و عدم تعادل داده‌های آن، تکنیک‌های مختلف افزایش داده‌ها برای بهبود دقت تشخیص مدل، مورد بررسی قرار گرفتند. نتایج به دست آمده نشان می‌دهد که میانگین دقت تشخیص روی مجموعه آموزشی RailSem19 اصلی، ۷۸

خودروی موتور مطابق با شکل ۱ نصب می‌شود تا اشیاء دنیای واقعی و موانع محیط شناسایی شوند.



شکل ۱. نحوه نصب دوربین روی قطار (Karakose, Akm, & Tastimur, 2013)

در ادامه، بخش دوم مقاله، به مرور پیشینه تحقیق پرداخته می‌شود. در بخش سوم، الگوریتم پیشنهادی تشخیص مانع در راه‌آهن و همچنین الگوریتم پیشنهادی شناسایی مسیر حرکت قطار مورد بررسی قرار می‌گیرد. در بخش چهارم به تحلیل نتایج الگوریتم پیشنهادی پرداخته می‌شود. بخش پنجم به جمع بندی اختصاص دارد و در نهایت در بخش ششم پیشنهادات آینده ارائه خواهد شد.

## ۲. ادبیات پژوهش

### ۱-۲ مروری بر روش‌های تشخیص اشیاء

در (صنیدزاده & کولانیان, ۱۴۰۲) عملکرد نسخه‌های پنجم و هفتم الگوریتم YOLO در تشخیص اشیاء با در نظر گرفتن پیچیدگی‌های محیط ریلی مورد بررسی قرار گرفته است و بعد از مصالحه دقت و سرعت، نسخه هفتم الگوریتم YOLO (Wang, Bochkovskiy, & Liao, 2022) به عنوان شبکه برتر در این مرحله انتخاب شده است. الگوریتم پیشنهادی در این پژوهش توانایی شناسایی پنج کلاس از موانع شامل وسیله نقلیه، عابر پیاده، دوچرخه، اتوبوس و ساخت و ساز را دارد.

در (LI, et al., 2020) با توجه به ضعف الگوریتم‌های یادگیری عمیق در تشخیص اشیاء کوچک، الگوریتم مبتنی بر SSD برای بهبود دقت این شبکه در تشخیص موانع کوچک پیشنهاد شده است. در این روش، ابتدا تصویر ورودی به چند

YOLOV8m به مقدار دقت ۸۸/۸ درصد با معیار MAP50 دست یافت.

در (Meng, et al., 2023) یک روش کارآمد تشخیص مانع در راه آهن با نام SDRC-YOLO به منظور مقابله با مشکلاتی مانند تشخیص کاذب بالا و تشخیص اشتباه، پیشنهاد شده است. در روش پیشنهادی، در ابتدا یک مکانیزم توجه ترکیبی که توانایی بازنمایی محلی را ترکیب می‌کند، به منظور بهبود دقت شناسایی اشیاء کوچک، پیشنهاد شده است، سپس DW-Decoupled Head به منظور ایجاد یک کانال ویژگی ترکیبی و با هدف بهبود توانایی کلاسه‌بندی و محلی‌سازی، پیشنهاد شده است. و در مرحله سوم یک کرنل کانولوشنی بزرگ، برای ایجاد میدان تأثیر بزرگ‌تر و بهبود قابلیت استخراج ویژگی شبکه، بکار گرفته شده است. علاوه بر این عملگر سبک‌وزن نمونه‌برداری کاهش یافته CARAFE نیز به منظور افزایش سرعت همگرایی شبکه استفاده شده است. نتایج تجربی نشان می‌دهد که روش پیشنهادی در مقایسه با شبکه پایه YOLOv5s، بهبود دقت (MAP) حدود ۲/۸ درصد روی مجموعه داده Rs و بهبود دقت ۱/۸ درصدی روی مجموعه داده Pascal VOC 2012 داشته است.

در (Rahman, Ahmed, Hasan, & Jahan, 2022) یک مدل یادگیری انتقالی مبتنی بر شبکه عصبی کانولوشن بر روی یک مجموعه داده سفارشی پیاده‌سازی شده است. مدل پیشنهادی در این تحقیق MobileNetV2 است که توانسته است، مانع را با دقت ۹۷ درصد تشخیص دهد. همچنین در این تحقیق مدل‌های YOLOV5, Resnet50, VGG19, VGG16 نیز روی مجموعه داده‌های جمع‌آوری شده، مورد آزمایش قرار گرفته‌اند و در نهایت شبکه MobileNetV2 به‌عنوان شبکه برتر معرفی شده است.

در (He, Zou, Chen, Liu, & Miao, 2021) یک آشکارساز شیء یک مرحله‌ای انعطاف‌پذیر و کارآمد با نام FE-YOLO برای تشخیص مانع پیشنهاد شده است. شبکه استخراج ویژگی از ماژول توجه، ماژول نمونه‌برداری پایین،

درصد بود که با متعادل‌سازی اندازه کلاس و افزایش مصنوعی داده‌های آموزشی، دقت به ۹۴ درصد رسید.

در (Qi, Ma, Xu, Xiang, & Qu, 2024) یک معماری بهبودیافته YOLOV5 به منظور شناسایی مانع در راه آهن و باندهای فرودگاه پیشنهاد شده است. در روش پیشنهادی معماری Fastnet و مکانیزم توجه<sup>۵</sup>، به منظور بهبود قابلیت‌های تشخیص مانع، ترکیب شده است. در این مطالعه، یک مجموعه داده جدید به نام AARFOD معرفی شده است که هدف این مجموعه داده بهبود قابلیت‌های تشخیص مانع است. مدل بهبودیافته YOLO، بهبود قابل توجهی را در دقت نشان داده است. (۱/۲ درصد در precision و ۱ درصد در recall). همچنین پارامترهای مدل تقریباً ۲۵/۱۲ درصد و GFLOPs حدود ۱۰/۶۳ درصد کاهش یافت.

در (Zhao, Kang, Sun, Ye, & Wu, 2024) از یک مدل تشخیص اشیاء بلادرنگ<sup>۶</sup> و با دقت بالا با نام RH\_Net برای حل چالش‌هایی مانند تشخیص اشیاء کوچک با دقت بالا و مصالحه دقت و سرعت، در موضوع تشخیص مانع در راه آهن پیشنهاد شده است. که در مدل پیشنهادی از یک شبکه عصبی کانولوشنال<sup>۷</sup> سبک وزن و یک ترنسفورمر بهبودیافته استفاده شده است.

در (Sevi & Aydın, 2023) یک روش مبتنی بر یادگیری عمیق برای تشخیص اجسام خارجی در اطراف خط راه آهن پیشنهاد شده است. در روش پیشنهادی از مجموعه داده RailSem19 استفاده شده است و یک مدل مبتنی بر YOLOV8 طراحی شده است. در این مطالعه، مجموعه داده متنوعی با استفاده از تکنیک‌های بهبود تصویر تولید شد و زیر معماری‌های YOLOV8 مورد ارزیابی قرار گرفت. نتایج نشان داد که زیر معماری YOLOV8m دارای مقادیر MAP50 بالاتری نسبت به سایر زیرمعماری‌ها بوده و عملکرد موفقی را در مرحله اعتبارسنجی نشان می‌دهد. معماری فرعی

## ۲-۲ مروری بر روش‌های شناسایی ریل

در (صنیدزاده & کولائیان, ۱۴۰۲) عملکرد شبکه‌های SE-Net, ResNet, Efficient-Net, NF-Net، در استخراج ویژگی‌های تصویر با هدف دستیابی به توازن میان دقت و حجم محاسبات مورد بررسی قرار گرفته است و در نهایت شبکه Efficient-Net به‌عنوان شبکه برتر معرفی شده است. در این پژوهش، از شبکه‌ای که ناحیه‌بندی انجام می‌دهد، بصورت همزمان خواسته شده است که علاوه بر شناسایی همه ریل‌های موجود در تصویر، ریل‌ها را به دو کلاس ریل اصلی و فرعی تقسیم کند. همچنین در این پژوهش، اشتراک بین ریل و موانع با استفاده از عملیات ضرب ماسک ریل و اشیاء موجود در تصویر مورد بررسی قرار گرفته است.


در (Wang, Wu, Yu, & Li, 2018) یک روش کارآمد تشخیص منطقه راه‌آهن بر اساس شبکه عصبی کانولوشنال (CNN) ارائه شد. این روش شامل دو بخش، استخراج منطقه ریل و اصلاح بیشتر آن است. اصلاح بیشتر شامل به حداکثر رساندن تطابق کانتور ناحیه ریل استخراج شده با استفاده از روش برازش چند ضلعی و در نتیجه بدست آوردن یک طرح کلی دقیق‌تر از منطقه ریل است. شبکه مورد استفاده در این مقاله، از شبکه (Badrinarayanan, Handa, & SegNet, 2015) که یک معماری رمزگذار-رمزگشا<sup>۸</sup> است، الهام گرفته شده است. رمزگذار ویژگی‌های ناحیه ریلی را در تصویر استخراج می‌کند و رمزگشا، نقشه‌های ویژگی رمزگذار را برای مطابقت با وضوح ورودی، نمونه‌برداری کرده و همچنین مسیر راه‌آهن را در لایه Softmax طبقه‌بندی می‌کند. آموزش و آزمایش شبکه پیشنهادی با استفاده از یک مجموعه داده سفرهای به نام BH-rail انجام شد که بر اساس استانداردهای مجموعه داده Cityscape (Cordts, et al., 2016) حاشیه‌نویسی شده است. مجموعه داده در خط یانفانگ مترو پکن و خط ۶ مترو شانگهای با دوربین On-Board ضبط شده است.

بلوک باقیمانده، ماژول SSP و.. تشکیل شده است. یک ماژول تجمیع مسیر در مقیاس متقابل دوجته به‌عنوان هسته شبکه ترکیب ویژگی طراحی شده است. برای مقایسه روش پیشنهادی با سایر الگوریتم‌های تشخیص اشیاء از معیارهایی مانند میانگین دقت متوسط (MAP)، زمان تشخیص، پارامترها و... استفاده شد. نتایج نشان داد که روش پیشنهادی بهترین عملکرد جامع را دارد و میانگین دقت متوسط می‌تواند به ۹۲/۵۷ درصد برسد. در (Ristic-Durrant, et al., 2020) یک روش جدید مبتنی بر یادگیری ماشین به نام DisNet ارائه شده است که از دوربین On-Board به‌منظور شناسایی موانع احتمالی در مقابل قطار استفاده می‌کند. DisNet از دو بخش تشکیل شده است: بخش اول تشخیص اشیاء مبتنی بر یادگیری عمیق را انجام می‌دهد و در بخش دوم از یک سیستم مبتنی بر شبکه عصبی با چند لایه پنهان برای تخمین فاصله استفاده شده است. آشکارساز شی، می‌تواند هر روش مبتنی بر یادگیری عمیق که توانایی شناسایی جعبه مرزی و کلاس اشیاء را دارد، باشد.

در (Zhang, Yan, Song, Wang, & Li, 2023) یک چارچوب تشخیص سه مرحله‌ای سبک وزن برای شناسایی موانع در راه‌آهن پیشنهاد شده است. این چارچوب شامل سه مرحله است: تولید پروپوزال‌های پیشنهادی، استفاده از یک شبکه تشخیص مانع سبک‌وزن برای شناسایی موانع، و مرحله پس‌پردازش. در این مطالعه، یک مدل تشخیص سبک و مؤثر بر اساس پیشرفت‌های اساسی YOLOv4-tiny طراحی شده است تا به‌طور همزمان جعبه‌های مرزی را در کل تصویر و در هر زیر منطقه پیش‌بینی کند.

در (Guan, Jia, Xie, & Yin, 2022) از ترکیب روش‌های بینایی ماشین و لیدار برای تشخیص مانع در راه‌آهن استفاده شده است. باتوجه به ضعف الگوریتم‌های بینایی ماشین در شرایط جوی مختلف، در این مطالعه با ادغام اطلاعات بصری بدست آمده از روش بینایی ماشین و لیدار، در خصوص وجود یا عدم وجود مانع در مسیر حرکت قطار، تصمیم‌گیری می‌شود.

RailCNN آورده شده است، ریل اصلی با رنگ سبز مشخص شده است. اما همان طور که در این شکل مشاهده می‌شود، شناسایی مسیر حرکت قطار در جلوی سوزن که کار بسیار دشواری است، از اهداف این مقاله نیست. روش RailCNN با IOU حدود ۰,۹۳ توانایی شناسایی ریل اصلی به جز نواحی سوزن را روی مجموعه داده Railsem 19 دارد.

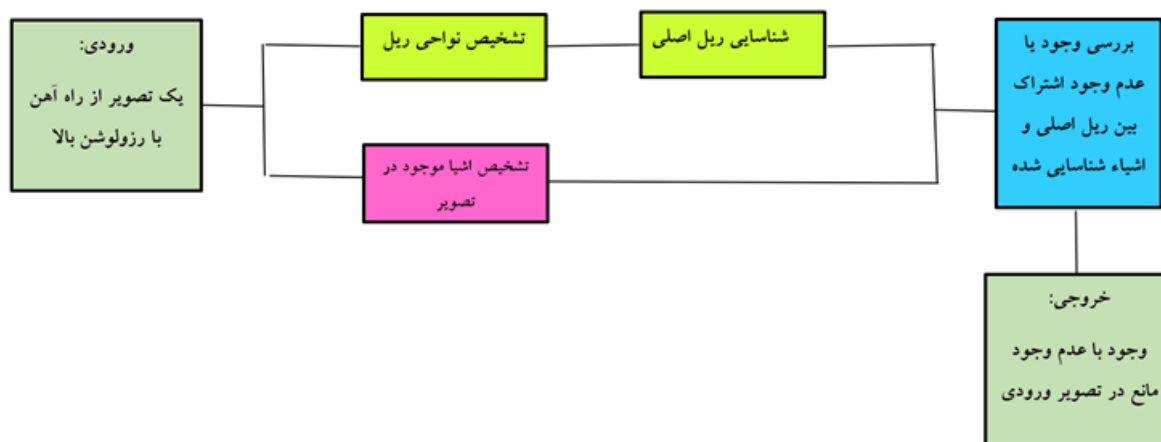


شکل ۲. نحوه تقسیم ریل های موجود در تصویر به دو کلاس ریل

اصلی و فرعی در روش RailCNN

### ۳. الگوریتم پیشنهادی تشخیص مانع در راه آهن

همان‌طور که در شکل ۳ مشاهده می‌شود، الگوریتم پیشنهادی در این مطالعه شامل سه مرحله کلی است که در ادامه به بررسی دقیق این مراحل پرداخته خواهد شد:



شکل ۳. بلوک دیاگرام الگوریتم سه مرحله‌ای تشخیص مانع در راه آهن

در (Wang Y. , Wang, Hu, & Qiu, 2019) یک الگوریتم ناحیه‌بندی مبتنی بر یادگیری عمیق، برای راه‌آهن به نام RailNet ارائه شده است. که در آن از یک شبکه استخراج ویژگی و یک شبکه ناحیه‌بندی تشکیل شده است. شبکه استخراج ویژگی از یک ساختار هرمی برای انتشار ویژگی‌ها از بالا به پایین برای بدست آوردن یک بردار ویژگی ترکیبی استفاده می‌کند. شبکه ناحیه‌بندی یک شبکه کانولوشن برای تولید نقشه ناحیه‌بندی راه‌آهن است. نویسندگان به منظور آموزش و آزمایش شبکه RailNet یک مجموعه داده ناحیه‌بندی راه‌آهن ایجاد کردند. این مجموعه داده شامل ۳۰۰۰ تصویر است که از ۲۵۰۰ تصویر برای آموزش، ۲۰۰ تصویر برای اعتبارسنجی و ۳۰۰ تصویر برای آزمایش استفاده شد. در برجسب‌گذاری داده‌های راه‌آهن، مسیر راه‌آهن، تمام پیکسل‌های بین دو ریل، تعریف شده است. وزن‌های شبکه عصبی ستون فقرات (که Resnet 50 است) برای آموزش داده شده توسط مجموعه داده ImageNet (Deng, et al., 2009) مقداردهی اولیه شدند.

در (Belyaev, et al., 2020) روشی با نام RailCNN پیشنهاد شده است. در این روش علاوه بر ناحیه بندی و شناسایی همه ریل‌های موجود در تصویر، ریل به دو کلاس ریل اصلی و فرعی نیز تقسیم می‌شود. در شکل ۲ که در متن مقاله

موانع را دارد ولی بدلیل محدودیت مجموعه داده و شرایط خاص راه‌آهن، آزمایش الگوریتم روی چند کلاس محدود انجام شد). ابعاد تصویر ورودی برای آزمایش شبکه، در نهایت (۸۹۶ و ۵۱۲) انتخاب شد. ابتدا ابعاد کوچک تر در نظر گرفته شد و با بزرگ شدن ابعاد، افزایش قابل توجه دقت مشاهده شد.

### ۳-۳ مرحله دوم: شناسایی نواحی ریل و شناسایی

#### مسیر حرکت قطار (ریل اصلی)

این مرحله خود به تنهایی شامل دو قسمت شناسایی نواحی ریل‌های موجود در تصویر و شناسایی مسیر حرکت قطار (ریل اصلی) از میان نواحی شناسایی شده است:

#### ۳-۳-۱ شناسایی نواحی ریل‌های موجود در تصویر

الگوریتم‌های کلاسیک پردازش تصویر مانند تبدیل هاف، تنها توانایی شناسایی ریل‌های مستقیم را دارند و در صورتی که ریل، قوس یا انحنای داشته باشد، عملکرد آن‌ها به شدت کاهش می‌یابد. اما از آنجایی که شبکه‌های عصبی عمیق از ویژگی‌های مختلف، برای شناسایی ریل استفاده می‌کنند، توانایی شناسایی ریل در شرایط مختلف با دقت بالا را دارند که این موضوع در مرحله آزمایش نیز اثبات شد. و الگوریتم با دقت بیش از ۹۹ درصد، توانایی شناسایی انواع ریل با قوس و انحناهای مختلف را داشت. در این مرحله از شبکه UNet به منظور ناحیه‌بندی و شناسایی نواحی ریل استفاده شده است. یک نمونه از تصویر ورودی و خروجی این شبکه در شکل ۴ نشان داده شده است. در این پژوهش از شبکه convnext\_base به عنوان backbone شبکه UNet استفاده شده است و با توجه به محدود بودن مجموعه داده آموزش، از یادگیری انتقالی برای بهبود دقت و جلوگیری از بیش‌برازش استفاده شد. برای آموزش شبکه از وزن‌های پیش‌آمورخته استفاده شده است و حتی هیچ یک از لایه‌ها freeze نشده اند و یادگیری انتقالی روی همه لایه‌ها انجام گرفته است. و مشاهده شد که حتی با آموزش شبکه به تعداد یک دوره، شبکه دقت نسبتاً مناسبی روی داده‌های آزمایش دارد. و بعد از ۴ دوره به دقت بسیار

### ۳-۱ ورودی و خروجی الگوریتم

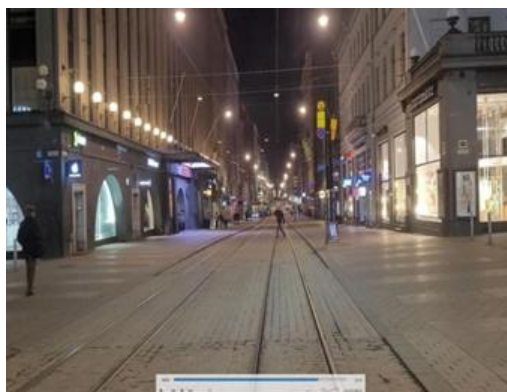
همان‌طور که پیش‌تر و در بخش مقدمه نیز اشاره شد، فرض اصلی و مهم این مقاله، نصب دوربین روی قطار است، در واقع ورودی الگوریتم پیشنهادی در این مقاله، یک فریم از تصاویر گرفته‌شده توسط دوربین نصب شده روی قطار است. و خروجی الگوریتم یک عدد ثابت صفر یا یک است، با این مفهوم که عدد صفر به معنی ایمن بودن مسیر و عدم وجود مانع است و عدد یک به معنی وجود مانع در مسیر حرکت قطار است.

### ۳-۲ مرحله اول: تشخیص اشیاء موجود در تصویر

#### توسط الگوریتم تشخیص اشیاء

در این مرحله تمامی اشیاء موجود در تصویر که ممکن است کاندید احتمالی به عنوان موانع باشند، توسط یک الگوریتم تشخیص اشیاء، شناسایی می‌شوند. یکی از محدودیت‌های موجود در حوزه تشخیص مانع در راه‌آهن، عدم دسترسی به یک مجموعه داده بزرگ با کلاس‌های متنوع است. به دلیل محدودیت‌ها و شرایط خاص راه‌آهن، امکان جمع‌آوری چنین مجموعه داده‌ای وجود نداشته و این مجموعه داده در دسترس نیست. از آنجایی که در صورت آموزش شبکه تشخیص اشیاء بر روی مجموعه داده کوچک می‌تواند منجر به بیش‌برازش شبکه شود و همچنین با توجه به عدم وجود مجموعه داده مانع‌دار راه‌آهن با تعداد کلاس‌های بالا، در این پژوهش به منظور افزایش تعداد کلاس‌ها و جلوگیری از بیش‌برازش شبکه YOLO، از نسخه آموزش دیده این شبکه روی مجموعه داده COCO استفاده شد و حتی تنظیم دقیق وزن‌ها روی مجموعه داده راه‌آهن انجام نشد. به این ترتیب الگوریتم پیشنهادی توانایی شناسایی ۸۰ کلاس از اشیاء شامل (انسان، قطار، اتومبیل، حیوانات و...) را دارد. با این حال، به دلیل محدودیت مجموعه داده راه‌آهن، آزمایش الگوریتم تشخیص مانع بر روی یک مجموعه داده غیرعمومی راه‌آهن انجام شد. این مجموعه داده شامل کلاس‌هایی محدود مانند انسان، قطار، چند نوع حیوان، دوچرخه و موتورسیکلت بود. (الگوریتم توانایی تشخیص ۸۰ نوع کلاس از

بنظر می‌رسد که این مجموعه‌داده از فریم‌های یک ویدیو در یک منطقه خاص تهیه شده است به همین دلیل از مجموعه داده Railsem19 که شامل تصاویر متنوعی از صحنه‌های راه‌آهن بود، برای آموزش شبکه UNet استفاده شد. اما با توجه به اینکه اکثر تصاویر این مجموعه‌داده فاقد مانع هستند، از این مجموعه‌داده تنها برای قسمت شناسایی ریل و مسیر حرکت قطار استفاده شده است و برای قسمت تشخیص اشیاء، مجموعه‌داده‌های دیگری مورد استفاده قرار گرفته‌اند. در سایر مطالعات نیز بدلیل عدم وجود مانع در مجموعه‌داده‌های عمومی، اغلب از مجموعه داده‌های شخصی برای مرحله تشخیص اشیاء استفاده شده است. تصاویر مجموعه داده Railsem19 ابعاد (۱۹۲۰ و ۱۰۸۰) دارند. ابعاد نهایی برای آموزش و آزمایش شبکه (۸۹۶ و ۵۱۲) انتخاب شد که سعی شد نسبت طول به عرض نسبت به ابعاد اصلی تصویر، حفظ شود. در ابتدا از ابعاد کوچکتر برای آموزش و آزمایش شبکه استفاده شد و مشاهده شد که شبکه توانایی تشخیص ساختار کلی ریل را دارد اما توانایی شناسایی بعضی از جزئیات مانند نواحی انتهایی ریل و انشعاب‌ها را ندارد. به همین دلیل در نهایت شبکه با ابعاد (۸۹۶ و ۵۱۲) آموزش و آزمایش شد. بزرگ شدن ابعاد تصویر، دقت را به میزان قابل توجهی افزایش داد، اما سرعت نسبت به ابعاد کوچکتر کاهش یافت.



شکل ۴. شناسایی نواحی ریل توسط شبکه UNet

مناسب (Accuracy بیش از ۹۹ درصد) رسید، اما پس از ۵ دوره مشاهده شد که شبکه دچار بیش‌برازش شده است. مقدار batch size برای آموزش شبکه عدد ۳ انتخاب شد. همچنین از روش‌های نرمال‌سازی مانند نرمال‌سازی اولیه روی داده‌های ورودی و نرمال‌سازی دسته‌ای استفاده شده است. با توجه به اینکه مجموعه‌داده Railsem19 (Zendel, et al., 2019) شامل تعداد ۸۵۰۰ تصویر از صحنه‌های واقعی راه‌آهن است، این مجموعه‌داده می‌تواند انتخاب مناسبی برای آموزش شبکه باشد که در این مقاله از ۷۰۰۰ تصویر از این مجموعه‌داده برای آموزش شبکه UNet استفاده شده است. به دلیل محدودیت شرایط راه‌آهن، مجموعه‌داده‌های بسیار محدودی در این زمینه وجود دارد و در بسیاری از مقالات مرتبط، از مجموعه‌داده‌های شخصی که معمولاً در دسترس عموم قرار ندارند، استفاده شده است. بعد از بررسی، مشاهده شد سه مجموعه داده شامل مجموعه‌داده Railsem19، یک مجموعه داده از کشور روسیه، و مجموعه داده RSDS در دسترس هستند، که بعد از بررسی مجموعه‌داده روسیه، مشاهده شد که این مجموعه‌داده، شامل تصاویر مشابه زیادی است و از تنوع تصاویر بسیار کمی برخوردار است. و از آنجایی که این مجموعه داده تنها از کشور روسیه تهیه شده است، فقط شرایط آب و هوایی و پوشش گیاهی این کشور را شامل می‌شود. همچنین در مجموعه‌داده RSDS تصاویر بسیار ساده و تکراری هستند و



## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق

نصب دوربین روی قطار، ریل اصلی، ریلی است که شروع آن در وسط تصویر قرار داشته باشد، برای مثال در شکل ۵ ب خروجی شبکه UNet را مشاهده می‌کنیم که شامل دو ریل مجزا است، این تصویر شامل دو مؤلفه است که با انتخاب مؤلفه‌ای که نقطه پایین و وسط تصویر را شامل می‌شود، مسیر حرکت قطار و ریل اصلی بدست می‌آید که نتیجه را در شکل ۵ الف مشاهده می‌کنیم. اما متأسفانه تشخیص مسیر حرکت قطار همیشه به این سادگی نیست و باتوجه به پیچیدگی‌های ریل با چالش‌های زیادی روبه‌رو هستیم که در ادامه به بررسی چالش‌های مسئله شناسایی مسیر حرکت قطار، پرداخته خواهد شد.



ب

### ۳-۲-۳ شناسایی مسیر حرکت قطار (ریل اصلی) از میان

#### نواحی شناسایی شده

در این مرحله نیاز است که مسیر حرکت قطار از میان نواحی ریلی شناسایی شده، جدا شود، به همین منظور در این مقاله الگوریتمی پیشنهاد شده است که با استفاده از یک شبکه تشخیص اشیاء و روش‌های پردازش تصویر، مسیر حرکت قطار از میان سایر ریل‌ها شناسایی شود. در صورتی که تنها یک ریل در تصویر وجود داشته باشد، نیازی به شناسایی مسیر حرکت قطار نیست و همان ریل، مسیر حرکت قطار است. اما در صورتی که بیش از یک ریل در تصویر وجود داشته باشد، در شرایطی که ریل‌ها کاملاً از هم مجزا باشند، باتوجه به فرض اولیه مسئله یعنی



الف

شکل ۵. الف: خروجی شبکه YOLO ب: ریل اصلی


تأخداً مکان ریل به حالت اولیه بازگردد. مراحل در شکل ۷ قابل مشاهده هستند.

• چالش اول: رسیدن ریل‌ها به هم در نواحی دور

در شکل ۶ به نظر می‌رسد که دو ریل در ناحیه‌های دور به هم همگرا شده‌اند، در حالی که می‌دانیم این دو ریل کاملاً از هم مجزا هستند و مسیر حرکت قطار، ریلی است که روی آن اتومبیل قرار دارد. در خروجی UNet (شکل ۷. بالا سمت چپ) نیز دو ریل به صورت به هم پیوسته شناسایی شده‌اند. در نتیجه ریل اصلی با روش پیشنهادی در قسمت قبل، قابل شناسایی نیست. از این رو نیاز است که در ابتدا به منظور جداسازی دو ریل، روی خروجی UNet، سایش انجام گیرد. سپس وسط‌ترین مؤلفه، به عنوان مسیر حرکت قطار انتخاب شود و در آخر عملیات گسترش، با همان فیلتر قبلی (فیلتر سایش)، روی ریل اصلی اعمال شود که



شکل ۶. نمونه تصویر که دو ریل در فاصله‌های دور به هم همگرا می‌شوند.



شکل ۷. مراحل تشخیص ریل اصلی، برای رفع چالش اول و پیدا کردن ریل اصلی

سوزن را در راه‌آهن نشان می‌دهد. در واقع مسیریابی با توجه به جهت زبانه سوزن که از کدام طرف (ریل سمت راست یا سمت چپ) فاصله گرفته است، تعیین می‌شود. برای مثال در شکل ۸ زبانه از ریل سمت چپ فاصله گرفته و مسیر حرکت قطار به سمت چپ است. حال مسئله مورد نظر، انجام این مسیریابی، توسط الگوریتم‌های هوش مصنوعی است. برای تعیین مسیر حرکت قطار ابتدا باید محدوده کلی سوزن و جهت زبانه‌های آن شناسایی شود. به همین منظور، یک مجموعه داده آموزش با سه کلاس مطابق با شکل ۹ تهیه شد. کلاس اول (جعبه قرمز رنگ) محدوده کلی سوزن را مشخص می‌کند، در حالی که کلاس‌های دوم و سوم محل دقیق زبانه‌های سوزن را تعیین می‌کنند. تفاوت

• چالش دوم: تعیین مسیر قطار در مکان‌هایی که سوزن وجود دارد.

سوزن ریل، یک وسیله مکانیکی است که برای قطارها امکان تغییر از یک مسیر به مسیر دیگر را در تقاطع‌ها فراهم می‌سازد. در حالت کلی نیاز است که مسیریابی در جلوی سوزن (جایی که یک ریل به دو شاخه تقسیم می‌شود) و پشت سوزن (جایی که دو شاخه ریل به یک شاخه تبدیل می‌شود) انجام شود. که در این پژوهش به طراحی الگوریتم برای مسیریابی در جلوی سوزن پرداخته شده است. و مسیریابی در پشت سوزن نیز به طریق مشابه انجام می‌گیرد که در قسمت پیشنهادات آینده آورده شده است. شکل ۸ یک نمونه از سوزن و نحوه مسیریابی در جلوی


## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق

کلاس از اهمیت بالایی برخوردار است. پس از آموزش شبکه YOLO بر روی این مجموعه داده، شبکه توانست با دقت بالا این سه کلاس را شناسایی کند.

اصلی بین این دو کلاس در این است که در کلاس دوم (جعبه زرد رنگ)، زبانه سوزن از ریل کناری فاصله گرفته است، در حالی که در کلاس سوم (جعبه سبز رنگ)، زبانه سوزن به ریل کناری چسبیده است. این تفاوت جزئی در تشخیص این دو




شکل ۸. یک نمونه سوزن و مسیریابی با توجه به جهت سوزن



شکل ۹. نمونه‌ای از برچسب‌های آموزشی سه کلاسه برای شناسایی محدوده کلی سوزن و ناحیه دقیق زبانه سوزن

تا این مرحله، محدوده کلی سوزن و محل دقیق زبانه‌های آن با دقت مناسبی شناسایی شده‌اند. اکنون نیاز است که با توجه به جهت زبانه سوزن، مسیر حرکت قطار مشخص شود و ریل‌های اضافی که ممکن است موانع کاذب ایجاد کنند، حذف گردند. ایده این مرحله به این صورت است که اگر بتوانیم در شکل ۱۰ الف مختصات دو نقطه را که یکی در محدوده آبی رنگ و یک نقطه دیگر در محدوده سبز رنگ قرار دارد را پیدا کنیم، و سپس مختصات آن دو نقطه را به صورت متناظر در شکل پیش‌بینی UNet شناسایی کنیم، (نقاط در شکل ۱۰ ب با رنگ‌های آبی و سبز قابل مشاهده‌اند)، با وصل کردن این دو نقطه به هم با خط راست مشکی، روی پیش‌بینی UNet، شکل ۱۱ الف بدست می‌آید که در این تصویر، مولفه‌ای که مسیر حرکت قطار قسمتی از آن است، تبدیل به دو مؤلفه شده است که یک مؤلفه مربوط به ریل اصلی است، (البته با مقداری خطا) و مؤلفه دیگر ریل‌های اضافی را نشان می‌دهد. که با حذف ریل‌های اضافی (مؤلفه‌هایی که از پایین شامل وسط‌ترین نقطه نمی‌شوند) فقط ریل اصلی باقی می‌ماند. شکل ۱۱ ب نمایانگر ریل نهایی است.

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق




ب



الف

شکل ۱۰. الف: محدوده های مورد نظر برای انتخاب دو نقطه ب: نقاط انتخاب شده روی تصویر ۱۰. الف بصورت متناظر روی خروجی UNet با رنگ سبز و آبی رسم شده اند.



ب



الف

شکل ۱۱. الف: تقسیم شدن شکل به دو مولفه بعد از رسم خط راست با شروع و پایان نقاط سبز و آبی در شکل ۱۰. ب: ریل نهایی بعد از انتخاب وسط ترین مولفه در شکل ۱۱. الف


(۱) در شکل ۱۰. ب که خروجی شبکه UNet را نشان می دهد، نقاط ریل که با رنگ سفید مشخص شده اند را به رنگ مشکی و نقاط مشکی زمینه را به رنگ سفید تبدیل می کنیم. (۲) یک صفحه مشکی با ابعاد تصویر اصلی ایجاد کرده و جعبه آبی رنگ مربوط به این تصویر را روی آن با رنگ سفید رسم می کنیم. (۳) ماسک بدست آمده در مراحل ۱ و ۲ را بصورت نظیر به نظیر در هم ضرب می کنیم.

فرض کنیم پیش بینی شبکه YOLO برای نمونه آزمایش یعنی شکل ۸ بصورت شکل ۱۳. الف باشد، نتیجه مورد نظر ما یعنی نقاطی از جعبه آبی رنگ در شکل ۱۳. الف که ریل نیستند، در شکل ۱۳. ب با رنگ زرد مشخص شده اند. با تکرار همین مراحل برای جعبه بنفش رنگ، اشتراک نقاط خارج از ریل و

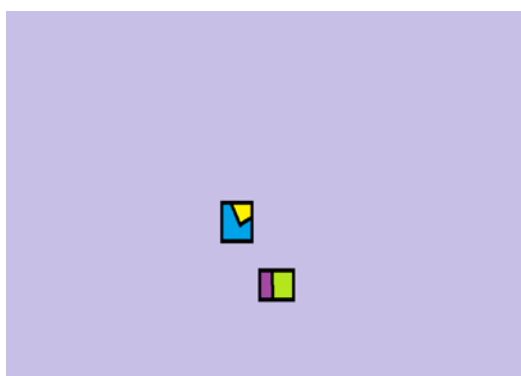
در ادامه، مسئله مورد نظر انتخاب دو نقطه است. بدین منظور، بر روی مجموعه داده آموزشی قبلی که شامل ۳ کلاس بود، دو برچسب جدید (برچسب های بنفش و آبی که کلاس های ۴ و ۵ هستند) به صورت شکل ۱۲ اضافه می کنیم و سپس شبکه را دوباره آموزش می دهیم. پس از اتمام فرآیند آموزش، مشاهده می شود که شبکه قادر است به راحتی این دو جعبه را در نمونه های آزمایش شناسایی کند. در شکل ۱۲ نقاطی از تصویر که در جعبه آبی رنگ قرار دارند ولی نقاط ریل نیستند، محدوده آبی رنگ را در شکل ۱۰. الف نشان می دهند. به منظور شناسایی مختصات این نقاط، نیاز است مراحل زیر روی مجموعه داده آزمایش (شکل ۸) انجام گیرد:

ابتدا و انتهای این نقاط، مولفه ریل اصلی به دو مولفه مجزا تقسیم گردد. انتخاب هر نقطه از هر یک از محدوده‌ها تا حدودی ما را به هدف مورد نظر می‌رساند، اما برای دقت بیش تر، مرکز مولفه‌ها به عنوان نقاط مورد نظر انتخاب شدند.

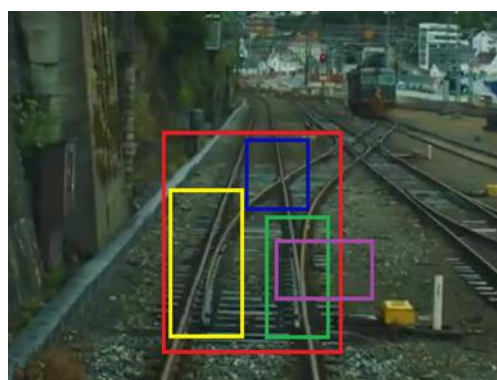
جعبه بنفش رنگ بدست می‌آید که این محدوده در شکل ۱۳. ب با رنگ سبز مشخص شده است. (محدوده‌ها بصورت تقریبی رسم شده‌اند). در ادامه نیاز است از هر کدام از محدوده‌های شناسایی شده، یک نقطه انتخاب شود، تا با رسم خط راستی با



شکل ۱۲. جعبه‌های بنفش و آبی بمنظور پیدا کردن محدوده دو نقطه مورد نظر رسم شده‌اند.



ب



الف

شکل ۱۳. الف: جعبه‌های بنفش و آبی (کلاس‌های ۴ و ۵) در نمونه آزمایش ب: اشتراک جعبه آبی و بنفش (کلاس‌های ۴ و ۵) با نقاط خارج از ریل با رنگ زرد و سبز مشخص شده است.

روش پیشنهادی برای یافتن جعبه‌های بنفش و آبی (کلاس ۴ و ۵) مربوط به هر سوزن به این صورت است که ابتدا یکی از جعبه‌های قرمز رنگ که محدوده کلی سوزن را مشخص می‌کند، انتخاب می‌شود و سپس اشتراک همه جعبه‌های بنفش رنگ با جعبه قرمز محاسبه می‌شود و در نهایت جعبه بنفشی که بیشترین اشتراک را با جعبه قرمز مورد نظر داشته باشد، به عنوان جعبه بنفش مربوط به آن سوزن انتخاب می‌شود. به همین ترتیب جعبه

الگوریتم پیشنهادی تا این قسمت، تنها در صورتی کارایی دارد که فقط یک سوزن در تصویر وجود داشته باشد در غیر این صورت الگوریتم دچار خطا می‌شود. بنابراین، در ادامه نیاز است روشی پیشنهاد شود که توانایی تشخیص مسیر حرکت قطار را در شرایطی که بیش از یک سوزن در تصویر وجود دارد، دارا باشد. در این شرایط نیاز است جعبه‌های بنفش و آبی (کلاس‌های ۴ و ۵) مربوط به هر سوزن به صورت جداگانه شناسایی شوند و مراحل قسمت قبل به صورت جداگانه روی آن‌ها اعمال گردد.

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق

در صورتی که سه شرط زیر برقرار باشد، تنها یک سوزن در تصویر وجود دارد و الگوریتم تشخیص سوزن به صورت عادی اجرا می شود (منظور از حالت عادی، حالت تک سوزن اولیه است):

- شناسایی فقط یک جعبه قرمز در تصویر توسط شبکه YOLO

- شناسایی حداقل یک جعبه آبی در تصویر توسط شبکه YOLO

- شناسایی حداقل یک جعبه بنفش در تصویر توسط شبکه YOLO

• حالت دوم: بیش از یک سوزن در تصویر وجود دارد:

در غیر این صورت اگر سه شرط زیر برقرار باشد، بیش از یک سوزن در تصویر وجود دارد و نیاز است جعبه های مربوط به هر سوزن به صورت مجزا شناسایی شوند:

- شناسایی بیش از یک جعبه قرمز در تصویر توسط شبکه YOLO

- شناسایی حداقل یک جعبه آبی در تصویر توسط شبکه YOLO

- شناسایی حداقل یک جعبه بنفش در تصویر توسط شبکه YOLO

• حالت سوم: سوزن در تصویر وجود ندارد.

در غیر این صورت:

سوزن در تصویر وجود ندارد.

در حالت سوم الگوریتم اصلاً وارد مرحله شناسایی مسیر حرکت قطار در جلوی سوزن نمی شود.

۳-۴ مرحله سوم: بررسی وجود یا عدم وجود

اشتراک بین ریل اصلی و اشیاء شناسایی شده توسط

### شبکه YOLO

در این مرحله، خروجی نهایی مرحله دو، یعنی ماسک مسیر حرکت (شکل ۱۵.ب) و خروجی شبکه YOLO (شکل ۱۵.الف) بصورت نظیر به نظیر در هم ضرب می شوند. در صورتی که ماتریس حاصل از ضرب این دو ماسک، حداقل یک درایه بزرگتر از صفر داشته باشد، مانع در مسیر حرکت قطار قرار دارد، در غیر

آبی متناظر با آن سوزن نیز تعیین می شود. این مراحل برای تمامی جعبه های قرمز رنگ تکرار می شود.

### ۳-۳-۳ ایراد روش پیشنهادی

تا اینجا الگوریتم توانایی تشخیص مسیر حرکت قطار را حتی در حالتی که چند سوزن در تصویر وجود داشته باشد، داراست، اما در صورتی که دو سوزن به هم بسیار نزدیک باشند و جعبه قرمز (محدوده کلی سوزن) آن ها با هم اشتراک داشته باشد، گاهی اوقات الگوریتم ممکن است دچار خطا شود. این وضعیت را می توان در سمت راست شکل ۱۴ مشاهده کرد، جایی که دو سوزن بسیار نزدیک به هم قرار دارند. در این حالت نیز روش پیشنهادی به این صورت است که به جای محاسبه اشتراک کل جعبه قرمز با جعبه های بنفش و آبی، از اشتراک نیمه پایینی جعبه قرمز برای محاسبه اشتراک با جعبه بنفش، و از نیمه بالایی جعبه قرمز برای محاسبه اشتراک با جعبه آبی استفاده می کنیم. این رویکرد کمک می کند تا دقیق تر بتوانیم جعبه های مربوط به هر سوزن را شناسایی کنیم و از خطاهای احتمالی ناشی از نزدیکی سوزن ها جلوگیری نماییم.



شکل ۱۴. یک نمونه خطای الگوریتم در حالتی که دو سوزن بسیار نزدیک به هم هستند.

### ۳-۳-۴ خلاصه الگوریتم پیشنهادی تشخیص سوزن

الگوریتم تشخیص سوزن پیشنهادی در این مقاله سه حالت کلی را شامل می شود:

• حالت اول: یک سوزن در تصویر وجود دارد.

کاذب بیش تری شناسایی و حذف می شوند. در واقع هدف اصلی این مقاله، طراحی الگوریتم شناسایی مسیر حرکت قطار به منظور حذف موانع کاذب می باشد.

این صورت مسیر ایمن است و خطری وجود ندارد. و به این ترتیب موانع واقعی از موانع کاذب جدا می شوند. بدیهی است که هر چه شناسایی مسیر حرکت قطار دقیق تر انجام گیرد، موانع



ب



الف

شکل ۱۵. الف: خروجی شبکه YOLO ب: ریل اصلی

جدول ۱. نتایج دقت الگوریتم تشخیص مانع در راه آهن روی

مجموعه داده آزمایش

Accuracy	۸۷/۲
Recall	۸۳/۴
Precision	۸۷/۵
F1score	۸۵/۴

همان طور که در جدول ۱ مشاهده می شود، الگوریتم پیشنهادی حدود ۱۳ درصد خطا داشته است. در ادامه، دلایل خطای الگوریتم مورد بررسی و تحلیل قرار خواهد گرفت.

موارد خطای الگوریتم روی مجموعه داده آزمایش به دقت بررسی شد، عمده دلایل خطا در یکی از ۳ حالت زیر مشاهده شدند:

(۱) عدم تشخیص تعدادی از اشیاء توسط شبکه تشخیص اشیاء (YOLOv8x): در این پژوهش، با وجود استفاده از شبکه YOLOv8x که دقت بالاتری نسبت به سایر نسخه های YOLOv8 دارد، این شبکه در تعدادی از موارد توانایی شناسایی برخی از اشیاء موجود در تصویر را نداشت. در نتیجه، الگوریتم کلی تشخیص مانع نیز در چنین مواردی دچار خطا شد و نتوانست برخی از موانع را به درستی شناسایی کند.

#### ۴. تحلیل داده ها

در این مطالعه یک الگوریتم تشخیص مانع در راه آهن ارائه شد. از آنجایی که در موضوع تشخیص مانع در راه آهن، شناسایی مسیر حرکت قطار از اهمیت بالایی برخوردار است و عدم حذف ریل های اضافی، باعث ایجاد موانع کاذب فراوان می شود، در این مقاله به طراحی الگوریتم شناسایی مسیر حرکت قطار پرداخته شد. که یکی از بخش های مهم آن شناسایی مسیر حرکت قطار با کمک الگوریتم تشخیص سوزن است. در ادامه به بررسی نتایج الگوریتم تشخیص مانع و سایر زیر الگوریتم ها بصورت جزئی پرداخته خواهد شد.

#### ۴-۱ بررسی نتایج الگوریتم کامل تشخیص مانع در

##### راه آهن

تصاویر آزمایش در این پژوهش شامل ۱۶۶۴ تصویر است که الگوریتم تشخیص مانع در ۱۴۵۱ تصویر خروجی صحیح داشت و در ۲۱۳ تصویر دچار خطا شد، در جدول ۱ دقت الگوریتم تشخیص مانع روی مجموعه داده آزمایش با معیارهای مختلف برحسب درصد، آورده شده است:

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق

همین دلیل، ریل و قطار هیچ گونه اشتراکی با یکدیگر نخواهند داشت و الگوریتم دچار خطا شده و توانایی شناسایی این نوع موانع را نخواهد داشت.

۲) عدم تشخیص اشیاء انتهایی ریل: شکل ۱۶ را در نظر بگیرید. در این شکل، با وجود شناسایی دقیق محل قطار و ناحیه بندی دقیق ریل، ناحیه بندی هرگز شامل نواحی زیر قطار نمی شود. به



شکل ۱۶. قطاری که روی ریل اصلی به سمت قطار مورد نظر در حال حرکت است و الگوریتم در حالت کلی توانایی تشخیص آن را بعنوان مانع ندارد.

حرکت است. با وجود ایمن بودن مسیر حرکت قطار مورد نظر، اشتراک کاذبی بین قطار قرمز رنگ و ریل مسیر حرکت قطار ایجاد شده است که منجر به تشخیص موانع کاذب شده است.

۳) ایجاد مانع کاذب بدلیل بزرگ بودن جعبه قطار: در شکل ۱۷ مسیر حرکت قطار مورد نظر با رنگ بنفش مشخص شده است و قطار قرمز رنگ روی ریل مجزا از مسیر مورد نظر در حال



شکل ۱۷. ایجاد موانع کاذب بدلیل بزرگ بودن جعبه قطار

جدول ۲. نتایج دقت الگوریتم تشخیص سوزن روی مجموعه داده

آزمایش	
Accuracy	۹۸/۹
Recall	۸۹/۳
Precision	۹۴/۷
F1score	۹۱/۹

### ۲-۴ بررسی نتایج الگوریتم تشخیص سوزن

نمونه های آزمایش الگوریتم تشخیص سوزن نیز شامل ۱۶۶۴ تصویر است که در ۱۲۱ تصویر سوزن وجود دارد و در ۱۵۴۳ تصویر سوزن وجود ندارد. در جدول ۲ دقت الگوریتم تشخیص سوزن روی مجموعه داده آزمایش با معیارهای مختلف آورده شده است:

که در این صورت الگوریتم توانایی شناسایی مسیر حرکت قطار را ندارد. در ادامه به بررسی یک نمونه چالشی که در مسیر حرکت قطار، دو سوزن بسیار نزدیک به هم قرار دارند، پرداخته خواهد شد، و مشاهده می‌شود، الگوریتم با دقت بالایی توانایی حذف ریل‌های اضافی را دارد.


شکل ۱۸ را در نظر بگیرید:



شکل ۱۸. یک نمونه تصویر که در آن دو سوزن بسیار نزدیک به هم در مسیر حرکت قطار، قرار دارند.

همان طور که مشاهده می‌شود، الگوریتم با دقت نزدیک به ۹۹ درصد توانایی مسیریابی در نواحی سوزن را دارد. حدود یک درصد خطا مربوط به تعدادی از مواردی است که سوزن در نواحی بسیار دور قرار دارد و جهت زبانه سوزن دقیق مشخص نیست. یکی دیگر از دلایل خطا، عدم شناسایی یکی از جعبه‌های مشخص شده در شکل ۱۲ توسط شبکه YOLO می‌باشد

خروجی شبکه YOLO (شبکه YOLO برای تشخیص سوزن) و خروجی شبکه UNet برای این تصویر را در به ترتیب در شکل‌های ۱۹ و ۲۰ مشاهده می‌کنیم:



شکل ۱۹. خروجی شبکه YOLO برای شکل ۱۸

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه‌آهن با استفاده از یادگیری عمیق

برچسب واقعی، نشان داده شده است. که همان طور که مشاهده می‌شود، پیش بینی شبکه و برچسب‌های واقعی، تنها در نواحی مرزی با هم اختلاف کوچکی دارند که این موضوع بدلیل عدم توانایی برچسب زنی دقیق در داده‌های آموزش اتفاق افتاده است. و از آنجایی که این نمونه دقتی تقریباً برابر با دقت متوسط دارد، نتیجه می‌گیریم دقت ناحیه بندی برای موضوع مورد نظر مقدار بسیار مناسبی است.

جدول ۳. نتایج دقت ناحیه‌بندی ریل توسط شبکه UNet روی

مجموعه داده آزمایش

Accuracy	۹۹/۳
Recall	۹۶/۵
Precision	۹۵/۷
F1score	۹۶/۱



شکل ۲۳. اختلاف برچسب واقعی و پیش بینی شبکه برای یک

نمونه آزمایش



شکل ۲۴. اختلاف پیش بینی شبکه از برچسب واقعی برای یک

نمونه آزمایش

### ۴-۴ مقایسه روش پیشنهادی با سایر مطالعات

یکی از دستاوردهای این مطالعه، طراحی الگوریتم تشخیص مانع با توانایی تشخیص ۸۰ کلاس از موانع می‌باشد که در مقایسه با



شکل ۲۰. خروجی شبکه UNet برای شکل ۱۸

در شکل ۲۱ مولفه ریل مسیر حرکت، با دقت بالایی از سایر مولفه‌ها جدا شده است.



شکل ۲۱. جدا شدن مولفه ریل اصلی از سایر مولفه‌ها

در نهایت وسط ترین مولفه، بعنوان ریل مسیر حرکت قطار انتخاب می‌شود (شکل ۲۲).



شکل ۲۲. ریل مسیر حرکت قطار در شکل ۱۸

### ۳-۴ بررسی نتایج ناحیه بندی ریل توسط شبکه

#### UNet

به دلیل اهمیت ناحیه‌بندی دقیق ریل در افزایش دقت الگوریتم کلی تشخیص مانع در راه‌آهن، نتایج دقت ناحیه‌بندی با معیارهای مختلف در جدول ۳ ارائه شده است. همچنین برای درک بهتر از دقت ناحیه بندی، در شکل ۲۳ اختلاف برچسب واقعی و پیش بینی شبکه و همچنین در شکل ۲۴ اختلاف پیش بینی شبکه از

همان‌طور که در جدول ۴ مشاهده می‌شود، تنها در یکی از روش‌ها از مجموعه داده Railsem19 استفاده شده است. که طبق شکل ۲ که در متن این مقاله ارائه شده است، مسیریابی در نواحی جلوی سوزن، که کار بسیار دشواری است، جزء اهداف آن مقاله نبوده است. این موضوع نشان‌دهنده کامل بودن روش پیشنهادی ما نسبت به این مطالعه است. همچنین برچسب زدن نواحی سوزن در سایر مجموعه‌داده‌ها برای مقایسه عددی نیز کار پرهزینه و زمان‌بری بود. در ادامه، دقت ناحیه‌بندی شبکه UNet با روش‌های سایر مقالات در جدول ۴ مقایسه شده است. در بعضی از این مقالات، دقت ناحیه‌بندی تمام ریل‌ها گزارش شده است و در بعضی دیگر، دقت ناحیه‌بندی مربوط به ریل مسیر حرکت قطار مورد ارزیابی قرار گرفته است. این قسمت از نوآوری‌های مطالعه به شمار نمی‌آید اما به هر حال مقایسه با سایر روش‌ها انجام شده است.

جدول ۴. مقایسه دقت ناحیه بندی در پژوهش های مختلف

IOU	مجموعه داده	نام الگوریتم یا شبکه
۹۲/۸	Railsem19	UNet
۸۵/۷	مجموعه داده روسیه	PAN+EfficientNet
۹۳	Railsem19	RailCNN
۸۹/۸	RSDS	RailNet

## ۵. جمع‌بندی و نتیجه‌گیری


در این مطالعه به طراحی الگوریتم تشخیص مانع در راه‌آهن پرداخته شد. در مرحله اول تمامی اشیاء موجود در تصویر توسط شبکه YOLOv8 شناسایی شدند. در این مرحله به‌منظور عدم بیش‌برازش شبکه روی مجموعه‌داده و افزایش تعداد کلاس‌ها، از شبکه YOLO آموزش دیده روی مجموعه داده COCO استفاده شد. (الگوریتم پیشنهادی در این مطالعه توانایی شناسایی ۸۰ نوع از موانع را دارد). در مرحله دوم ابتدا نیاز بود که تمامی ریل‌های موجود در تصویر شناسایی شوند، از این‌رو از شبکه UNet به‌منظور شناسایی نواحی ریل استفاده شد. در ادامه مرحله ۲، به‌منظور کاهش تعداد موانع کاذب، نیاز بود که مسیر حرکت قطار

سایر مقالات که در اکثر آن‌ها الگوریتم طراحی شده تنها توانایی تشخیص ۳ یا ۴ کلاس از موانع را دارد، پیشرفت قابل توجهی می‌باشد که این کار با توجه به محدودیت مجموعه‌داده مانع دار راه آهن، با استفاده از ایده استفاده از شبکه پیش‌آمورخته روی مجموعه‌داده COCO و عدم تنظیم دقیق وزن‌ها روی مجموعه داده راه آهن، انجام گرفته است. همچنین مقاله حاضر به معرفی یک الگوریتم نوآورانه در زمینه شناسایی مسیر حرکت قطار می‌پردازد. مهم‌ترین بخش این الگوریتم، شناسایی مسیر حرکت قطار در نواحی جلوی سوزن است. الگوریتم پیشنهادی توانایی مسیر یابی در این نواحی را با دقت بالا دارد. برای این منظور، ابتدا نیاز است تا جهت زبان سوزن که جزئیات کوچکی از تصویر را تشکیل می‌دهد، شناسایی شود و سپس بر اساس این جهت، عملیات مسیریابی انجام گیرد. در سایر مقالات، شناسایی مسیر حرکت قطار به الگوریتم‌هایی که کار ناحیه‌بندی را انجام می‌دهند واگذار شده است؛ اما در بسیاری از این پژوهش‌ها، مسیریابی در نواحی جلوی سوزن مورد توجه قرار نگرفته است. با توجه به اینکه برای مسیریابی در جلوی سوزن، ابتدا نیاز است که جهت زبانه سوزن، که یک شیء بسیار ریز در تصویر است، توسط الگوریتم شناسایی شود و سپس بر اساس این جهت، مسیریابی انجام گیرد، در این پژوهش، برخلاف روش‌های سایر مقالات، برای اولین بار یک الگوریتم مجزا برای مسیریابی در نواحی سوزن طراحی شده است. در این روش، یک شبکه YOLO به‌طور خاص برای شناسایی جزئیات ریز سوزن آموزش داده شد. پس از آن، با استفاده از الگوریتم‌های کلاسیک پردازش تصویر، ریل اصلی از سایر ریل‌ها جدا شد و به این ترتیب مسیریابی انجام گرفت. این موضوع نشان‌دهنده کامل بودن روش پیشنهادی این مطالعه نسبت به مطالعات پیشین است که در نهایت مسیریابی در جلوی سوزن با دقت بالا انجام گرفت. به دلیل تفاوت مجموعه‌داده‌های مورد استفاده در پژوهش‌های مختلف، امکان مقایسه دقیق عددی روش مسیریابی در نواحی جلوی سوزن این مطالعه با سایر مطالعات وجود نداشت.

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه‌آهن با استفاده از یادگیری عمیق

شرایط جوی و آب و هوایی مختلف بودند. از میان این تصاویر، ۵۹ نمونه شامل تصاویر باران روی شیشه قطار، ۱۲۵ نمونه برف روی زمین و ۶۶ نمونه در شب و تاریکی بودند، در حالی که در سایر تصاویر، شرایط جوی و نور تقریباً مناسب بود. برای مثال در حالت برف روی زمین، حدود ۱۰ درصد کاهش دقت مشاهده شد. دقت روی ۱۶۶۴ تصویر، حدود ۸۷ محاسبه شد، در حالی که دقت در ۱۲۵ نمونه برفی حدود ۷۸ درصد محاسبه شد. شرایط جوی نامناسب، مانند مه، هوای ابری، برف روی زمین و باران روی شیشه قطار، بسته به شدت آن‌ها، باعث کاهش دقت الگوریتم تشخیص مانع می‌شوند. با این حال، در صورتی که شدت این عوامل کم باشد، دقت الگوریتم تقریباً مشابه حالت عادی است. بیشترین کاهش دقت الگوریتم مربوط به شرایط تاریکی کامل است، که در آن الگوریتم دقت مناسبی ندارد. به همین دلیل، پیشنهاد می‌شود که در مطالعات آینده، الگوریتمی مجزا برای تحلیل تصاویر دوربین دید در شب توسعه یابد. در شکل ۲۵ نمونه‌هایی از تصاویر مجموعه داده آزمایش در شرایط جوی مختلف مشاهده می‌شود. در نهایت، الگوریتم تشخیص مانع بر روی این ۱۶۶۴ تصویر با دقت (Accuracy) بیش از ۸۷ درصد قادر بود موانع را در مسیر حرکت قطار شناسایی کند. همچنین دقت الگوریتم تشخیص سوزن (Accuracy) نزدیک به ۹۹ درصد محاسبه شد. زمان اجرا در شرایط مختلف و با توجه به شرایطی مثل وجود یا عدم وجود سوزن در تصویر و تعداد سوزن‌ها از حدود ۲ تا ۵ ثانیه متغیر است.

از میان سایر نواحی ریل جدا شود و ریل‌های اضافی حذف گردد، از این‌رو در این مطالعه یک الگوریتم شناسایی مسیر حرکت قطار پیشنهاد شد. روش کلی شناسایی ریل اصلی در الگوریتم پیشنهادی به این صورت است که در اکثر تصاویر که ریل‌ها کاملاً از هم مجزا هستند، وسط‌ترین مؤلفه، در پیش‌بینی UNet به‌عنوان ریل مسیر حرکت قطار انتخاب می‌شود. اما همان‌طور که مشاهده شد، شناسایی ریل اصلی همیشه به این سادگی نیست و در بعضی از تصاویر با چالش‌هایی مواجه هستیم که در ادامه به بررسی دو نمونه مهم و پرتکرار این چالش‌ها و ارائه راه‌حل برای آن‌ها پرداخته شد. مهم‌ترین چالش موضوع موردنظر، مسیریابی قطار در نواحی جلوی سوزن که ریل به دوشاخه تبدیل می‌شود، است. از این‌رو سعی شد الگوریتم مناسبی برای مسیریابی در این نواحی پیشنهاد شود. در نهایت پس از شناسایی مسیر حرکت قطار، در مرحله سوم اشتراک میان خروجی مرحله اول و مسیر حرکت قطار محاسبه شد و در صورت وجود اشتراک، مانع در مسیر وجود داشت و در غیر این صورت مسیر ایمن در نظر گرفته شد. به دلیل محدودیت شرایط راه‌آهن، امکان آزمایش در محیط واقعی وجود نداشت، اما مجموعه داده آزمایش شامل حدود ۱۶۰۰ تصویر از صحنه‌های راه‌آهن بود، که تعدادی از تصاویر آن موانع واقعی و طبیعی داشتند. پس از شبیه‌سازی کامل الگوریتم تشخیص مانع در راه‌آهن، این الگوریتم و همچنین الگوریتم تشخیص سوزن، مورد آزمایش قرار گرفتند. تصاویر آزمایش شامل ۱۶۶۴ تصویر با



شکل ۲۵. نمونه‌هایی از تصاویر شرایط جوی مختلف در مجموعه داده آزمایش

## ۶. پیشنهادات

پیشنهادات آینده این تحقیق در ۵ مورد خلاصه می‌شود:

(۱) بررسی دقیق موارد خطای الگوریتم تشخیص مانع و ارائه پیشنهاد برای کاهش موارد خطا (تعدادی از موارد خطا در بخش تحلیل نتایج مورد بررسی قرار گرفت).

(۲) تهیه و جمع‌آوری مجموعه داده مناسب برای مرحله تشخیص اشیاء

بزرگ‌ترین محدودیت این تحقیق، عدم وجود مجموعه‌داده مانع‌دار با تعداد زیادی تصویر و کلاس‌های متنوع است. با توجه به محدودیت‌های موجود در راه‌آهن، امکان جمع‌آوری چنین مجموعه‌داده‌ای فراهم نیست. این مجموعه‌داده باید شامل کلاس‌های متنوعی از موانع باشد تا الگوریتم تشخیص مانع بتواند به‌طور کامل و مؤثر عمل کند. در این پژوهش، به دلیل عدم امکان جمع‌آوری مجموعه‌داده مانع‌دار با تعداد تصاویر زیاد و کلاس‌های متنوع، از شبکه YOLO پیش‌آمورخته روی مجموعه داده COCO استفاده شد. برای جلوگیری از بیش‌برازش شبکه روی مجموعه‌داده راه‌آهن و حفظ تنوع کلاس‌ها، تنظیم دقیق وزن‌ها روی مجموعه‌داده راه‌آهن انجام نشد. در نتیجه، الگوریتم پیشنهادی توانایی تشخیص ۸۰ کلاس از موانع را دارد. با این حال، افزایش تعداد کلاس‌ها همچنان ضروری به نظر می‌رسد. از این رو، می‌توان با جمع‌آوری مجموعه‌داده‌ای با کلاس‌های متنوع‌تر و تعداد تصاویر بیشتر، عملکرد الگوریتم را بهبود بخشید.

(۳) استفاده از مجموعه داده جمع‌آوری شده توسط دوربین دید در شب

(۴) شناسایی مسیر حرکت قطار در نواحی پشت سوزن

در این مطالعه الگوریتم مناسبی برای شناسایی مسیر حرکت در نواحی جلوی سوزن، پیشنهاد شد. شناسایی مسیر حرکت قطار در نواحی پشت سوزن نیز با روشی مشابه امکان پذیر است.

(۵) استفاده از ویدیو به جای تصویر

محدودیت دیگر در این مطالعه استفاده از مجموعه‌داده تصویری است. به دلیل عدم استفاده از ویدیو، در بعضی از تصاویر که در آن‌ها ابتدای سوزن قابل مشاهده نیست، جهت زبانه سوزن مشخص نیست و در نتیجه امکان مسیریابی در این شرایط وجود ندارد. در صورت استفاده از ویدیو، مسیریابی در اولین فریمی که جهت زبانه سوزن در آن مشخص است، انجام می‌گیرد و در فریم‌های بعدی نیز اعمال می‌گردد.

## ۷. پی‌نوشت‌ها

1. Feature map
2. Feature Fusion
3. Bounding boxe
4. confidence
5. attention mechanisms
6. Real Time
7. Convolutional Neural Network
8. Encoder-Decoder

## ۸. مراجع

– سندیدزاده، م.، & کولانیان، س. (۱۴۰۲). فصلنامه مهندسی حمل و نقل. نظارت تصویری بر موانع حمل‌ونقل ریلی با استفاده از روش‌های مبتنی بر یادگیری عمیق.

– Zhang, Q., Yan, F., Song, W., Wang, R., & Li, G. (2023). Automatic Obstacle Detection Method for the Train Based on Deep Learning. Sustainability, 1-14.

– Badrinarayanan, V., Handa, A., & Cipolla, R. (2015). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling. Computer Vision and Pattern Recognition, 1-10.

– Belyaev, S., Popov, I., Shubnikov, V., Popov, P., Boltenkova, E., & Savchuk, D. (2020). Railroad semantic segmentation on high-resolution images. IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC).

transmission system for improving safety at level crossings. 2015 International Carnahan Conference on Security Technology (ICCST), 363-367, Taipei, Taiwan.

– Karakose, M., Akın, E., & Tastimur, C. (2013). Image Processing Based Level Crossing Detection and Foreign Objects Recognition Approach in Railways,. International Journal of Applied Mathematics, Electronics and Computers, 1, 19-23.

– LI, Y., DONG, H., LI, H., ZHANG, X., Zhang, B., & XIAO, Z. (2020). Multi-block SSD based on small object detection for UAV railway scene surveillance. Chinese Journal of Aeronautics, 33(6), 1747-1755.

– Meng, C., Wang, Z., Shi, L., Gao, Y., Tao, Y., & Wei, L. (2023). SDRC-YOLO: A Novel Foreign Object Intrusion Detection Algorithm in Railway Scenarios. journal of Electronics, , 1-16.

– Nakason, R., Nagamine, N., Ukai, M., & Mukojima, H. (2017). Frontal Obstacle Detection Using Background Subtraction and Frame Registration. Quarterly Report of RTRI.

– Qi, S., & Yu, D. (2021). Railway obstacle detection based on radar and image data fusion. Journal of Physics: Conference Series, 1-8.

– Qi, Z., Ma, D., Xu, J., Xiang, A., & Qu, H. (2024). Improved YOLOv5 Based on Attention Mechanism and FasterNet for Foreign Object Detection on Railway and Airway tracks," Computer Vision and Pattern Recognition. Computer Vision and Pattern Recognition, 1-5.

– Rahman, F. U., Ahmed, M., Hasan, M., & Jahan, N. (2022). Real-Time Obstacle Detection Over Railway Track using Deep

– Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., & Benenson, R. (2016). The Cityscapes Dataset for Semantic Urban Scene Understanding. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 3213-3223.

– Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition, 248-255, Miami, FL, USA.

– Dent, M., & Marinov, M. (2019). Introducing Automated Obstacle Detection to British Level Crossings. Springer International Publishing, 37-80.

– Drizi, H. K., & Boukadoum, M. (2024). CNN Model with Transfer learning and Data Augmentation for Obstacle Detection in Rail Systems. 2024 IEEE International Symposium on Circuits and Systems (ISCAS), 1-5, Singapore.

– Guan, L., Jia, L., Xie, Z., & Yin, C. (2022). A Lightweight Framework for Obstacle Detection in the Railway Image Based on Fast Region Proposal and Improved YOLO-Tiny Network. IEEE Access, 1-16.

– He, D., Zou, Z., Chen, Y., Liu, B., & Miao, J. (2021). Rail Transit Obstacle Detection Based on Improved CNN. IEEE Transactions on Instrumentation and Measurement, 1-14.

– He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778. Las Vegas, NV, USA.

– Hsieh, H.-H., Hsu, C.-Y., Ke, P.-Y., Liu, G.-S., & Lin, C.-P. (2015). Applying Lidar-based obstacle detection and wireless image

- Yao, Z., He, D., Chen, Y., Liu, B., Miao, J., & Deng, J. (2020). Inspection of exterior substance on high-speed train bottom based on improved deep learning method. *Journal of the International Measurement Confederation*, 1-12.
- Zendel, O., Murschitz, M., Zeilinger, M., Steininger, D., Abbasi, S., & Beleznai, C. (2019). RailSem19: A Dataset for Semantic Rail Scene Understanding. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1221-1229.
- Zhao, Z., Kang, J., Sun, Z., Ye, T., & Wu, B. (2024). real-time and high-accuracy railway obstacle detection method using lightweight CNN and improved transformer. *Journal of the International Measurement Confederation*, 238, 1-16.
- Ristic-Durrant, D., Haseeb, M. A., Franke, M., Banic, M. S., Simonovic, M., & Stamenković, D. (2020). Artificial Intelligence for Obstacle Detection in Railways: Project SMART and Beyond. *Dependable Computing - EDCC 2020 Workshops*, 44-55.
- S, A. (2019). Image Processing based Real Time Obstacle Detection and Alert System for Trains. *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, 740-745, Coimbatore, India.
- Sevi, M., & Aydın, İ. (2023). Detection of Foreign Objects Around the Railway Line with YOLOv8. *Journal of Computer Science*, 19-23.
- Wang, C.-Y., Bochkovski, A., & Liao, H.-Y. M. (2022). Yolov7: Trainable bag-of-freebies sets new state-of-the art for real-time object detectors. *Conference on Computer Vision and Pattern Recognition (CVPR)*, 7464-7475.
- Wang, Y., Wang, L., Hu, Y., & Qiu, J. (2019). RailNet: A Segmentation Network for Railroad Detection. *IEEE Access*, 143772-143779.
- Wang, Z., Wu, X., Yu, G., & Li, M. (2018). Efficient Rail Area Detection Using Convolutional Neural Network. *IEEE Access*, 6, 77655-77664.
- Xu, Y., Gao, C., Yuan, L., Tang, S., Wei, G., & Wei, G. (2019). Real-time Obstacle Detection Over Rails Using Deep Convolutional Neural Network. *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, 1007-1012, Auckland, New Zealand.

## شناسایی مسیر حرکت قطار برای تشخیص مانع در راه آهن با استفاده از یادگیری عمیق

فاطمه خزاعی، درجه کارشناسی مهندسی برق را در سال ۱۴۰۰ از دانشگاه شاهد و درجه کارشناسی ارشد برق را در سال ۱۴۰۳ از دانشگاه علم و صنعت اخذ نمود. در حال حاضر در حوزه هوش مصنوعی مشغول به پژوهش و فعالیت علمی است. زمینه‌های مورد علاقه ایشان، هوش مصنوعی، بینایی ماشین و یادگیری ماشین است.

محمدرضا محمدی کارشناسی و کارشناسی ارشد مهندسی برق را به ترتیب در سال‌های ۱۳۸۸ و ۱۳۹۰ از دانشگاه صنعتی امیرکبیر و مدرک دکتری را در سال ۱۳۹۴ از دانشگاه صنعتی شریف اخذ نمود. زمینه پژوهشی مورد علاقه ایشان، هوش مصنوعی، بینایی ماشین و یادگیری ماشین است. ایشان در حال حاضر عضو هیئت علمی گروه هوش مصنوعی دانشکده مهندسی کامپیوتر دانشگاه علم و صنعت ایران است.

حسین بلندی، درجه کارشناسی را در سال ۱۹۸۴ از دانشگاه ایالتی نورکفوک آمریکا و درجه کارشناسی ارشد و دکتری را به ترتیب در سال‌های ۱۹۸۶ و ۱۹۹۰ از دانشگاه جورج واشنگتن آمریکا اخذ نمود. زمینه‌های تحقیقاتی ایشان، طراحی سیستمی و ساخت ماهواره، طراحی و ساخت زیر سیستم تعیین و کنترل وضعیت ماهواره، اتوماسیون و رباتیک است. ایشان در حال حاضر عضو هیئت علمی گروه کنترل دانشکده مهندسی برق دانشگاه علم و صنعت ایران است.