

# پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهپادی

محمد صفایی، کارشناسی ارشد، دانشکده مهندسی عمران، پردیس دانشکدگان فنی، دانشگاه تهران، ایران

مهدی صمدزاد (مسئول مکاتبات)، استادیار، دانشکده مهندسی عمران، پردیس دانشکدگان فنی، دانشگاه تهران، ایران

**E-mail: msamadzad@ut.ac.ir**

مرتضی باقری، دانشیار، عضو هیأت علمی دانشکده مهندسی راه‌آهن، دانشگاه علم و صنعت ایران، ایران

پذیرش: ۱۴۰۱/۰۳/۳۰

دریافت: ۱۴۰۰/۱۱/۰۴

## چکیده

خطوط ریلی در مناطق بیابانی با مشکلی جدی هجوم ماسه‌های بادی و انباشت آن‌ها بر روی ریل‌ها روبرو است. در اثر این پدیده، احتمال بسته شدن خطوط آهن، توقف حرکت قطارها و وقوع حادثه وجود دارد. در حال حاضر تلاش می‌شود تا با بازدیدهای میدانی در مناطق در معرض هجوم ماسه‌های بادی، از بروز این مشکل جلوگیری شود اما روش‌های سنتی با وجود ساده بودن دارای محدودیت‌هایی است که مهم‌ترین آنها هزینه مالی و زمانی بالای آن‌ها است. از این رو نیاز به بازنگری در روش‌های سنتی پایش در این مناطق به شدت احساس می‌شود. در این پژوهش با بکارگیری فناوری تصویربرداری پهپادی و پردازش هوشمند تصویر مبتنی بر شبکه‌های عصبی همگشتی و یادگیری عمیق یک سامانه جامع پایش طراحی شده است. استفاده از پهپادها و عمودپروازها در مدیریت و تعمیر و نگهداری و تعمیرات فراسازه‌های ترابری می‌تواند گام مهمی در بالا بردن دقت و سرعت و البته کاهش هزینه‌ها باشد. به این ترتیب پایش سامانه ریلی به جای آنکه تنها محدود به بازه‌های زمانی بازدید میدانی باشد، به صورت پیوسته زیر نظر است. در این تحقیق از شبکه عصبی یولو با هدف تشخیص هجوم ماسه‌های بادی بر شبکه ریلی در تصاویر پهپادی استفاده شده است. در نهایت با آموزش شبکه، دقت شبکه در تشخیص هجوم ماسه بر سطح ریل ۹۱ درصد بدست آمده است.

واژه‌های کلیدی: پردازش تصویر، شبکه ریلی، شبکه عصبی همگشتی، هجوم ماسه بادی

## ۱. مقدمه

ناشی از آن مورد بررسی قرار نگرفته است. در حال حاضر راهکار یکتایی برای حل مسئله هجوم ماسه‌ها وجود ندارد از این رو از روش‌های گوناگون برای کاهش خسارت این بحران استفاده می‌شود که به دلیل هزینه بالایی که دارند هر یک که بازدهی بیشتری داشته باشد برای ادامه مسیر پیشنهاد می‌شود. می‌توان گفت که تفاوت‌های اقلیمی عامل اصلی ناتوانی در پیشنهاد یک راهکار جامع و مشترک در حل این بحران است. مسئله ماسه‌های بادی از سه دیدگاه بررسی می‌شود. نخست از دیدگاه مهندسی، دوم از نظر محیط‌زیستی و سوم از دیدگاه فیزیک ماسه‌های بادی [Bruno et al, 2018]. در حوزه ترابری از دیدگاه مهندسی به ارزیابی این مسئله پرداخته می‌شود.

در ایران ۵۳۵ کیلومتر از شبکه ریلی، تحت تاثیر هجوم ماسه‌های بادی قرار دارد [Samadi Pakdel, 2019]. علاوه بر کشور ایران، کشورهایی مانند: آمریکا، هند و چین نیز دچار معضل هجوم ماسه‌های بادی در مناطق بیابانی‌اند. در هند حدود ۱۲۵۰ کیلومتر از شبکه ریلی در مسیر ماسه‌های بادی قرار دارد که هر ساله حوادثی از قبیل خارج شدن قطار از ریل و اختلال در سرویس‌دهی در آن رخ می‌دهد. علاوه بر این مسائل، حدود ۱۴۸۰ کارگر در سال، در بازه‌های مختلف زمانی به کار گرفته می‌شوند تا خطوط ریلی را از این ماسه‌ها پاکسازی نمایند [Zakeri and Forghani, 2012]. نزدیک به ۱۰ هزار کیلومتر از خط آهن چین که بیشتر در شمال غرب این کشور قرار دارد درگیر مسئله ماسه‌های بادی است که بالاترین میزان نسبت به دیگر کشورهای جهان را دارد. در طی ۱۵ سال گذشته تلاش زیادی برای کاهش گستردگی این بحران صورت گرفته است. با این حال همچنان چین با خسارت‌های ناشی از مسئله، روبرو است [Cheng et al., 2015]. راهکارهای مختلفی در جهت بهبود انباشت ماسه‌های بادی صورت گرفته‌است اما با توجه به شرایط محیطی متفاوت در مناطق مختلف، راه‌حلی جامع و مشترک برای انباشت ماسه‌های بادی یافت نشده است


احداث زیرساخت‌های ترابری در ابعاد یک کشور بسیار گران است. بر اساس برآوردهای موجود هزینه احداث زیرساخت‌های جدید حمل‌ونقل تا سال ۲۰۳۰ در کشورهای با درآمد کم و متوسط سالانه بین ۰,۵ تا ۳,۳ درصد از تولید ناخالص داخلی (GDP) می‌باشد که مبلغی بین ۱۵۷ میلیارد دلار تا ۱ تریلیون دلار است. همچنین بسته به کارایی شبکه میزان ۱ تا ۲ درصد از تولید ناخالص داخلی (GDP) صرف نگهداری زیرساخت‌های ترابری می‌گردد. از این رو است که کاهش هزینه‌های جاری مدیریت، نگهداری و تعمیرات زیرساخت‌های ترابری، دارای اهمیت است؛ علاوه بر این با تعمیر به موقع زیرساخت‌ها می‌توان اطمینان پیدا کرد که در هر لحظه از ۱۰۰ درصد ظرفیت مجموعه بهره‌برداری می‌شود [Rozenberg et al, 2019].

سامانه ریلی به ویژه در مناطق بیابانی و کویری با مشکل انباشت ماسه‌های بادی بر روی ریل‌ها روبرو است با دفن شدن ریل زیر ماسه‌ها، عملاً آن بخش از سامانه از رده خارج می‌شود و هر انتقالی تا تعمیر بخش آسیب‌دیده با تاخیر روبرو می‌شود. روش سنتی بررسی خطوط ریلی بازدید میدانی است که به دلیل بیابانی و یا صعب‌العبور بودن مناطق پرخطر، دسترسی به نقاط حساس می‌تواند با دشواری‌هایی همراه باشد.

هجوم ماسه‌های بادی به شبکه ریلی می‌تواند باعث کندی حرکت قطارها و یا توقف کامل آن‌ها شود که در صورت نبود مسیر جایگزین، بخشی از سامانه ریلی به کلی مسدود می‌شود. علاوه بر این با ورود ماسه‌های بادی به سامانه تهویه هوای قطارهای مسافری، مسافران دچار مشکلات تنفسی خواهند شد که برای افراد با شرایط خاص، این مسئله می‌تواند با خطر جانی همراه باشد. با وجود آنکه هجوم و انباشت ماسه‌ها بر روی ریل‌ها می‌تواند ایمنی و خدمت‌رسانی سامانه ریلی را به خطر اندازد با این حال این مسئله کمتر مورد توجه قرار گرفته است و استفاده از روش‌های هوشمند پردازش تصویر برای کاهش خسارت‌های

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهبادی

کامل حل نکرده‌اند و تنها در کاهش شدت و میزان آن موثر بوده‌اند [Samadi Pakdel, 2018].



شکل ۲. درصد طول مسیر ماسه‌گیر شبکه ریلی مناطق مختلف

ایران [Samadi Pakdel, 2018]

مطابق با شکل ۲ بیشترین میزان هجوم ماسه‌های بادی و شن‌های روان به شبکه ریلی در جنوب شرق کشور دیده می‌شود. برای مثال می‌توان از راه‌آهن زاهدان-بیم در منطقه شورگزر نام برد. طی مصاحبه صورت گرفته با مدیرکل وقت راه آهن کرمان، جناب مهندس ارجونی فاصله شهر نصرت-آباد تا فهرج در خط آهن زاهدان-کرمان، ۷۰ کیلومتر است که ۲۰ کیلومتر از آن، حد فاصل شورگزر تا رودشور در وضعیت بحرانی قرار دارد. همچنین بر اساس مصاحبه صورت گرفته با کارشناس خط ریلی زاهدان-بیم جناب مهندس احسانی، هجوم ماسه‌های بادی در این مسیر باعث شده است تا سرعت ایده‌آل قطار از ۱۲۰ به ۷۰ کیلومتر در ساعت کاهش یابد و زمان طی مسیر تا تهران از ۱۷ ساعت به ۲۳ ساعت افزایش یابد. طی اطلاعات بدست آمده از مصاحبه با کارشناس خط ریلی مورد نظر در شکل ۳ و شکل ۴ موقعیت محور بحرانی رودشور-شورگزر نشان داده شده است. این محور در محدوده حوزه استحفاظی استان کرمان و سیستان و بلوچستان قرار دارد و در هنگام هوای طوفانی در محاصره و هجوم ماسه‌های بادی قرار می‌گیرد. در شکل ۵ نمونه‌ای از هجوم ماسه‌های بادی در این محور نشان داده شده است.

[Bruno et al, 2018]. شکل ۱ نمونه‌ای از هجوم ماسه‌های

بادی در ایران را نشان می‌دهد.



شکل ۱. نمونه‌ای از هجوم ماسه‌های بادی به شبکه ریلی (ایران،

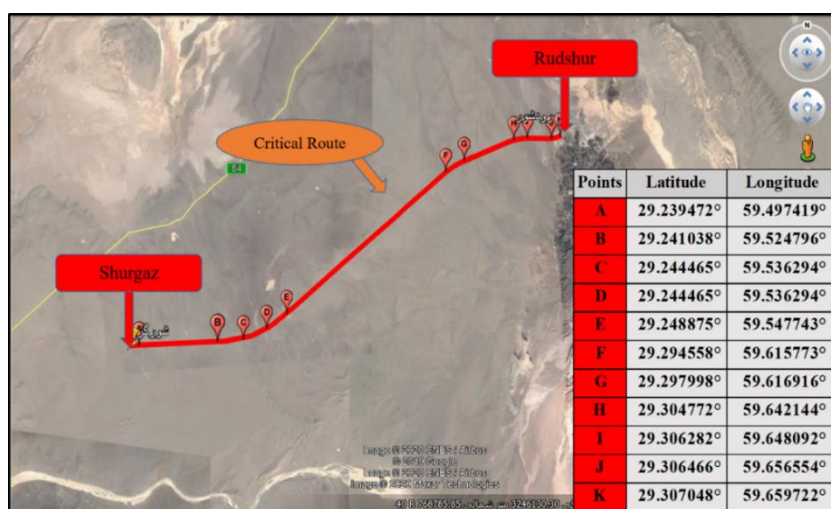
شورگزر)

### ۱-۱ هجوم ماسه‌های بادی در شبکه ریلی ایران

از آنجایی که ۸۰ درصد از ایران آب و هوای خشک و نیمه‌خشک دارد و ۲۰ درصد از خاک کشور را مناطق بیابانی تشکیل می‌دهد، انتظار می‌رود که بخش قابل توجهی از سامانه ریلی به دلیل جایگیری در مناطق بیابانی با خطر هجوم ماسه‌های بادی روبرو باشد. شبکه‌های ریلی جنوب شرق، جنوب، هرمزگان، شمال شرق، شرق، تهران و اصفهان از جمله بخش‌های درگیر با بحران هجوم ماسه‌های بادی است که نزدیک به ۵۳۵ کیلومتر از سامانه خطوط ریلی کشور را پوشش می‌دهد. در شکل ۲، درصد هر یک از مناطق ماسه‌گیر کشور نسبت به کل ۵۳۵ کیلومتر بخش مستعد هجوم ماسه‌های بادی نشان داده شده است. در ایران دو برنامه سنتی و نوین جهت حل معضل هجوم ماسه‌های بادی در حال اجرا است. از جمله برنامه‌های سنتی می‌توان به نهال‌کاری، حفر خندق، مالچ پاشی اشاره نمود و از جمله روش‌های نوین می‌توان به تراورس‌های کوهان‌دار اشاره کرد. هیچ یک از روش‌های مورد نظر تا به اکنون معضل ماسه‌های بادی را به طور



شکل ۳. محور بحرانی شورگز-رودشور، حدفاصل زاهدان-فهرج



شکل ۴. نمای نزدیک تر محور بحرانی شورگز-رود شور، حدفاصل زاهدان-فهرج



شکل ۵. نمونه‌ای از هجوم ماسه‌های بادی (ایران، شورگز)

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهپادی



شکل ۷. گروهی از کارگران، مشغول پاکسازی مسیر (رودشور-

شورگز



شکل ۸. پاکسازی مسیر (رودشور- شورگز)

شبکه راه‌آهن استان سیستان و بلوچستان ارتباط دهنده اصلی قطارهای بین‌المللی به داخل شبکه ریلی کشور است. همچنین راه‌آهن جنوب شرق با داشتن دو نوع خط عریض و استاندارد به سامانه ریلی کشور پاکستان متصل است و در مسیر بین‌المللی شرق به غرب جهان و اتصال آسیای مرکزی، پاکستان و شبه قاره هند به ترکیه و اروپا جای دارد از این رو دارای اهمیت بین‌المللی هم هست. با توجه به طرح‌های پیش‌رو جهت توسعه شبکه بین‌المللی ریلی، با ساخت خطوط ریلی مشهد-بافق - بندرعباس و زاهدان-بم - کرمان زمینه و ایجاد مسیرهای بین‌المللی انتقال کالا از طریق راه‌آهن و اتصال کشورهای آسیای مرکزی، دریای سیاه، قفقاز و اتحادیه اروپا با شبه قاره هند، خاور دور و

به دلیل مسافت زیاد سفر با خودروی شخصی از زاهدان تا مرکز کشور و هزینه بالای مسافرت هوایی استقبال مسافران از سفر با قطار در محور ریلی قطار زاهدان-تهران افزایش یافته است. طی گفتگو و مصاحبه صورت گرفته با جناب مهندس احسانی (کارشناس خط محدوده رودشور-شورگز) راهکارهایی برای حل معضل هجوم ماسه‌های بادی به شبکه ریلی ارائه شده است و در حال اجرا هستند. به دلیل هزینه‌ی بالای این راهکارها، هر یک از این روش‌ها در بخشی از مسیر اجرا شده‌اند تا چنانچه اثربخش بود ادامه مسیر را پوشش دهند. متأسفانه این روش‌ها در کوتاه مدت موثر بوده‌اند و بعد از مدتی دوباره با مشکل مواجه شده‌اند و هنوز راهکاری که بتواند به صورت دائمی این مشکل را حل کند ارائه نشده است. بر اساس مصاحبه با کارشناسان خط مورد مطالعه، سالانه حدود ۲۵۰ نفر در سه گروه علاوه بر تلاش برای مهار ماسه‌ها و شن‌های روان، مسائل مربوط به حفاظت و نگهداری از خطوط ریلی این محور را بر عهده دارند. این امر علاوه بر درجه سختی کار بسیار بالا، هزینه‌ی بالایی را در برمی‌گیرد. در شکل ۶، شکل ۷ و شکل ۸ نمونه‌هایی از عملیات پاکسازی شبکه ریلی مسدود شده توسط ماسه‌های بادی مشاهده می‌شود.



شکل ۶. گروهی از کارگران، مشغول پاکسازی مسیر (رودشور-

شورگز)



همکاران با در نظر گرفتن شرایط اقلیمی خاص مانند محیط مه‌آلود، تلاش کرد با اضافه نمودن ویژگی‌هایی به فرایند پردازش تصویر، تشخیص خرابی در این شرایط را ممکن سازد [Wu et al., 2019]. در این میان استفاده از روش‌های هوشمند و خودکار حائز اهمیت خواهد بود.

## ۲-۱ کاربرد پهپاد در پایش تصویری

زیرساخت‌های عمرانی با صرف هزینه‌های هنگفت توسعه می‌یابند و شریان‌های حیاتی کشور را تشکیل می‌دهند. از این رو تداوم عملکرد مناسب این زیرساخت‌ها از طریق پایش و مدیریت تعمیر و نگهداری دارای اهمیت بسیار است. بررسی و بازدید از زیرساخت‌ها به صورت سنتی و با به کارگیری تعدادی نیروی کارشناس باعث افزایش هزینه نگهداری و مدیریت این زیرساخت‌ها می‌گردد. امروزه همزمان با سایر صنایع استفاده از پهپادها در جهت کاهش هزینه نگهداری و مدیریت زیرساخت‌های عمرانی مورد توجه قرار گرفته است. به عنوان نمونه، حادثه طوفان مورا کوت که در سال ۲۰۰۹ در کشور تایوان رخ داد منجر به کشته شدن ۶۱ نفر شد و پل‌های بسیاری در این طوفان تخریب شدند. دلیل خرابی بسیاری از پل‌ها در این طوفان، وجود ترک در قستی از پل‌ها بیان شده بود که دسترسی به آن و بازدید از آن برای بازرسان دشوار بوده است. به این ترتیب این حادثه زمینه‌ساز استفاده از پهپادها برای جلوگیری از وقوع موارد مشابه شد [Chen et al. 2017]. همچنین علاوه بر شناسایی ترک‌های پل [Rau et al. 2017] از پهپادها در عکسبرداری هوایی برای پایش وضعیت محصولات زراعی [Perez-Ortiz et al. 2016]، بازرسی سطح تیغه‌های توربین‌های بادی [Wang and Zhang. 2017]، بازرسی خطوط نیروگاه‌های برق [Deng et al. 2014]، بازرسی‌های مربوط به تشخیص آتش‌سوزی در جنگل [Yuan et al. 2015] استفاده شده است. البته استفاده از پهپاد برای نظارت و پایش تصویری دارای محدودیت‌هایی نیز می‌باشد که از جمله آن‌ها می‌توان به عدم امکان پرواز در شرایط آب و هوایی نامساعد

کشورهای جنوب شرقی آسیا فراهم خواهد شد. با توجه به اهمیت بین‌المللی خطوط ریلی و لزوم بهره‌برداری صد درصدی از ظرفیت آن و اطمینان از ایمنی و به موقع رسیدن قطارها، مسئله پایش خطوط ریلی در راستای کاهش هزینه ناشی از آسیب‌های هجوم ماسه‌های بادی اهمیتی دو چندان می‌یابد. در این مقاله به بررسی کاربرد تصویربرداری پهپادی و پردازش تصویر در پایش خطوط ریلی پرداخته می‌شود و نتایج آن با روش‌های سنتی پایش که از گذشته تا امروز کاربرد داشته مقایسه می‌گردد.

## ۲. پیشینه تحقیق

در بررسی‌ها و مطالعات صورت گرفته، برای کاهش خطرات عوامل محیطی از اتوماسیون و روش‌های هوشمند استفاده شده است. به عنوان مثال یکی از این عوامل محیطی خطرآفرین، وجود بست‌های اتصال ریلی است. شکست یا عدم اتصال مناسب یا ایجاد هرگونه خرابی در بست‌های ریلی، ممکن است باعث خارج شدن قطار از ریل و واژگونی آن شود. از این رو بست‌ها باید به صورت منظم و پیوسته توسط نیروی متخصص بازمی‌نویس شود و این کار به دلیل نیاز به نیروی انسانی متخصص هزینه بالایی را در برمی‌گیرد. از این رو مونتر و همکاران در سال ۲۰۱۵ روشی برای بازدید و بررسی بست‌ها با استفاده از ربات را توسعه دادند که کاربرد آن به‌ویژه در تونل‌های راه‌آهن که شرایط بازدید در آن‌ها برای متخصصین و کارگران دشوار است بسیار اثربخش بوده است [Montero et al., 2015]. در ادامه ماکانتاسیس<sup>۲</sup> و همکاران در سال ۲۰۱۵ به صورت اختصاصی بر روی ساده‌سازی و بهبود روش‌های بازمی‌نویس مسیرهای تونلی راه‌آهن کار کردند. ایشان برای این منظور از پردازش تصویر بهره بردند [Makantasis et al., 2015].

امروزه پهپادها به دلیل بازدهی بالا و هزینه نسبی پایین نقش مهمی در بازرسی از خطوط ریلی دارند [Wu et al., 2018]. وی<sup>۳</sup> در سال ۲۰۱۹ در جهت کامل نمودن تحقیقات قبلی و در جهت بهتر نمودن شرایط تشخیص، از شبکه عصبی همگشتی<sup>۴</sup> (CNN) استفاده نمود [Wei et al., 2019]. در ادامه وو<sup>۵</sup> و

[Zhang et al., 2019] <sup>۶</sup>R-FCN ، [Cui et al., 2021] و [Shuai & Wu, 2020] <sup>۸</sup>SSD است. متناسب با شرایط و ویژگی‌های شیء، از نظر موقعیت و اندازه آن، می‌توان از هر یک از این سیستم‌ها استفاده نمود. با توجه به ویژگی‌های مدنظر این طرح، در جهت شناسایی ماسه و ریل، سیستم یولو (YOLO) به دلیل سرعت بسیار بالا نسبت به سایر سیستم‌های بیان شده، انتخاب می‌گردد و در این پژوهش مورد استفاده قرار می‌گیرد. در همین راستا برای آموزش شبکه و تشخیص وجود ماسه‌های بادی بر روی مسیر ریلی، نیاز به گردآوری تصاویر و فیلم‌هایی از شیء مورد نظر است. در محدوده اطلاع این نویسندگان تا کنون مطالعاتی بر روی تشخیص هجوم ماسه‌های بادی با استفاده از پهپاد و شبکه‌های عصبی صورت نگرفته است. در این تحقیق سعی بر آن است تا با به کارگیری شبکه یولو در کنار تصاویر پهپادی به تشخیص هجوم ماسه‌های بادی پرداخته شود. از این رو با به کارگیری شبکه‌های عصبی عمیق و تصاویر پهپادی با هدف تشخیص هجوم ماسه‌های بادی می‌توان در زمان مناسب و دقت بالاتر مانع از وقوع حوادث گشت. الگوریتم‌های یادگیری عمیق زیرمجموعه‌ای از حوزه یادگیری ماشین‌اند و این دو جزئی از دامنه هوش مصنوعی می‌باشند.

### ۳-۱ به کارگیری الگوریتم تشخیص اشیاء<sup>۹</sup>

تشخیص اشیاء عبارت است از الگوریتمی در پردازش تصویر که از آن برای پیدا کردن اشیاء در هر تصویر استفاده می‌شود. گام نخست، برای آنکه هر الگوریتم بتواند شیء را در تصویر شناسایی کند نخست باید مدلی از آن شیء را به عنوان مدل مرجع، ایجاد کند. گام دوم، پس از ساخت مدل، الگوریتم شروع به جستجو در عکس می‌کند تا شیء را پیدا کند. پیدا شدن شیء به این معنی است که الگوریتم توانسته شیء را در تطابق با الگوریتم مرجع پیدا کند. مدل‌های تشخیص اشیاء پس از شناسایی اشیاء موجود در تصویر در گام بعدی آن‌ها را بر اساس گروه‌های مورد نظر و تعریف شده، طبقه‌بندی می‌کنند.


و محدودیت مدت زمان پرواز با توجه به محدودیت وزن باتری قابل حمل اشاره کرد [Fan and Saadeghvaziri, 2019]. پهپادهای مورد استفاده در پایش زیرساخت‌های عمرانی با توجه به طرح بال آن‌ها به سه دسته کلی شامل بال ثابت، بال گردان و ترکیبی تقسیم می‌شوند [Trubia and Curto, 2021]. پهپادهای بال ثابت با سرعت زیاد پرواز می‌کنند و از مداومت پروازی بالایی برخوردارند و در نتیجه برای پایش زیرساخت‌های خطی مانند جاده یا راه‌آهن مناسب می‌باشند. در مقابل پهپادهای بال گردان می‌توانند در یک نقطه متوقف شوند و به ارزیابی دقیق محلی بپردازند.

### ۳. روش تحقیق

تصویربرداری پهپادها به دلیل دقت و بازدهی بالا می‌تواند هزینه‌های حضور فیزیکی در محل برای بازرسی ریل‌ها در نقاط مستعد خرابی را کاهش دهد. امروزه کنترل تغییرات چشمگیر در محیط اطراف ریل‌ها با کمک بازرسی بصری مبتنی بر تصاویر هوایی به بخش مهمی در بازرسی خطوط ریلی تبدیل شده است [Wu et al., 2018]. اولین گام در جهت اجرا و پیاده‌سازی این طرح، بخش مربوط به فرایند پردازش تصویر است. با توجه به وجود تکنیک‌های مختلف پردازش تصویر، باید متناسب با نیاز طرح، روش مناسبی انتخاب شود. این طرح نیازمند استفاده از روشی است که بتواند شیء مورد نظر را شناسایی نماید. در واقع دو شیء مورد نظر، خط ریلی و ماسه‌های بادی موجود در محدوده مورد مطالعه هستند. استفاده از هوش مصنوعی و یادگیری عمیق در جهت شناسایی اشیاء، جزء به روزترین، دقیق‌ترین و سریع‌ترین روش‌های موجود است که در فرایند پردازش تصویر مورد استفاده قرار می‌گیرد. طی سال‌های اخیر یادگیری عمیق بصورت گسترده در حوزه بینایی کامپیوتر مورد مطالعه قرار گرفته است و به همین دلیل تعداد زیادی از روش‌های مرتبط با آن بوجود آمده است. چند سیستم پرکاربرد در پردازش تصویر مبتنی بر یادگیری عمیق شامل R-CNN [Mohammed et al., 2020] ، <sup>۶</sup>YOLO

### ۳-۱-۱ معیار تابع همپوشانی<sup>۱۰</sup>

سیستم‌های تشخیص شیء تصاویر مختلف را به دسته‌های مناسب آن‌ها تخصیص می‌دهند. تابع همپوشانی معیاری است که همپوشانی بین کادر تشخیص و کادر شیء را ارزیابی می‌کند. با استفاده از معیار تابع همپوشانی می‌توان تشخیص داد که تشخیص معتبر است. در واقع تعریف این معیار مطابق با شکل 9 است.



شکل 9. رابطه معیار همپوشانی

در فرایند شناسایی اشیاء به کمک معیار همپوشانی چهار حالت متفاوت می‌تواند اتفاق افتد که به قرار زیر است،

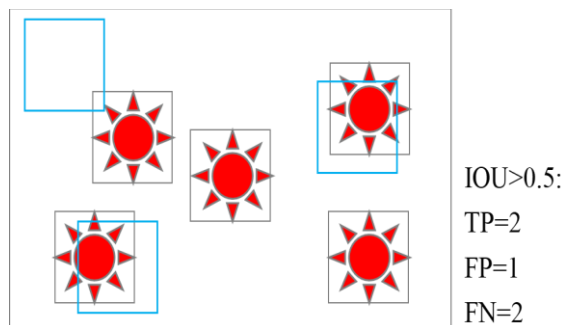
- مثبت صحیح<sup>۱۱</sup> (TP): بیانگر تعداد تشخیص‌هایی است که دسته واقعی آن‌ها مثبت است و مدل شبکه دسته آن‌ها را به درستی مثبت تشخیص داده است.

- مثبت کاذب<sup>۱۲</sup> (FP): بیانگر تعداد تشخیص‌هایی است که دسته واقعی آن‌ها منفی است و مدل شبکه دسته آن‌ها را به اشتباه مثبت تشخیص داده است.

- منفی کاذب<sup>۱۳</sup> (FN): بیانگر تعداد تشخیص‌هایی است که دسته واقعی آن‌ها مثبت است و مدل شبکه دسته آن‌ها را به اشتباه منفی تشخیص داده است.

- منفی صحیح<sup>۱۴</sup> (TN): بیانگر تعداد تشخیص‌هایی است که دسته واقعی آن‌ها منفی است و مدل شبکه دسته آن‌ها را به درستی منفی تشخیص داده است.

در هر شبکه، بسته به معیار انتخابی، مقدار آستانه همپوشانی می‌تواند برابر با ۵۰، ۷۵ یا ۹۵ درصد باشد. در شکل 10 به عنوان نمونه حالت‌های مختلف همپوشانی نشان داده شده است.



شکل 10. تعریف حالت‌های مختلف تشخیص شیء در تصویر

ورودی

### ۳-۱-۲ معیار دقت<sup>۱۵</sup>

معیار دقت عبارت است از توانایی یک مدل در شناسایی هر یک از اجسام مورد نظر. این معیار میزان درستی تشخیص صورت گرفته را نشان می‌دهد. معیار دقت از رابطه ۱ به دست می‌آید:

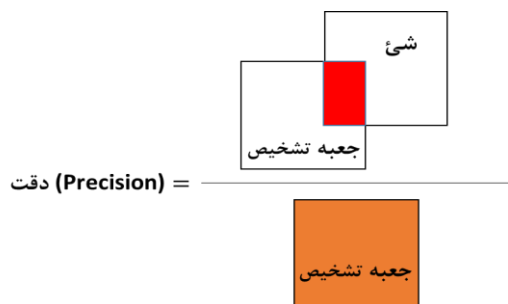
$$\text{Precision} = \frac{TP}{TP+FP} \quad (1)$$

معیار دقت = Precision

تعداد تشخیص کاملاً صحیح و درست = TP

تعداد تشخیص اشتباه شیء دیگر = FP

به عبارت دیگر معیار دقت برابر است با نسبت سطح همپوشانی کادر وجود شیء و کادر تشخیص شیء توسط شبکه به سطح کادر تشخیص شیء. تعریف معیار دقت به صورت نمادین در شکل 11 نشان داده شده است.



شکل 11. شکل و رابطه معیار دقت

### ۳-۱-۳ معیار فراخوانی<sup>۱۶</sup>



### ۳-۱-۵ معیار میانگین دقت متوسط<sup>۱۸</sup>

مهم‌ترین معیار در ارزیابی دقت روش‌های تشخیص اشیاء، معیار میانگین دقت متوسط است. میانگین دقت متوسط یا mAP با در نظر گرفتن میانگین AP در تمام کلاس‌ها و یا آستانه‌های کلی IOU، محاسبه می‌شود.

معمولاً، مدل‌های تشخیص شیء در آستانه‌های مختلف IOU ارزیابی می‌شوند که در آن هر آستانه می‌تواند پیش‌بینی متفاوتی از آستانه‌های دیگر داشته باشد.

برای مثال، اگر یک مدل با تصویری تغذیه شود که ۱۰ شیء در ۲ کلاس دارد؛ برای محاسبه mAP باید به ترتیب زیر عمل کرد، نخست باید AP برای هر کلاس را محاسبه کرد سپس باید با میانگین‌گیری از AP ها، مقدار mAP برای همه کلاس‌ها را به دست آورد. در این پژوهش برای تشخیص شیء از شبکه عصبی یولو استفاده شده است. در ادامه، این شبکه عصبی با جزئیات ارائه شده است.

### ۳-۲ طبقه‌بندی شبکه‌های عصبی و شبکه‌های عصبی

#### کانولوشنی

به صورت کلی وجه تمایز شبکه‌های عصبی در سه ویژگی قرار می‌گیرد:

۱. مدل‌های محاسباتی نرون (توابع فعالیت نرون): اطلاعات دریافتی توسط نرون‌ها از تابع فعالیت عبور می‌نماید که در نهایت منجر به قبول شدن یا رد شدن داده در آن شبکه می‌شود. توابع فعالیت مهم را می‌توان در چهار گروه نام برد: آستانه‌ای، خطی مقطع، هلالی و نرمال.


۲. قواعد یادگیری: داده‌هایی که به یک شبکه داده می‌شوند در دو دسته قرار می‌گیرند: داده‌های آموزشی و داده‌های آزمایشی. شبکه با استفاده از الگوهای آموزشی، داده‌های آموزشی را در جهت بالا بردن عملکرد مناسب مورد استفاده قرار می‌دهد و وزن‌های ارتباطی را بهنگام سازی می‌نماید. در واقع شبکه با الگوهای یادگیری وزن‌های ارتباطی را تعدیل می‌نماید.

معیار فراخوانی سنجشی از توانایی یک مدل در شناسایی همه جعبه‌های صحیح حقیقی است که به صورت زیر بیان می‌شود:

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

دقت اندازه‌گیری بیانگر آن است که هنگامی که مدل، اشیائی را شناسایی می‌کند، چه تعداد از تشخیص‌های صورت گرفته، درست است؛ اگر دقت آشکارساز شیء در یک کلاس، با افزایش شمار فراخوانی‌ها، کاهش نیابد در این صورت عملکرد خوبی از خود نشان داده است. در این حالت، با تغییر آستانه اطمینان، دقت و فراخوانی همچنان بالا می‌ماند. با کمک منحنی دقت در فراخوانی، می‌توان عملکرد آشکارساز شیء را ارزیابی کرد.

معیار فراخوانی برابر است با نسبت سطح همپوشانی جعبه وجود شیء و جعبه تشخیص شیء توسط شبکه به سطح جعبه شیء موجود. تعریف معیار فراخوانی به صورت نمادین در شکل 12 نشان داده شده است.



$$\text{فراخوانی (Recall)} = \frac{\text{Area of Detection Box overlapping with Object}}{\text{Area of Object}}$$



شکل ۱۲. شکل و رابطه معیار فراخوانی

با ترکیب معیار دقت و معیار فراخوانی می‌توان به جزئیات دقیق‌تری از شبکه دست یافت. ترکیب این دو معیار که با نماد  $F_1$  نشان داده شود از رابطه ۳ به دست می‌آید.

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

### ۳-۱-۴ معیار میانگین دقت<sup>۱۷</sup>

از آنجا که منحنی‌های میانگین دقت اغلب با تغییرات زیادی مواجه می‌شوند و بالا و پایین می‌روند از این رو مقایسه آشکارسازهای مختلف (منحنی‌های مختلف) معمولاً کار آسانی نیست به همین دلیل از معیار میانگین دقت استفاده می‌شود.

در این پژوهش شبکه یولو به کار گرفته شده است. در ادامه جزئیات بیشتری در رابطه با معماری شبکه یولو ارائه شده است.

### ۳-۳ شبکه عصبی یولو

در سال ۲۰۱۵، محقق جوزف ردمون<sup>۱۹</sup> و همکارانش الگوریتم یولو را برای تشخیص شیء معرفی کردند که تمام مراحل ضروری برای تشخیص یک شیء را با استفاده از یک شبکه عصبی برای اولین بار انجام می‌داد [Redmon et al., 2016].

طی ۵ سال، تا سال ۲۰۲۰ الگوریتم یولو به پنج نسخه (از جمله نسخه اصلی) ارتقا یافت. سه نسخه اول توسط نویسنده الگوریتم یولو، جوزف ردمون، تحقیق و توسعه یافته است. جوزف ردمون پس از انتشار نسخه یولو ۳ اعلام کرد که تحقیقات خود را در زمینه بینایی کامپیوتر متوقف کرده است.

در اوایل سال ۲۰۲۰، الکسی بوچوفسکی<sup>۲۰</sup> نسخه یولو ۴ را منتشر نمود [Bochkovski et al., 2020]. یک ماه پس از نسخه یولو ۴، محقق گلن جوچر<sup>۲۱</sup> و تیم تحقیقاتی او الگوریتم‌های یولو را بر روی چارچوب Pytorch ساختند، که نهایتاً نسخه یولو ۵ را با چند تفاوت و بهبود منتشر کردند. اگر چه نسخه یولو ۵ توسط تیم نویسنده اصلی توسعه نیافته است اما دارای عملکرد فوق‌العاده نسبت به نسخه‌های قبلی است.

سیستم عامل یولو به کمک شبکه کانولوشنی، اشیاء را شناسایی و طبقه‌بندی می‌کند [Radovi et al., 2017]. این شبکه نسبت به دیگر شبکه‌ها، سرعت بالاتری در شناسایی وسایل نقلیه دارد از این رو در صنعت حمل و نقل بسیار پرکاربرد است [Zhao et al., 2019] همچنین در مسیریابی خودروهای خودران و شناسایی عابران پیاده هم از یولو استفاده می‌شود [Chen et al. 2020; Nugraha et al., 2017].

روش تشخیص مبتنی بر شبکه یولو به گونه‌ای است که ویژگی‌های مورد انتظار از قبیل: وجود لبه، مرز تغییر رنگ و ... را در چارچوب خاصی استخراج می‌کند و تمام این ویژگی‌ها را در نظر می‌گیرد. مدل یولو دارای مزایایی نسبت به سایر شبکه‌ها می‌باشد که در ادامه بیان شده است:

۳. معماری شبکه: معماری‌های شبکه عصبی گراف‌های جهت‌داری هستند که هر گره نقش نرون‌های مصنوعی را دارد و پیکان‌های جهت‌دار ارتباط بین خروجی‌ها و ورودی‌ها را نشان می‌دهند. از این رو شبکه‌های عصبی را در دو گروه اصلی تقسیم بندی می‌کنند: شبکه‌های پیش‌رو و شبکه‌های بازگشتی. شبکه‌های عصبی کانولوشن (به اختصار CNN) یکی از مهمترین الگوریتم‌های حوزه یادگیری ماشین مخصوصاً بینایی کامپیوتر می‌باشند. این شبکه‌ها در سال ۱۹۸۹ برای اولین بار مورد استفاده قرار گرفتند. و در سال‌های اخیر نوع عمیق آن‌ها بسیار مورد استفاده قرار گرفته‌اند. به صورت کلی هر شبکه کانولوشن از سه لایه اصلی تشکیل می‌گردد: لایه کانولوشن، لایه پولینگ، لایه کاملاً متصل. در حقیقت یک شبکه عصبی کانولوشن، شبکه‌ای سلسله مراتب می‌باشد که لایه‌های کانولوشنی آن چند در میان، میان لایه‌های پولینگ قرار دارد و پس از آن‌ها لایه‌های کاملاً متصل قرار دارند. [Krizhevsky et al., 2017].

### ۳-۲-۱ معماری‌های عصبی کانولوشنی

با پیشرفت و توسعه شبکه‌های عصبی کانولوشنی در حوزه بینایی ماشین مدل‌هایی ارائه گشته است که در ادامه به چند مدل بسیار پر کاربرد اشاره می‌گردد:

- ALEXNET: این معماری برای شبکه‌هایی دارای ۵ لایه کانولوشنی و ۳ لایه کاملاً متصل بسیار مناسب می‌باشد.
- RESNET: این معماری در سال ۲۰۱۵ توسط محققین شرکت مایکروسافت ارائه شد. این معماری دارای ۱۵۲ لایه می‌باشد که در تشخیص اشیاء عملکردی بهتر از انسان را ارائه داد.
- YOLO: این معماری سرعت بسیار بالایی نسبت به سایر معماری‌ها دارد و در سال ۲۰۱۵ برای اولین بار معرفی شد. مزیت دیگر این معماری تشخیص بلادرنگ و در لحظه می‌باشد.

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهپادی

- شبکه یولو دو جعبه تشخیص برای هر سلول ترسیم می‌کند، اما این جعبه از دو دسته مختلف می‌باشند. یعنی در هر سلول، از یک دسته دو جعبه نمی‌تواند ترسیم نماید.
- شبکه یولو توانایی تشخیص اشیاء بسیار کوچک را در تصاویر ندارد چون از ویژگی‌های کلی اشیاء برای تشخیص استفاده می‌نماید.

- توانایی تشخیص شیء مورد نظر در تصاویر ورودی با ابعاد جدید را دارا نمی‌باشد [Krizhevsky et al., 2017].

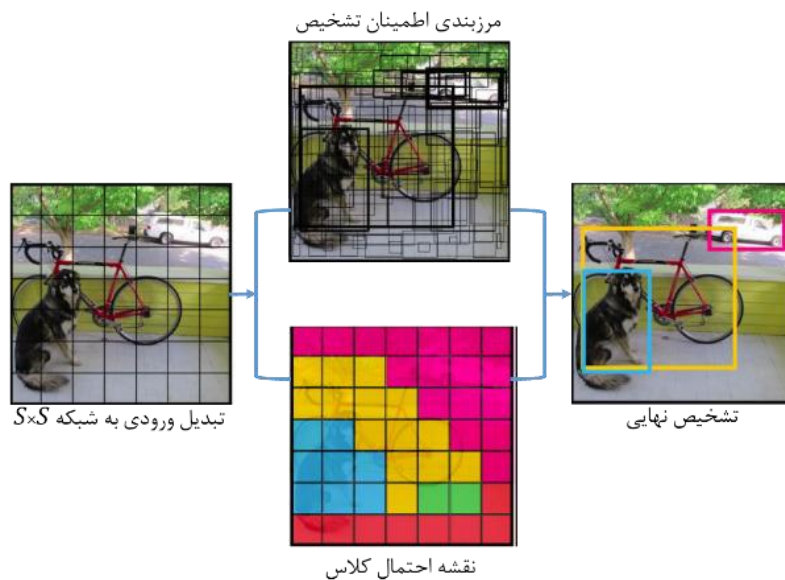
ایده اصلی یولو ۱ این است که یک سلول شبکه‌ای به اندازه  $S \times S$  ( $7 \times 7$  پیش فرض) را در یک تصویر اعمال می‌کند. اگر مرکز یک شیء در یک سلول شبکه بیفتد، آن سلول شبکه مسئول تشخیص آن شیء است (شکل 13). هر بخش از تصویر پنج متغیر دارد، متغیرهای  $x$  و  $y$  بیان‌کننده مختصات مرکز شیء مورد نظر در تصویر،  $w$  و  $h$  به ترتیب بیان‌کننده عرض و ارتفاع و نهایتاً بخش تشخیص متغیر  $confidence$ . به عنوان نمونه معیارهای مورد نظر در شکل 14 نشان داده شده‌اند.

- شبکه یولو دارای سرعت بسیار بالایی می‌باشد. دو شبکه برای یولو طراحی شده که به ترتیب یولو اصلی و یولو سریع نامیده می‌شوند. نسخه یولو سریع دارای سرعتی بیش از ۱۵۰ فریم‌برثانیه می‌باشد و یولو اصلی با کارت گرافیک Titan X دارای سرعت ۴۵ فریم‌برثانیه می‌باشد. در واقع شبکه یولو دارای سرعت بالایی نسبت به سایر شبکه‌های بلادرنگ می‌باشد.


- شبکه یولو در پیش‌بینی شیء و تشخیص آن، به صورت کلی (Global) به تصویر نگاه می‌کند. برخلاف روش‌های پنجره‌های لغزان (Slide)، شبکه یولو تمام تصویر را یکباره مورد ارزیابی قرار می‌دهد.

- شبکه یولو دارای قابلیت تعمیم‌پذیری می‌باشد. در واقع این شبکه در مواجهه با حوزه‌های جدید با احتمال کمتری نسبت به بقیه شبکه‌ها با شکست مواجه می‌شود.

همچنین شبکه یولو دارای محدودیت‌هایی نیز می‌باشد که در ادامه بیان شده است:



شکل ۱۳. مدل یولو با سلول شبکه‌ای  $7 \times 7$  بر روی تصویر ورودی [Redmon et al., 2016]



شکل ۱۴. معیارهای یک جعبه محدود در سلول شبکه ۳×۳ [Menegaz, 2018]

تعیین می‌شود. بود یا نبود شیء در هر بخش از تصویر به صورت صفر و یک بیان می‌شود. در صورت نبود شیء در یک بخش، اطمینان آن بخش،  $P_r$  برابر با صفر در نظر گرفته می‌شود. که در رابطه ۴ بیان شده است.

$$P_r(\text{Object}) = \begin{cases} 0 & \text{No target in the cell} \\ 1 & \text{There are targets in the cell} \end{cases} \quad (4)$$

اطمینان از وجود شیء در ناحیه =  $P_r(\text{Object})$

شیء در ناحیه وجود ندارد = No target in the cell

شیء در ناحیه وجود دارد = There are targets in the cell

در ادامه به صورت کلی نسخه‌های مختلف یولو ارائه شده‌اند.

### ۳-۳-۱ شبکه عصبی یولو ۱

مدل یولو به گونه‌ای طراحی شده است که تمام ویژگی‌های تصویر را پردازش می‌کند که نویسندگان آن، نامش را معماری دارکنت نامیده‌اند. به دنبال آن ۲ لایه کاملاً متصل برای پیش‌بینی جعبه مرزی برای اشیاء انجام طراحی شده است ( **Error!** Reference source not found). این مدل در مجموعه داده‌های پاسکال مورد ارزیابی قرار گرفته‌اند که دارای ۲۰ دسته است که با در نظرگیری ۲ پیش‌بینی، نهایتاً خروجی شبکه به صورت  $(7 \times 7) \times (20 + 5 \times 2)$  محقق می‌گردد.

در یولو ابتدا تصویر مورد استفاده برای آموزش شبکه به  $S \times S$  بخش تقسیم می‌شود. هر قسمت پیش‌بینی می‌کند که آیا مرکز شیء مورد نظر در آن قسمت قرار دارد یا خیر؛ در صورتی که وجود مرکز شیء در یک بخش تعیین شد، پیرامون مرکز شیء در داخل هر بخش، مرز شیء مشخص می‌شود سپس دقت هر قسمت

اگر درصد وجود شیء مورد نظر در تصویر ورودی با متغیر IOU نشان داده شود، مقدار IOU از رابطه ۵ بدست می‌آید.

$$IOU_{\text{truth pred}} = \frac{\text{area}(\text{box}(\text{truth}) \cap \text{box}(\text{pred}))}{\text{area}(\text{box}(\text{truth}) \cup \text{box}(\text{pred}))} \quad (5)$$

درصد وجود شیء مورد نظر در تصویر =  $IOU_{\text{truth pred}}$


=  $\text{area}(\text{box}(\text{truth}))$  مساحت ناحیه وجود شیء

=  $\text{area}(\text{box}(\text{pred}))$  مساحت ناحیه پیش‌بینی شیء

درصد اطمینان وجود شیء از رابطه ۶ بدست می‌آید.

$$\text{Conf}(\text{Object}) = \text{Pr}(\text{Object}) \times IOU_{\text{truth pred}} \quad (6)$$

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهبادی



شکل ۱۵. معماری اولیه یولو ۱

کناره‌گیری خود را از حوزه بینایی رایانه اعلام کرد و توسعه الگوریتم یولو را متوقف کرد. در سال ۲۰۲۰، الکسی بوچوفسکی، محقق و مهندس روسی، چارچوب دارکنت و ۳ معماری قبلی یولو را بر اساس ایده‌های نظری جوزف ردمون بر پایه C توسعه داد و نسخه یولو ۴ را منتشر نمود [Bochkovskiy et al., 2020].

### ۳-۳-۵ شبکه عصبی یولو ۵

در حقیقت یولو یک روش تشخیص اشیاء یک مرحله‌ای است. با انجام معماری CNN (شبکه عصبی کانولوشن) روی عکس می‌توانید موقعیت و نوع اشیاء را در تصویر قضاوت کنید. همچنین امکان افزایش سرعت تشخیص با تغییر در شبکه وجود دارد. بر این اساس همواره در نسخه‌های جدید یولو تلاش شده است تا در کنار کاهش خطای، سرعت تشخیص نیز افزایش یابد. ساختار شبکه یولو ۵ به سه قسمت ستون فقرات، گردن و خروجی تقسیم می‌شود. در ستون فقرات، تصویر ورودی با وضوح  $3 \times 640 \times 640$  از ساختار Focus عبور می‌کند. با استفاده از عمل برش، ابتدا به یک نقشه ویژگی  $320 \times 320 \times 12$  تبدیل می‌شود و سپس پس از عملیات کانولوشن  $32 \times 32$  هسته، در نهایت به یک نقشه ویژگی  $320 \times 320 \times 32$  تبدیل می‌شود.

### ۳-۳-۴ به کارگیری شبکه یولو

برای به کارگیری شبکه‌های عصبی، نخست باید داده‌هایی از جنس هدف، در اختیار آن قرار داد. پس از آن باید شبکه را به کمک این داده‌ها آموزش داد پس از آماده‌سازی شبکه، برای اعتبارسنجی، باید شبکه به دست آمده را با داده‌های آزمایشی،

### ۳-۳-۲ شبکه عصبی یولو ۲

نرمال سازی دسته ای یکی از رایج ترین روش های عادی سازی در مدل یادگیری عمیق است. با تثبیت توزیع لایه‌های ورودی در طول آموزش، امکان آموزش سریع‌تر و پایدارتر شبکه‌های عصبی عمیق فراهم می‌گردد [Ioffe & Szegedy, 2015]. در یولو ۲ نرمال‌سازی دسته‌ای در لایه‌های پیچشی اعمال شده است. این تکنیک نه تنها زمان آموزش را کاهش می‌دهد بلکه تعمیم شبکه را نیز افزایش می‌دهد. در یولو ۲، با اعمال نرمال سازی دسته‌ای میانگین دقت متوسط (mAP) حدود ۲ درصد افزایش یافته است. [Redmon et al., 2016].

### ۳-۳-۳ شبکه عصبی یولو ۳

شبکه یولو ۳ از ساختار بستر دارکنت  $53 \times 22$  به عنوان بستر اصلی طبقه‌بندی استفاده می‌کند. در مقایسه با بستر رزنت  $152 \times 23$  و رزنت  $101 \times 24$  که بسترهای پرکاربرد هستند؛ دارکنت  $53$  نه تنها دارای دقت طبقه‌بندی مشابه است، بلکه دارای سرعت محاسبه بسیار بالاتر و سریع‌تر و لایه‌های شبکه‌ای کمتری است. بر این اساس شبکه یولو ۳ دارای سرعت بسیار بالایی در تشخیص نسبت به دو نسخه قبلی یولو است.


### ۳-۳-۴ شبکه عصبی یولو ۴

الگوریتم اصلی یولو توسط جوزف ردمون نوشته شده است که نویسنده یک چارچوب سفارشی به نام دارکنت است. پس از ۵ سال تحقیق و توسعه برای نسل سوم یولو، جوزف ردمون به دلیل نگرانی از سوء استفاده از تحقیقاتش در برنامه‌های نظامی،

پس از انتخاب نوع پهپاد، جزئیات پرواز دارای اهمیت بالایی است. در جدول ۱ و شکل ۱۷ جزئیات پرواز با هدف برداشت اطلاعات ذکر شده است.

جدول ۱. جزئیات و نمای کلی برداشت اطلاعات با پهپاد

جزئیات برداشت اطلاعات با پهپاد	
ارتفاع پرواز	۱۵ تا ۲۰ متر
سرعت پرواز	۲۰ کیلومتر بر ساعت در شرایط جوی مساعد
زاویه دوربین	۱۰ تا ۱۵ درجه نسبت به محور قائم در جهت حرکت عمودپرواز
مسیر حرکت	محور اصلی مسیر (با خطای حداکثر ۲ متر در حین عمودپرواز)
عمودپرواز	پرواز از محور اصلی)



شکل ۱۷. جزئیات و نمای کلی برداشت اطلاعات با پهپاد

مدت زمان فیلم‌های به دست آمده از جستجوی در اینترنت نزدیک به ۶۰ دقیقه است و از نرم‌افزار Video to Picture برای جداسازی تصویر از فیلم استفاده شده است. با کمک این نرم‌افزار ۱۲۰۰ تصویر با وضوح  $1080 \times 1920$  با فرمت JPG از فیلم‌ها استخراج شد. در شکل ۱۸، نمونه‌ای از تصاویر به‌دست آمده، نشان داده شده است.



شکل ۱۸. نمونه تصویر شبکه ریلی جهت آموزش شبکه

ارزیابی کرد و میزان خطای آن را در تشخیص شیء مورد نظر به دست آورد. در این پژوهش، داده‌ها از جنس فیلم و عکس است. امروزه از شبکه‌های عصبی عمیق در صنایع دیگر هم استفاده می‌شود و نتایج آن بسیار رضایت‌بخش است، با توجه به اینکه در تعمیر و نگهداری زیرساخت‌های ترابری کمتر از این شبکه‌ها استفاده شده می‌توان امیدوار بود که با به کارگیری آن‌ها، دگرگونی چشمگیری در حوزه نظارت بر زیرساخت‌ها، اتفاق خواهد افتاد؛ چون این ایده، پتانسیل آن را دارد که برای دیگر معضلات زیرساخت‌های ترابری هم مورد استفاده قرار گیرد؛ تنها باید داده‌های از جنس فیلم یا عکس برای آموزش در اختیار شبکه قرار گیرد که برای تهیه این داده‌ها باید بازدید میدانی صورت گیرد یا از داده‌های مشابه استفاده کرد.

### ۳-۵ گردآوری داده‌های شبکه ریلی

همان‌گونه که پیش‌تر گفته شد، برای آموزش شبکه اولیه، باید داده‌هایی از جنس فیلم یا تصویر در اختیار مدل قرار داده شود. در این پژوهش، داده‌های مورد نظر که از جنس فیلم و تصویر هستند که با جستجو در فضای مجازی و اینترنت گردآوری شده‌اند. اما با هدف بیان جزئیات گردآوری میدانی فیلم و تصاویر می‌توان از پهپاد مدل فانتوم ۴<sup>۲۵</sup> استفاده نمود. لنز دوربین پهپاد مورد استفاده ۲۰ مگاپیکسل است و کیفیت فیلمبرداری آن 4K و با نرخ ۶۰ فریم بر ثانیه (۶۰FPS) می‌باشد. حداکثر سرعت این پهپاد ۷۲ کیلومتر در ساعت و حداکثر سرعت پرواز در شرایط باد ۴۰ کیلومتر در ساعت است. در شکل ۱۶ پهپاد فانتوم ۴ نشان داده شده است.



شکل ۱۶. پهپاد فانتوم ۴



## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهبادی

### ۳-۶ پیش پردازش تصاویر

گام دوم پس از گردآوری داده‌ها، پیش‌پردازش تصاویر است؛ این کار پیش از طبقه‌بندی تصاویر برای آموزش شبکه صورت می‌گیرد. از آنجایی که تمامی عکس‌های مورد استفاده در آموزش شبکه باید ابعاد یکسانی داشته باشند در نتیجه ابعاد همه عکس‌ها باید به مقدار مشخصی تغییر کند. برش تصاویر و تغییر اندازه آن‌ها، از جمله کارهایی است که در گام پیش‌پردازش تصاویر انجام می‌شود. یادآوری می‌شود که میزان تصاویر ورودی و ابعاد آن‌ها، تاثیر به سزایی در خروجی شبکه دارد.

### ۳-۷ برچسب زنی تصاویر

برچسب‌زنی تصاویر به معنی مشخص نمودن اشیاء و موقعیت آن‌ها در هر تصویر است. در هر تصویر در صورت وجود بیش از یک شیء باید همه آن‌ها برچسب زده شوند. مرحله برچسب زنی، آخرین مرحله پیش از آموزش شبکه است. در شکل 19 نمونه‌ای از برچسب‌زنی در شبکه ریلی نشان داده شده است.




شکل ۱۹. نمونه‌ای از برچسب زنی تصاویر (شبکه ریلی)

در این پژوهش از ۱۲۰۰ تصویر برای آموزش شبکه استفاده شد که ۶۰۰ مورد از آن‌ها برچسب‌زنی شدند و از بقیه تصاویر برای اعتبارسنجی شبکه استفاده شد.

### ۳-۸ معماری شبکه

در این پژوهش به منظور تشخیص هجوم ماسه‌های بادی در تصویر، از شبکه‌های عصبی یولو استفاده شده است. شبکه عصبی یولو شامل یک شبکه عصبی کانولوشنی با ۲۴ لایه کانولوشنی برای استخراج ویژگی و همچنین ۲ لایه فولی‌کانکتد<sup>۲۷</sup> برای پیش‌بینی احتمال و مختصات اشیاء است.

اندازه ورودی شبکه  $448 \times 448 \times 3$  است. تصویر ورودی به یک شبکه  $S \times S$  تقسیم می‌گردد و به شبکه پیچشی ارسال می‌گردد. خروجی شبکه ماتریسی به ابعاد  $S \times S \times 30$  است. هر یک از درایه‌های ماتریس  $S \times S$  خروجی معادل با یک سلول در شبکه  $S \times S$  ورودی است، خروجی  $S \times S \times 30$  شامل مختصات باکس‌ها و احتمال هاست. معماری شبکه یولو در شکل 20 نشان داده شده است [Guanqing et al., 2018].



شکل ۲۰. معماری شبکه یولو همراه با بیست و چهار لایه پیچشی [Guanqing et al., 2018]

فصلنامه مهندسی حمل و نقل / سال چهاردهم / شماره چهارم (۵۷) / تابستان ۱۴۰۲

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهپادی

دهندگان نرم افزار و مهندسان نرم افزار اجزای فعال‌سازی ویژگی استفاده از کارت گرافیک برای اهداف پردازشی عمومی را می‌دهد، در واقع با کودا می‌توان الگوریتم‌ها را سریعتر اجرا نمود.

### ۳-۹-۲ روش دوم، به کارگیری گوگل کولب

گوگل کولب محیطی با GPU قوی است که شرکت گوگل آن را به رایگان در اختیار کاربران قرار می‌دهد. با کمک این محیط کاربران می‌توانند بدون نیاز به سیستمی با پردازشگر گرافیکی قوی، یک شبکه را آموزش دهند. کاربران برای بهره‌مندی از قابلیت‌های گوگل کولب باید به زبان پایتون مسلط باشند و اتصال آن‌ها به اینترنت پایدار باشد چون در صورت قطع اینترنت امکان ادامه آموزش شبکه وجود ندارد؛ برای آموزش شبکه با کمک گوگل کولب، باید نخست داده‌ها را در گوگل درایو بارگذاری کرد که با توجه به حجم بالای داده‌ها، ممکن است ادامه کار کمی دچار مشکل شود. در این پژوهش به دلیل نبود دسترسی به رایانه‌ای با کارت گرافیک پر قدرت، برای آموزش شبکه از گوگل کولب استفاده شد.

پس از آموزش شبکه با یکی از دو روش گفته شده، یک فایل وزنی با پسوند weights به دست می‌آید. این فایل، تشخیص اشیای مورد نظر در تصاویر را ممکن می‌سازد. پس از آموزش، باید شبکه را با تصاویر بدون برچسب آزمود تا درصد خطای آن به دست آید از آنجایی که در این پژوهش، مطالعه موردی بر روی دو شیء صورت گرفته، اعتبارسنجی هر یک به صورت جداگانه در بخش نتایج ارائه شده است.

### ۳-۱۰-۱ اعتبارسنجی شبکه عصبی جهت تشخیص

#### هجوم ماسه‌های بادی

برای انجام این پژوهش ۱۲۰۰ داده از جنس تصویر تهیه شد که به دلیل محدودیت در شمار تصاویر پوشیده شده از ماسه، تنها از ۶۰۰ تصویر استفاده شد که ۳۰۰ مورد از آن‌ها بدون ماسه بر

در تمامی لایه‌ها از تابع فعال ساز لیک ریلو<sup>۲۸</sup> استفاده شده است. اندازه خروجی شبکه ۳۰×۷×۷ از پیش بینی‌ها است. در این ساختار تصاویر ورودی به یک شبکه ۷×۷ تقسیم بندی می‌شوند. بنابراین، خروجی ۷×۷ متناظر با تصویر شبکه شده ورودی است. هر درایه در ۷×۷ خروجی، متناظر با یک سلول در تصویر شبکه شده ورودی است. ضمناً هر درایه از این ماتریس ۷×۷ خروجی، یک بردار به طول ۳۰ دارد. این بردار به طول ۳۰ شامل اطلاعات پیش بینی احتمال‌ها و مختصات باکس است. به این صورت که هر سلول از این آرایه ۷×۷ دو باکس می‌تواند رسم کند. برای رسم هر باکس به ۵ پارامتر (x,y,w,h,confidence) نیاز است. پارامترهای X و Y مختصات سطر و ستون مبدأ باکس (مرکز باکس) را نشان می‌دهند. مختصات w و h به ترتیب متناظر با پهنا و ارتفاع باکس هستند. با این چهار پارامتر می‌توانیم باکس را ترسیم کنیم. پارامتر پنجم ضریب اطمینان است. لازم به توضیح است که یولو از نسخه تغییر یافته تابع اتلاف مجموع مربعات خطا<sup>۲۹</sup> استفاده می‌کند. [Guanqing et al., 2018].

### ۳-۹ آموزش شبکه

برای آموزش شبکه یولو دو راه وجود دارد، راه نخست، به کارگیری یک سیستم با قابلیت پشتیبانی از GPU است و راه دوم استفاده از فضای ابری گوگل کولب<sup>۳۰</sup> است؛


### ۳-۹-۱ روش اول، به کارگیری کارت گرافیک

در این روش از یک رایانه با ویژگی‌های گرافیکی قابل قبول، استفاده می‌شود. با استفاده از رویکرد GPGPU<sup>۳۱</sup> می‌توان از کارت گرافیک برای انجام پردازش‌های الگوریتم‌های شبکه عصبی استفاده کرد. این پردازش با استفاده از هسته‌های کودا<sup>۳۲</sup> صورت می‌گیرد. هسته‌های کودا یک لایه نرم افزاری است که دسترسی مستقیم جهت استفاده از مجموعه ساختارهای مجازی مربوط به کارت‌های گرافیک و پردازش موازی برای اجرای هسته‌های محاسباتی را می‌دهد. این بستر برای کار با زبان‌های C و C++ و فورتین طراحی شده است. کودا به توسعه

## پایش هجوم ماسه‌های بادی بر زیر ساخت‌های ریلی با استفاده از شبکه عصبی همگشتی و تصاویر پهپادی

ابعاد تصاویر خروجی شبکه،  $432 \times 768$  پیکسل است و شبکه قادر است هجوم ماسه‌های بادی را با دقت ۹۱ درصد شناسایی کند و زمان صرف شده برای هر عکس  $0/87$  ثانیه است. نمونه خروجی شبکه در شکل ۲۲ و شکل ۲۳ نشان داده شده است. با توجه به نتایج به دست آمده می‌توان گفت سرعت و دقت به شبکه یولو در تشخیص هجوم ماسه‌های بادی به ریل قابل قبول است.

روی ریل بود. در شکل ۲۱ تعداد برجسب‌ها برای دو دسته ریل پوشیده شده با ماسه و پوشیده نشده با ماسه نشان داده شده است.



شکل ۲۱. تعداد برجسب زده شده برای دو دسته تشخیص ماسه



شکل ۲۲. نمونه خروجی شبکه یولو در شبکه ریلی در جهت تشخیص ماسه های بادی



شکل ۲۳. نمونه خروجی شبکه یولو در شبکه ریلی در جهت تشخیص ماسه های بادی

تشخیص بحران و اقدام در مواجهه با آن بیشتر است و امید است که استفاده از این دانش آغازگر تحولی در پایش زیرساخت‌های ترابری باشد. برای مثال می‌توان به موضوع خرابی‌های ریلی و بست‌های ریلی با استفاده از علم بینایی ماشین اشاره کرد. از جمله محدودیت‌های موجود دشواری برداشت اطلاعات با توجه به مساعد نبودن شرایط جوی و آب و هوایی نواحی بیابانی می‌باشد. از این رو در برداشت این اطلاعات می‌بایست از پهپادهایی با قابلیت پرواز در شرایط آب‌وهوایی نامساعد استفاده نمود.

#### ۵. پی‌نوشت‌ها

1. Montero
2. Makantasis
3. Wei
4. Convolutional Neural Network
5. Wu
6. You Look Only Once
7. Region-based Fully Convolutional Networks
8. Single Shot Multibox Detector
9. Object detection algorithm
10. Intersection over Union
11. True Positive
12. False Positive
13. False Positive
14. True Negative
15. Precision
16. Recall
17. Average Precision
18. meanAverage Precision
19. Joseph Redmon
20. Alexey Bochkovskiy
21. Glenn Jocher
22. Darknet53
23. ResNet152
24. ResNet101
25. Phantom 4 Advanced
26. Frame Per Second
27. Fully Connected
28. Leaky ReLU Activation Function
29. Sum of Squares Error (SSE)
30. Google Colab

فصلنامه مهندسی حمل‌ونقل / سال چهاردهم / شماره چهارم (۵۷) / تابستان ۱۴۰۲

هدف نهایی این تحقیق تشخیص معضل بیان شده به صورت خودکار با استفاده از شبکه‌های عصبی عمیق و تصاویر پهپادی است. به کارگیری شبکه‌های عصبی عمیق، علاوه بر افزایش دقت باعث افزایش سرعت در تشخیص می‌گردد. در این روش می‌توان معضل موجود را با توجه به عکس دو بعدی به صورت بلادرنگ تشخیص داد.

با توجه به نوین بودن فناوری‌های یادگیری ماشین و کاربرد بالای آن، علم یادگیری ماشین به سرعت در حال پیشرفت در صنایع مختلف است. تحقیق حاضر حاصل به کارگیری علم یادگیری ماشین در حوزه زیرساخت‌های ترابری است. با توجه به نتایج بدست آمده، مشخص شده است که به کارگیری این فناوری در حوزه زیرساخت‌های ترابری دارای پتانسیل بالایی است. می‌توان با دقتی شدن در هر یک از بخش‌های مختلف این حوزه و بررسی نیازمندی‌های مورد نظر و بکارگیری فناوری یادگیری ماشین سبب بهبود وضعیت آن بخش گشت.

#### ۴. نتیجه‌گیری و پیشنهادها

در این پژوهش با استفاده از تصاویر پهپادی و شبکه‌های عصبی عمیق تلاش شده است تا معضل هجوم ماسه‌های بادی به ریل‌ها به صورت خودکار در هر محل شناسایی شود. بر این اساس با استفاده از شبکه عصبی یولو قابلیت تشخیص ماسه‌های بادی بر روی ریل با دقت ۹۱ درصد و زمان ۰٫۸۷ ثانیه برای هر عکس بدست آمده است. بکارگیری این فناوری در حوزه زیرساخت‌های ترابری دارای پتانسیل بالایی است و می‌توان استفاده از آن را روز به روز در امور مختلف گسترش داد. موضوع بررسی شده در این تحقیق تنها یکی از موضوعاتی است که می‌توان با استفاده از علم بینایی ماشین در زیرساخت‌های ترابری ارائه نمود. از این رو می‌توان بیان کرد این علم و فناوری پتانسیل بالایی در رفع معضلات موجود و کاهش اتلاف وقت و هزینه دارد. بنابراین با بررسی معضلات و چالش‌های موجود در زیرساخت‌های ترابری می‌توان با توجه به معیارها و ویژگی‌های چالش مورد نظر از علم بینایی ماشین استفاده نمود. با این روش، سرعت و دقت در

– Chen, Li et al. 2020. “Survey of Pedestrian Action Recognition Techniques for Autonomous Driving.” *Tsinghua Science and Technology* 25(4): 458–70.

– Cheng, Jian jun et al. 2015. “Characteristics of the Disastrous Wind-Sand Environment along Railways in the Gobi Area of Xinjiang, China.” *Atmospheric Environment* 102: 344–54.

– Cheng, Jian jun, and Chun xiao Xue. 2014. “The Sand-Damage-Prevention Engineering System for the Railway in the Desert Region of the Qinghai-Tibet Plateau.” *Journal of Wind Engineering and Industrial Aerodynamics* 125: 30–37.

– Cui, X., Wang, Q., Dai, J., Zhang, R., & Li, S. (2021). Intelligent recognition of erosion damage to concrete based on improved YOLO-v3. *Materials Letters*, 302(June), 130363. <https://doi.org/10.1016/j.matlet.2021.130363>

– Deng, Chuang et al. 2014. “Unmanned Aerial Vehicles for Power Line Inspection: A Cooperative Way in Platforms and Communications.” *Journal of Communications* 9(9): 687–92.

– Fan, Jin, and M Ala Saadeghvaziri. 2019. “Applications of Drones in Infrastructures: Challenges and Opportunities.” *World Academy of Science, Engineering and Technology International Journal of Mechanical and Mechatronics Engineering* Vol:13, No:10 13(10): 649–55. <https://doi.org/10.1063/5.0047880>.

– Koks, E.E., Rozenberg, J., Zorn, C. et al. A global multi-hazard risk analysis of road and railway infrastructure assets. *Nat Commun* 10, 2677 (2019). <https://doi.org/10.1038/s41467-019-10442-3>

31. General-Purpose Computing on Graphics Processing Units

32. Compute Unified Device Architecture

## ۶. مراجع

– هوشنگ صمدی پاکدل، ۱۳۹۹، “راهکارهای حفاظت از آهن راه خطوط درمقابل هجوم از ناشی بحران شن های روان بهینه راهکار ارایه و بحران مدیریت، دکتری دانشجویی، ایران، اصفهان، پژوه شاخص طبیعی بحران.”

– Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. <http://arxiv.org/abs/2004.10934>

– Bruno, Luca et al. 2018. “Shield for Sand: An Innovative Barrier for Windblown Sand Mitigation.” *Recent Patents on Engineering* 12(3): 237–46.

– Bruno, Luca, Davide Fransos, and Andrea Lo Giudice. 2018. “Solid Barriers for Windblown Sand Mitigation: Aerodynamic Behavior and Conceptual Design Guidelines.” *Journal of Wind Engineering and Industrial Aerodynamics* 173: 79–90.

– Bruno, Luca, Marko Horvat, and Lorenzo Raffaele. 2018. “Windblown Sand along Railway Infrastructures: A Review of Challenges and Mitigation Measures.” *Journal of Wind Engineering and Industrial Aerodynamics* 177(April): 340–65.

– Chen, Jieh Haur et al. 2017. “A Self Organizing Map Optimization Based Image Recognition and Processing Model for Bridge Crack Inspection.” *Automation in Construction* 73: 58–66.

– <http://dx.doi.org/10.1016/j.autcon.2016.08.033>.

0

- Montero, R. et al. 2015. “Past, Present and Future of Robotic Tunnel Inspection.” *Automation in Construction* 59: 99–112.
- Nugraha, Brilian Tafjira, Shun Feng Su, and Fahmizal. 2017. “Towards Self-Driving Car Using Convolutional Neural Network and Road Lane Detector.” *Proceedings of the 2nd International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology, ICACOMIT 2017* 2018-Janua: 65–69.
- Pérez-Ortiz, María et al. 2016. “Selecting Patterns and Features for Between- and within-Crop-Row Weed Mapping Using UAV-Imagery.” *Expert Systems with Applications* 47: 85–94.
- Radovic, Matija, Offei Adarkwa, and Qiaosong Wang. 2017. “Object Recognition in Aerial Images Using Convolutional Neural Networks.” *Journal of Imaging* 3(2).
- Rau, J. Y. et al. 2017. “Bridge Crack Detection Using Multi-Rotary UAV and Object-Base Image Analysis.” *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 42(2W6): 311–18.
- Shuai, Q., & Wu, X. (2020). Object detection system based on SSD algorithm. 2020 *International Conference on Culture-Oriented Science & Technology (ICCST)*, 141–144. <https://doi.org/10.1109/ICCST50977.2020.00033>
- Trubia, Salvatore, and Salvatore Curto. 2021. “The Use of UAVs for Civil Engineering Infrastructures.” *AIP Conference Proceedings* 2343, 110012 (2021).
- Krizhevsky, I. Sutskever, and G. E. Hinton. (2017). “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, doi: 10.1145/3065386.
- Li, Guanqing & Song, Zhiyong & Fu, Qiang. (2018). A New Method of Image Detection for Small Datasets under the Framework of YOLO Network. 1031-1035. 10.1109/IAEAC.2018.8577214.
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *32nd International Conference on Machine Learning, ICML 2015*, 1, 448–456.
- Makantasis, Konstantinos et al. 2015. *Proceedings - 2015 IEEE 11th International Conference on Intelligent Computer Communication and Processing, ICCP 2015 Deep Convolutional Neural Networks for Efficient Vision Based Tunnel Inspection*. Institute of Electrical and Electronics Engineers Inc.
- Menegaz, M. (2018). Understanding YOLO. *hackernoon*. Seach date 12.11.2021. <https://hackernoon.com/understanding-yolo-f5a74bbc7967>
- Menendez, E., J. G. Victores, R. Montero, and C. Balaguer. 2017. “Autonomous Robotic System with Tunnel Inspection Tool Positioning.” In *ISARC 2017 - Proceedings of the 34th International Symposium on Automation and Robotics in Construction, International Association for Automation and Robotics in Construction I.A.A.R.C.*, 655–62.
- Mohammed, Y., Uddin, N., Tan, C., & Shi, Z. (2020). Crack Detection using Faster R-CNN and Point Feature Matching. 10(3). <https://doi.org/10.19080/CERJ.2020.10.55579>



of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December, 779–788.

<https://doi.org/10.1109/CVPR.2016.91>

– Rozenberg, J. & Fay, M. Beyond the Gap: How Countries Can Afford the Infrastructure They Need While Protecting the Planet. (Washington, D.C., World Bank Group, 2019).

– Rioja, F. What is the value of Infrastructure Maintenance? A Survey. *Infrastructural Policies* 13,

– Zhao, Shuai et al. 2019. “Vehicle Detection in Aerial Image Based on Deep Learning.” *Journal of Physics: Conference Series* 1302(3).

<https://doi.org/10.1063/5.0047880>.

– Wang, Long, and Zijun Zhang. 2017. “Automatic Detection of Wind Turbine Blade Surface Cracks Based on UAV-Taken Images.” *IEEE Transactions on Industrial Electronics* 64(9): 7293–7309.

– Wei, X., Yang, Z., Liu, Y., Wei, D., Jia, L., & Li, Y. (2019). Railway track fastener defect detection based on image processing and deep learning techniques: A comparative study. *Engineering Applications of Artificial Intelligence*, 80, 66–81.

<https://doi.org/10.1016/j.engappai.2019.01.008>

– Wu, Yunpeng et al. 2019. “Densely Pyramidal Residual Network for UAV-Based Railway Images Dehazing.” *Neurocomputing*.

– Wu, Yunpeng, Yong Qin, Zhipeng Wang, and Limin Jia. 2018. “A UAV-Based Visual Inspection Method for Rail Surface Defects.” *Applied Sciences (Switzerland)* 8(7).

– Yuan, Chi, Zhixiang Liu, and Youmin Zhang. 2015. “UAV-Based Forest Fire Detection and Tracking Using Image Processing Techniques.” *2015 International Conference on Unmanned Aircraft Systems, ICUAS 2015*: 639–43.

– Zakeri, Jabbar-Ali, and Maryam Forghani. 2012. “Railway Route Design in Desert Areas.” *American Journal of Environmental Engineering* 2(2): 13–18.

– Zhang, J., Lu, C., Wang, J., Wang, L., & Yue, X.-G. (2019). Concrete Cracks Detection Based on FCN with Dilated Convolution. *Applied Sciences*, 9(13), 2686.

<https://doi.org/10.3390/app9132686>

– Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings*

محمد صفایی، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۶ از دانشگاه تهران و درجه کارشناسی ارشد را در رشته مهندسی عمران گرایش راه و ترابری در سال ۱۴۰۰ از همان دانشگاه اخذ نمود. زمینه های پژوهشی مورد علاقه ایشان مطالعات خردنگر ترافیکی، مطالعات هندسی معابر شهری، سیستم های حمل و نقل عمومی، بینایی ماشین و یادگیری عمیق است.



مهدی صمدزاد درجه کارشناسی در مهندسی عمران را در سال ۱۳۸۴ و درجه کارشناسی ارشد در مهندسی سازه را در سال ۱۳۸۷ از دانشگاه تهران دریافت کرد. وی در سال ۱۳۹۱ از مقطع دکتری در رشته برنامه ریزی حمل و نقل از دانشگاه پاریس شرق فارغ التحصیل شد. در حال حاضر ایشان استادیار دانشکده مهندسی عمران دانشگاه تهران است. زمینه های پژوهشی مورد علاقه ایشان شامل برنامه ریزی و مدل سازی تقاضا و پایش زیرساخت های حمل و نقل است.



مرتضی باقری، درجه کارشناسی در رشته مهندسی حمل و نقل ریلی را در سال ۱۳۸۱ از دانشگاه علم و صنعت و درجه کارشناسی ارشد در رشته مدیریت لجستیک و حمل و نقل را در سال ۱۳۸۳ از دانشگاه چالمرز سوئد اخذ نمود. در سال ۱۳۸۸ موفق به کسب درجه دکتری در رشته حمل و نقل از دانشگاه واترلو کانادا گردید. زمینه های پژوهشی مورد علاقه ایشان مهندسی حمل و نقل و مدیریت ایمنی و ریسک بوده و در حال حاضر عضو هیات علمی با مرتبه دانشیاری در دانشگاه علم و صنعت است.

